

Estado da publicação: O preprint não foi publicado em outro meio.

# Agente LLM com arquitetura Naive RAG aplicado à ouvidoria do SUS: uma proposta de automação inteligente para triagem e análise de manifestações cidadãs

Mara Dantas Pereira, Leonardo Andrade Santos Reginaldo, Míria Dantas Pereira

<https://doi.org/10.1590/SciELOPreprints.16445>

Submetido em: 2026-06-08

Postado em: 2026-06-15 (versão 1)

(AAAA-MM-DD)

# AGENTE LLM COM ARQUITETURA NAIVE RAG APLICADO À OUVIDORIA DO SUS: UMA PROPOSTA DE AUTOMAÇÃO INTELIGENTE PARA TRIAGEM E ANÁLISE DE MANIFESTAÇÕES CIDADÃS

## *LLM AGENT WITH NAIVE RAG ARCHITECTURE APPLIED TO THE SUS OMBUDSMAN'S OFFICE: AN INTELLIGENT AUTOMATION PROPOSAL FOR SCREENING AND ANALYZING CITIZEN COMPLAINTS*

Mara Dantas Pereira<sup>1\*</sup> <https://orcid.org/0000-0002-5943-540X>; Leonardo Andrade Santos Reginaldo<sup>2\*</sup> <https://orcid.org/0009-0003-7829-2250>; Míria Dantas Pereira<sup>3</sup> <https://orcid.org/0000-0002-9774-9717>

<sup>1</sup> Pós-graduanda em Desenvolvimento Full Stack, Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), Rio de Janeiro, Rio de Janeiro, Brasil.

<sup>2</sup> Mestrando no Programa de Pós-Graduação em Informática e Gestão do Conhecimento (PPGI), Universidade Nove de Julho (UNINOVE), São Paulo, São Paulo, Brasil.

<sup>3</sup> Pós-graduanda em Inteligência Artificial e Ciência de Dados na Saúde, Pontifícia, Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre, Rio Grande do Sul, Brasil.

\* Correspondência: [maradantaspereira@gmail.com](mailto:maradantaspereira@gmail.com) ou [leonardo.andrade.bi.ia@gmail.com](mailto:leonardo.andrade.bi.ia@gmail.com)

### Resumo

Os serviços de ouvidoria do Sistema Único de Saúde (SUS) recebem um volume crescente de manifestações cidadãs (reclamações, denúncias, sugestões e elogios) cuja análise manual impõe desafios operacionais à gestão em saúde pública. Este trabalho apresenta a implementação de um agente baseado em *Large Language Model* (LLM), utilizando arquitetura *Naive Retrieval-Augmented Generation* (RAG), para automatizar a triagem, a classificação de sentimentos e a elaboração de respostas às manifestações registradas na Ouvidoria SUS. A solução emprega o modelo *Llama 3* por meio da *API Ollama*, vetorização multilíngue com o modelo *paraphrase-multilingual-MiniLM-L12-v2*, recuperação de informações por similaridade de cosseno e uma interface interativa desenvolvida em *Gradio*, executada em ambiente Google Colab. O estudo descreve os componentes da arquitetura implementada e discute possibilidades de evolução para uma abordagem *Advanced RAG*, incorporando orquestração via *LangChain*, persistência vetorial em *PostgreSQL* com *pgvector* e ranqueamento por *Cross-Encoder*. A iniciativa dialoga com os avanços recentes na incorporação da inteligência artificial aos serviços de ouvidoria do SUS, evidenciando o potencial dessas tecnologias para otimizar os processos de escuta e atendimento no âmbito da saúde pública.

**Palavras-chave:** Modelo de Grande Linguagem; Geração Aumentada por Recuperação; Ouvidoria SUS; Processamento de Linguagem Natural; Saúde Pública Digital; Agentes de IA.

### Abstract

The ombudsman services of the Brazilian Unified Health System (SUS) receive an increasing volume of citizen complaints (complaints, denunciations, suggestions and compliments), the manual analysis of which poses operational challenges to public health management. This work

presents the implementation of an agent based on the Large Language Model (LLM), using Naive Retrieval-Augmented Generation (RAG) architecture, to automate the triage, sentiment classification, and response generation of complaints registered with the SUS Ombudsman. The solution employs the Llama 3 model through the Ollama API, multilingual vectorization with the paraphrase-multilingual-MiniLM-L12-v2 model, information retrieval by cosine similarity, and an interactive interface developed in Gradio, running in a Google Colab environment. The study describes the components of the implemented architecture and discusses possibilities for evolution towards an Advanced RAG approach, incorporating orchestration via LangChain, vector persistence in PostgreSQL with pgvector, and reranking by Cross-Encoder. This initiative aligns with recent efforts to incorporate artificial intelligence into the SUS (Brazilian Unified Health System) ombudsman services, reinforces the potential of these technologies to increase the efficiency of listening and service processes in public health.

**Keywords:** Big Language Model; Augmented Generation by Recovery; SUS Ombudsman; Natural Language Processing; Digital Public Health; AI Agents.

### Resumen

Los servicios de la Defensoría del Pueblo del Sistema Único de Salud (SUS) de Brasil reciben un volumen creciente de comentarios ciudadanos (quejas, denuncias, sugerencias y felicitaciones), cuyo análisis manual plantea desafíos operativos para la gestión de la salud pública. Este trabajo presenta la implementación de un agente basado en el Modelo de Lenguaje Grande (LLM), utilizando la arquitectura de Generación Aumentada con Recuperación Ingenua (RAG), para automatizar la clasificación, la categorización de sentimientos y la generación de respuestas a los comentarios registrados en la Defensoría del Pueblo del SUS. La solución emplea el modelo Llama 3 a través de la *API Ollama*, vectorización multilingüe con el modelo *paraphrase-multilingual-MiniLM-L12-v2*, recuperación de información por similitud de coseno y una interfaz interactiva desarrollada en *Gradio*, que se ejecuta en un entorno de Google Colab. El estudio describe los componentes de la arquitectura implementada y analiza las posibilidades de evolución hacia un enfoque RAG avanzado, que incorpore orquestación mediante *LangChain*, persistencia vectorial en *PostgreSQL* con *pgvector* y reordenamiento mediante *Cross-Encoder*. Esta iniciativa se alinea con los avances recientes en la incorporación de inteligencia artificial a los servicios de defensoría del paciente del Sistema Único de Salud (SUS) de Brasil, destacando el potencial de estas tecnologías para optimizar los procesos de atención y servicio dentro del sector de la salud pública.

**Palabras clave:** Modelo de lenguaje natural; Generación aumentada por recuperación; Defensor del paciente del SUS; Procesamiento del lenguaje natural; Salud pública digital; Agentes de IA.

## INTRODUÇÃO

A participação cidadã na gestão da saúde pública constitui um dos pilares do Sistema Único de Saúde (SUS), instrumentalizada, entre outros mecanismos, pelo sistema de ouvidorias. Regulamentadas pela Portaria GM/MS nº 2.416, de 7 de novembro de 2014, às Ouvidorias do SUS têm como mandato receber, analisar e encaminhar manifestações dos cidadãos (reclamações, denúncias, sugestões e elogios), além de realizar mediação administrativa visando à resolução de

problemas e ao subsídio dos gestores na melhoria contínua dos serviços de saúde<sup>1</sup>. O funcionamento integrado dos sistemas de informação das ouvidorias é disciplinado pela Portaria SE/MS nº 729, de 29 de dezembro de 2020, que consolida normas da Secretaria-Executiva do Ministério da Saúde e estabelece os parâmetros técnicos para o uso de ferramentas de integração de dados, como o sistema OuvidorSUS<sup>2</sup>.

O volume de manifestações gerenciadas por esse sistema é considerável. O Brasil possui uma população de mais de 200 milhões de pessoas potencialmente usuárias do SUS, o que torna inviável o processamento exclusivamente manual de demandas na escala requerida<sup>3</sup>. Esse cenário impõe desafios operacionais complexos, como garantir respostas ágeis e precisas, identificar padrões de insatisfação que possam sinalizar riscos ao cuidado do paciente e apoiar a tomada de decisão de gestores com base em evidências extraídas das manifestações recebidas. O Manual das Ouvidorias do SUS, disponibilizado pelo Ministério da Saúde, orienta os cidadãos sobre os canais de registro de manifestações, incluindo a Ouvidoria-Geral do SUS (OuvSUS), e detalha os fluxos de tramitação e resposta<sup>4</sup>.

Considerando esse cenário, tecnologias de Processamento de Linguagem Natural (PLN) e, mais recentemente, os *Large Language Models* (LLMs), têm emergido como soluções promissoras para a automação e qualificação do atendimento em serviços públicos. LLMs são modelos baseados na arquitetura Transformer, com centenas de bilhões de parâmetros, treinados em vastos corpos textuais, capazes de compreender e gerar linguagem natural com alto grau de coerência e contextualização<sup>5</sup>. Quando equipados com mecanismos de recuperação de informação externos, paradigma denominado *Retrieval-Augmented Generation* (RAG), esses modelos reduzem significativamente alucinações e ampliam sua acurácia em domínios especializados, incluindo aplicações médicas e de saúde pública<sup>6,7</sup>.

Iniciativas nacionais recentes corroboram a pertinência dessa abordagem. Em dezembro de 2025, o Ministério da Saúde brasileiro iniciou o projeto OuvidorSUS.IA em parceria com a Universidade Federal do Rio Grande do Norte (UFRN) e o Instituto Metrópole Digital (IMD), com investimento de aproximadamente R\$ 5,2 milhões, visando automatizar a classificação de manifestações, identificar demandas recorrentes e integrar a solução às plataformas FalaBR e OuvidorSUS<sup>8</sup>. Paralelamente, a Controladoria-Geral da União (CGU) apresentou, em 2025, estudo inédito aplicando técnicas de PLN, incluindo n-grams, PoS tagging e modelagem de tópicos (LDA), à análise de mais de 4.000 manifestações recebidas por quatro ministérios federais<sup>9</sup>.

Agentes baseados em LLMs, definidos como sistemas autônomos capazes de planejar, raciocinar e executar tarefas em sequências de passos, representam o estado da arte em aplicações de IA na medicina e nos serviços de saúde<sup>10,11</sup>. Revisões recentes documentam aplicações em suporte à decisão clínica, triagem de pacientes, geração de documentação clínica e otimização de fluxos de atendimento<sup>10,12</sup>, evidenciando o potencial transformador dessa tecnologia também em contextos de serviços públicos de saúde.

A proposta visa responder a uma demanda recorrente em contextos de análise de dados aplicados às ouvidorias, observada também na experiência do autor L.A.S.R., referente à identificação automatizada dos sentimentos presentes nas manifestações dos usuários. Assim, a seguinte questão de pesquisa foi formulada: “É possível automatizar a classificação de sentimentos em manifestações registradas na Ouvidoria do SUS, categorizando-as em positivas, neutras ou negativas por meio de técnicas de inteligência artificial e processamento de linguagem natural?”

Desse modo, este artigo descreve uma proposta técnica complementar a esse movimento, apresentando a arquitetura, implementação e análise de um agente LLM com Naive RAG aplicado a dados fictícios que simulam interações de pacientes com a Ouvidoria SUS. O objetivo é demonstrar a viabilidade técnica da abordagem em ambiente de prototipagem de baixo custo, discutir suas limitações e propor um *roadmap* evolutivo para adoção em produção.

## REFERENCIAL TEÓRICO

### *Large Language Models (LLMs)*

Os Large Language Models representam a fronteira atual do Processamento de Linguagem Natural. Conforme definição de Zhao et al. (2023), LLMs são “modelos de linguagem baseados em Transformer que contêm centenas de bilhões (ou mais) de parâmetros, treinados em dados textuais massivos”<sup>5</sup>. Suas capacidades emergentes, raciocínio em cadeia (*chain-of-thought*), geração contextualizada e adaptação por instrução (*instruction tuning*), os tornam adequados para tarefas complexas de diálogo, classificação e síntese de informações em contextos de saúde<sup>5,12</sup>.

A arquitetura *Transformer*, central a esses modelos, fundamenta-se no mecanismo de *self-attention*, que permite ao modelo ponderar a relevância de cada *token* em relação aos demais dentro de uma janela de contexto, capturando dependências de longa distância na linguagem<sup>12</sup>. Modelos da família *Llama*, desenvolvidos pela Meta AI e disponibilizados em versões abertas, têm demonstrado desempenho competitivo em *benchmarks* de compreensão e geração textual, com a

vantagem adicional de poderem ser executados localmente, aspecto crítico em contextos que envolvem dados sensíveis de saúde<sup>5,10</sup>.

Revisão sistemática de Wang et al. (2025), aceita no ACL 2025 Findings, fornece um panorama abrangente dos agentes LLM em medicina, examinando arquiteturas, mecanismos de planejamento clínico, *frameworks* de raciocínio médico e capacidades de melhoria por fontes externas<sup>10</sup>. O estudo conclui que, embora os agentes LLM demonstrem grande promessa na melhoria da assistência em saúde, desafios relacionados ao gerenciamento de alucinações, integração multimodal e considerações éticas permanecem como obstáculos relevantes a superar<sup>10</sup>.

### ***Retrieval-Augmented Generation (RAG)***

A arquitetura RAG, proposta por Lewis et al. (2020), combina um módulo de recuperação (*retriever*) com um módulo gerador (*generator*), permitindo que o LLM acesse bases de conhecimento externas em tempo de inferência, sem necessidade de retreinamento<sup>13</sup>. Essa abordagem é especialmente relevante para domínios especializados, pois mitiga o problema das alucinações, geração de informações plausíveis, porém factualmente incorretas, ao ancorar as respostas em documentos previamente recuperados e verificados<sup>6,7</sup>.

Em revisão narrativa publicada em *Digital Health* (2025), Kohandel Gargari e Habibi documentam aplicações de RAG em medicina abrangendo interpretação de diretrizes clínicas, assistência diagnóstica, triagem para elegibilidade em ensaios clínicos e chatbots de informação clínica<sup>7</sup>. O estudo demonstra que modelos GPT-4 aprimorados com RAG para interpretação de diretrizes hepatológicas alcançaram acurácia de 99,0%, em comparação a 43,0% do GPT-4 Turbo sem RAG ( $p < 0,001$ )<sup>7</sup>. Da mesma forma, sistemas RAG superaram o desempenho humano em triagem de pacientes para ensaios clínicos, atingindo acurácia de 93,6% frente a 85,9% do pessoal humano<sup>7</sup>.

A variante denominada *Naive RAG*, implementada no presente trabalho, opera por meio de busca vetorial direta, sem etapas intermediárias de re-ranking ou filtragem adaptativa, representando o ponto de entrada mais simples, reproduzível e computacionalmente acessível para prototipagem<sup>6</sup>. Abordagens avançadas, como o *Advanced RAG* e o *Modular RAG*, introduzem etapas adicionais de recuperação híbrida, reranking por *Cross-Encoder* e orquestração via *frameworks* como *LangChain*, elevando a precisão e a escalabilidade do sistema<sup>7</sup>.

## **LLMs em Saúde: Aplicações e Desafios**

A revisão de Maity e Saikia (2025), publicada em *Bioengineering*, oferece exame sistemático das aplicações de LLMs no domínio da saúde, cobrindo suporte à decisão clínica, educação médica, diagnóstico, cuidado ao paciente e descoberta de fármacos<sup>12</sup>. Os autores destacam que os LLMs apresentam aplicações promissoras em sistemas de triagem, modelos de interpretação de registros clínicos e ferramentas de geração de respostas a pacientes, enquanto apontam desafios críticos em privacidade, implantação ética e acurácia factual que precisam ser resolvidos para integração responsável em sistemas de saúde<sup>12</sup>.

No contexto específico do atendimento ao paciente, Busch et al. (2025) conduziram revisão sistemática publicada em *Communications Medicine* (Nature) analisando as aplicações atuais e os desafios dos LLMs no cuidado ao paciente<sup>14</sup>. O estudo evidencia que LLMs demonstram desempenho promissor em tarefas de triagem e geração de respostas em contextos clínicos, com a ressalva de que a validação em populações diversas e cenários reais permanece um desafio a ser superado<sup>14</sup>. Aspectos como viés algorítmico, interpretabilidade, conformidade regulatória (incluindo a Lei Geral de Proteção de Dados (LGPD) Lei nº 13.709/2018, no contexto brasileiro) e governança de dados são apontados como requisitos fundamentais para a implantação segura e ética dessas tecnologias em saúde pública<sup>12,14</sup>.

## **Contexto Regulatório das Ouvidorias do SUS**

A Portaria GM/MS nº 2.416/2014 estabelece as bases normativas para o funcionamento das ouvidorias no âmbito do SUS, definindo seus objetivos, competências e fluxos de atendimento<sup>1</sup>. Entre os pilares institucionais das Ouvidorias do SUS, destacam-se: (1) a escuta qualificada das manifestações cidadãs; (2) a mediação administrativa para resolução de conflitos entre usuários e serviços de saúde; e (3) o subsídio informado aos gestores para a melhoria contínua dos serviços<sup>3</sup>.

A Portaria SE/MS nº 729/2020 complementa esse arcabouço ao consolidar normas operacionais da Secretaria-Executiva do Ministério da Saúde, disciplinando o uso do sistema OuvidorSUS como plataforma de integração de dados entre as esferas federal, estadual e municipal<sup>2</sup>. Essa portaria define os parâmetros técnicos para registro, tramitação e resposta às manifestações, além de estabelecer os requisitos para interoperabilidade entre os sistemas de informação das ouvidorias em todo o território nacional<sup>2</sup>.

## METODOLOGIA

### Arquitetura Geral da Solução

A solução proposta segue uma arquitetura de agente LLM com Naive RAG, composta por sete etapas sequenciais, da ingestão dos dados à entrega da resposta ao usuário, conforme descrito a seguir.

*Etapa 1 - Ingestão Inteligente de Dados:* Os dados de entrada são fornecidos em formato Excel ou CSV, correspondendo a duas bases fictícias: uma de manifestações genéricas e outra de perguntas e respostas frequentes (FAQ). O pré-processamento inclui limpeza de colunas via método `.strip()`, responsável por eliminar espaços e caracteres indesejados nas strings, garantindo a integridade dos registros antes da indexação.

*Etapa 2 - Vetorização Multilíngue:* Os textos são convertidos em representações vetoriais densas (*embeddings*) utilizando o modelo *paraphrase-multilingual-MiniLM-L12-v2*, disponível na biblioteca *Sentence-Transformers*. Esse modelo foi selecionado por seu suporte nativo a múltiplos idiomas, incluindo o português, e por seu equilíbrio entre qualidade de representação semântica e eficiência computacional, sendo adequado para execução em ambiente de prototipagem.

*Etapa 3 - Recuperação Naive RAG:* A recuperação de contextos relevantes é realizada por busca vetorial direta, calculando a similaridade de cosseno entre o vetor da consulta do usuário e os vetores dos documentos indexados. Somente os *chunks* com similaridade superior ao limiar de 0,35 são considerados, filtrando resultados semanticamente distantes da consulta. Os três *chunks* com maior similaridade (Top-3) são selecionados para compor o contexto injetado no *prompt*.

*Etapa 4 - Montagem do Prompt:* O *prompt* final é construído pela injeção dos Top-3 *chunks* recuperados em um template estruturado que define uma *system persona* identificada como “Ouvidoria”. Essa *persona* orienta o modelo a responder de forma institucional, empática e objetiva, alinhada às diretrizes do serviço de ouvidoria pública estabelecidas pela Portaria GM/MS nº 2.416/2014<sup>1</sup>.

*Etapa 5 - Inferência Local com Llama 3:* A geração de respostas é realizada pelo modelo Llama 3, acessado via *API Ollama*. A execução local do modelo representa uma escolha deliberada de design, visando preservar a privacidade dos dados, considerada fundamental em contextos que envolvem informações de saúde sob o escopo da LGPD<sup>12</sup>, além de eliminar custos recorrentes associados ao uso de APIs proprietárias em nuvem.

*Etapa 6 - Interface Interativa em Gradio:* A solução é disponibilizada por meio de interface web desenvolvida com a biblioteca Gradio, renderizada diretamente no ambiente Google Colab. A interface inclui um campo de entrada para simulação de consultas de pacientes e uma aba analítica para visualização de métricas sobre a base de manifestações processada.

*Etapa 7 - Mecanismo Fail-Safe:* Nos casos em que nenhum *chunk* recuperado supera o limiar de similaridade estabelecido, o sistema retorna uma resposta estática predefinida (*fail-safe*), evitando que o modelo gere conteúdo sem embasamento factual nos documentos de referência, mitigação direta do risco de alucinações documentado na literatura<sup>7</sup>.

### **Stack Tecnológica**

A solução proposta foi desenvolvida utilizando uma arquitetura baseada em ferramentas de código aberto para processamento de dados, recuperação de informação e geração de linguagem natural. Os componentes tecnológicos empregados são apresentados no Quadro 1, que descreve os recursos utilizados em cada camada da aplicação.

Quadro 1 - Componentes da stack tecnológica empregados na implementação do agente LLM com arquitetura Naive RAG.

<b>Componente</b>	<b>Tecnologia</b>
Linguagem de Programação	Python 3.x
Bibliotecas de NLP/ML	NLTK, Sentence-Transformers
Interface Web	Gradio
Manipulação de Dados	Pandas
Ambiente de Execução	Google Colab (GPU T4)
Modelo LLM	Llama 3 (Meta AI)
Acesso ao Modelo	API Ollama (execução local)
Cálculo de Similaridade	Similaridade de Cosseno ( <i>in-memory</i> )

A Figura 1 apresenta o *pipeline* de execução da solução, evidenciando o fluxo de dados entre as etapas de preparação, vetorização, inferência pelo modelo Llama 3 via Ollama e disponibilização das funcionalidades ao usuário por meio da interface Gradio. Essa arquitetura foi concebida para permitir a prototipagem de um agente LLM com Naive RAG em ambiente de baixo custo e fácil reprodutibilidade.

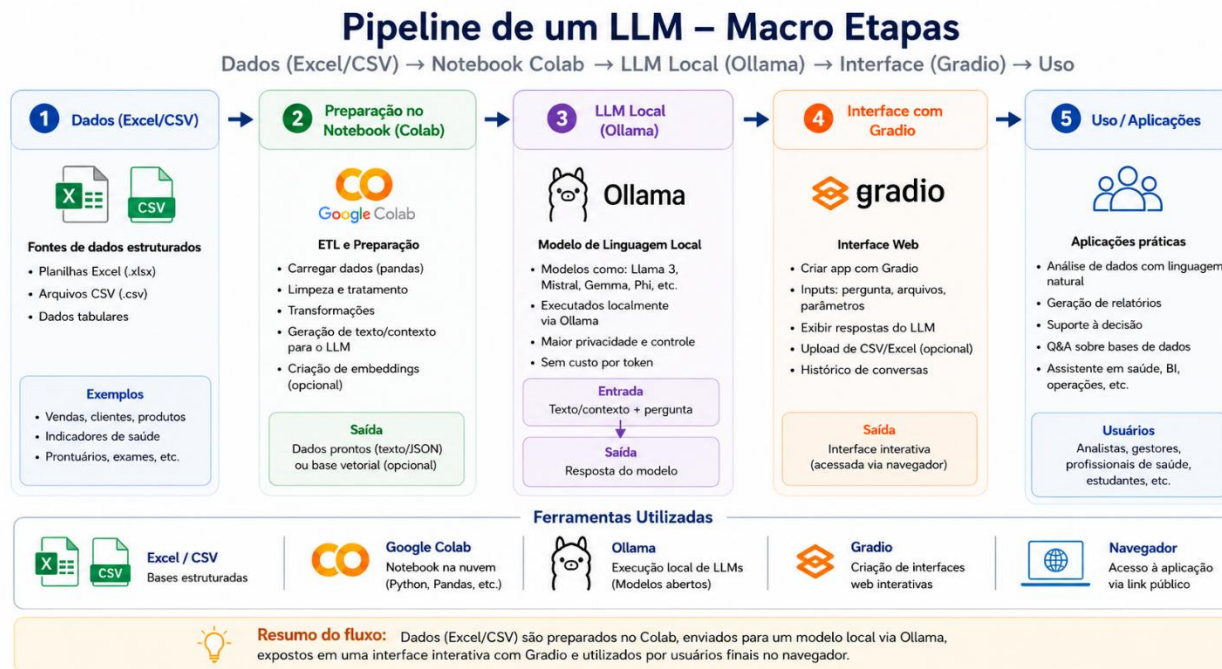


Figura 1 - Arquitetura e fluxo de processamento da solução proposta, desde a ingestão dos dados até a interação do usuário com o modelo de linguagem.

## Bases de Dados Utilizadas

Para fins de prototipagem e simulação, foram utilizadas duas bases de dados fictícias desenvolvidas especificamente para representar cenários típicos do contexto das ouvidorias em saúde pública. A primeira corresponde à base de Manifestações, composta por registros simulados de usuários contendo informações como identificador da manifestação, tipo de ocorrência (reclamação, sugestão, elogio ou denúncia), texto da manifestação e data de registro. Esses registros foram elaborados para reproduzir situações frequentemente observadas no cotidiano dos serviços de ouvidoria do SUS.

A segunda base consiste em um conjunto de FAQ, contendo pares de perguntas e respectivas respostas relacionadas aos serviços de saúde e aos procedimentos da ouvidoria. Essa base atua como a principal fonte de conhecimento utilizada pelo mecanismo RAG, permitindo a recuperação de contextos relevantes para apoiar a geração de respostas pelo modelo de linguagem.

A utilização de dados fictícios foi adotada como estratégia para garantir a conformidade com os requisitos éticos e de privacidade aplicáveis a sistemas que processam informações relacionadas à saúde. Dessa forma, não foram utilizados dados reais de cidadãos, em conformidade

com as disposições da LGPD (Lei nº 13.709/2018) e com as diretrizes de segurança da informação estabelecidas pelo Ministério da Saúde.

Após o carregamento das bibliotecas necessárias, inicialização do ambiente e disponibilização do modelo Llama 3 via *Ollama*, o sistema solicita ao usuário o envio dos arquivos obrigatórios que compõem a base de conhecimento da aplicação. Esses arquivos correspondem à base de FAQ e à base de Manifestações, que serão utilizadas nas etapas subsequentes de indexação, recuperação de contexto e geração de respostas. A Figura 2 apresenta a interface de *upload* implementada no Google Colab, na qual o usuário deve selecionar os dois arquivos antes da execução do *pipeline*.

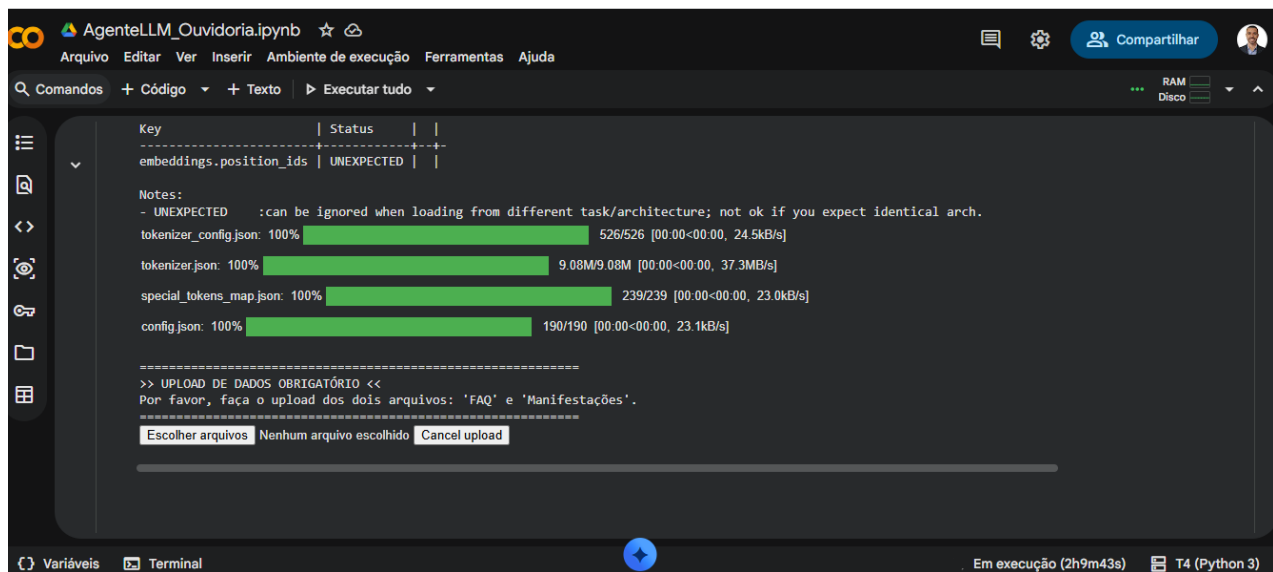


Figura 2 - Notebook Python, escolher arquivos obrigatórios.

As bases utilizadas na prototipagem foram estruturadas para representar cenários típicos do contexto das ouvidorias em saúde pública. A base de Manifestações Genéricas reúne registros simulados de interações de usuários com o sistema de ouvidoria, contemplando diferentes tipos de manifestações e classificações de sentimento. Já a base de FAQ constitui a principal fonte de conhecimento utilizada pelo mecanismo de recuperação de contexto do módulo RAG, contendo dúvidas recorrentes e respectivas respostas relacionadas aos serviços de saúde e aos procedimentos da ouvidoria.

As Figuras 3 e 4 apresentam exemplos das duas bases de dados utilizadas no desenvolvimento da solução.

ID	Polaridade	Manifestacao
1	Mista (Negativa-Positiva)	O médico foi atencioso, o que aliviou minha preocupação, mas a demora de mais de cinco horas na emergência é inaceitável e frustrante.
2	Mista (Negativa-Positiva)	Fiquei desapontada com a lentidão na emissão do laudo, porém a recepcionista Camila foi incrível em me ajudar, um conforto na espera.
3	Mista (Negativa-Neutra)	Apesar do medo que senti antes, a cirurgia foi um sucesso, o centro cirúrgico estava bem equipado e moderno.
4	Mista (Positiva-Neutra)	O prédio do posto de saúde é antigo, mas a equipe de enfermagem demonstrou ser maravilhosa e dedicada; a temperatura estava agradável.
5	Mista (Negativa-Neutra)	Receber o diagnóstico foi um choque para a família, as luzes do corredor, no entanto, piscavam de forma intermitente e constante.
6	Mista (Negativa-Positiva)	O convênio negou a cobertura inicialmente, causando grande frustração, mas a secretária conseguiu reverter a situação rapidamente.
7	Negativa	A comida hospitalar era terrível e intragável, o que prejudicou minha recuperação e humor, me deixando muito irritado.
8	Mista (Negativa-Neutra)	Achei estranho o revestimento das paredes da sala de exames, mas a espera de 40 minutos para o procedimento foi irritante e desnecessária.
9	Mista (Positiva-Neutra)	O cheiro de álcool nel no ambiente estava forte, como de costume, mas o farmacêutico corrigiu o erro a tempo, o que trouxe alívio.

Figura 3 - Base de Manifestações Genéricas contendo registros simulados de usuários da ouvidoria, incluindo identificador da manifestação, classificação de polaridade e descrição textual da manifestação.

Pergunta	Resposta
O que é a Ouvidoria da Saúde?	A Ouvidoria da Saúde é um canal institucional destinado a receber, analisar e encaminhar manifestações dos cidadãos sobre serviços de saúde, contribuindo para a melhoria dos serviços.
Quem pode utilizar a Ouvidoria?	Qualquer pessoa que tenha utilizado serviços de saúde, seja usuário, familiar, servidor, prestador ou representante legal.
Como faço para registrar uma reclamação?	Você pode registrar uma reclamação por telefone, e-mail, presencialmente ou pelo formulário eletrônico disponível no site da instituição.
Posso registrar minha manifestação de forma anônima?	Sim. É possível enviar uma manifestação sem identificação, porém o anonimato pode limitar o retorno de informações sobre o andamento do caso.
A Ouvidoria pode resolver problemas imediatamente?	Não necessariamente. A Ouvidoria é um canal mediador que analisa a manifestação e encaminha para os setores responsáveis. Cada caso pode demandar um tempo para ser resolvido.
Em quanto tempo receberei uma resposta?	O prazo médio de resposta é de até 30 dias corridos, podendo ser prorrogado mediante justificativa.
Como acompanho minha manifestação?	Ao registrar sua manifestação, você receberá um número de protocolo. Com ele, é possível acompanhar o andamento pelos canais oficiais da Ouvidoria.
A Ouvidoria pode punir profissionais?	A Ouvidoria não tem poder punitivo. Ela apura informações e encaminha o caso para os setores competentes, que podem adotar medidas administrativas.
Para que serve o protocolo de atendimento?	O protocolo é um identificador que permite consultar o progresso da manifestação e garantir rastreabilidade durante o tratamento.
Quais tipos de manifestações posso registrar?	Você pode registrar reclamações, elogios, denúncias, sugestões e solicitações relacionadas aos serviços de saúde.

Figura 4 - Base de Perguntas e Respostas Frequentes (FAQ) utilizada como fonte de conhecimento para recuperação de contexto, composta por pares de perguntas e respostas relacionadas aos serviços da Ouvidoria da Saúde.

## Análise de Sentimentos

Para a classificação das manifestações, foi implementado um módulo de análise de sentimentos utilizando a biblioteca NLTK, integrado à aba analítica da interface Gradio. O processamento inclui tokenização, remoção de *stopwords* e atribuição de polaridade às manifestações em três categorias (positivo, neutro e negativo). A classificação automática de sentimento responde diretamente à necessidade operacional identificada nos serviços de ouvidoria em saúde, como a priorização ágil de manifestações críticas com potencial impacto no cuidado do paciente.

## Síntese do *Pipeline* de Execução

O *pipeline* de execução da solução compreende nove etapas sequenciais. (1) Inicialmente, são carregadas as bibliotecas necessárias e realizado o processo de inicialização do ambiente *Ollama* com o modelo *Llama 3*. (2) Em seguida, o usuário realiza o *upload* obrigatório das bases de Manifestações e FAQ, que servirão como fontes de dados para o sistema. (3) Os arquivos passam por uma etapa de pré-processamento e limpeza, incluindo a remoção de espaços e caracteres indesejados por meio do método *.strip()*. (4) Posteriormente, os textos são convertidos em *embeddings* multilíngues utilizando o modelo *paraphrase-multilingual-MiniLM-L12-v2*.

Além disso, (5) quando uma consulta é inserida na interface *Gradio*, o sistema recebe a entrada do usuário e inicia o processo de recuperação de contexto. (6) Para isso, é calculada a similaridade de cosseno entre a consulta e os documentos indexados, aplicando-se um limiar mínimo de 0,35 para filtragem dos resultados. (7) Os três trechos mais relevantes (*Top-3 chunks*) são então selecionados e incorporados a um *prompt* estruturado contendo a persona institucional “Ouvidoria”. (8) O *prompt* é enviado ao modelo *Llama 3* por meio da *API Ollama* para realização da inferência e geração da resposta. (9) Por fim, o sistema retorna a resposta produzida ao usuário ou, quando não são encontrados contextos suficientemente relevantes, aciona um mecanismo *fail-safe* estático para evitar a geração de conteúdo sem embasamento documental.

## RESULTADOS

### Ingestão e Pré-processamento

O *pipeline* de ingestão processou com sucesso as duas bases fictícias fornecidas em formato CSV. A etapa de limpeza via *.strip()* revelou-se essencial para garantir a consistência dos registros, eliminando ruídos introduzidos por exportações de planilhas. Após o pré-processamento, os registros foram convertidos em *embeddings* e armazenados em memória para consulta em tempo de inferência. O *upload* interativo dos arquivos, exigido no início da sessão, permitiu o versionamento das bases e a substituição dinâmica dos documentos de referência sem necessidade de reinicialização do ambiente.

### Recuperação Semântica e Geração de Respostas

A busca por similaridade de cosseno demonstrou capacidade de recuperar contextos semanticamente relevantes para as consultas simuladas. O limiar de 0,35 mostrou-se adequado para

filtrar *chunks* irrelevantes sem comprometer a cobertura da base. Em consultas simulando perguntas típicas de pacientes, como dúvidas sobre prazos de resposta, procedimentos de reclamação e acesso a serviços específicos, o sistema recuperou consistentemente passagens pertinentes da base de FAQ e gerou respostas coerentes com a persona “Ouvidoria” definida no *prompt*. Nos casos em que nenhum *chunk* atingiu o limiar, o mecanismo *fail-safe* foi acionado, devolvendo resposta estática padronizada e evitando a geração de conteúdo sem respaldo documental.

### **Classificação de Sentimentos e Aba Analítica**

A aba analítica, desenvolvida em *Gradio*, viabilizou a classificação automática das manifestações em categorias de sentimento (positivo, neutro, negativo). Essa funcionalidade responde diretamente à demanda identificada nos projetos de análise de dados em ouvidorias de saúde, como a necessidade de priorização automática de manifestações críticas que possam indicar riscos ao cuidado do paciente, dado que o volume de registros torna inviável a triagem manual em tempo hábil. A Figura 5 ilustra o painel de análise de sentimento gerado pela interface, exibindo a distribuição das 500 manifestações processadas entre as categorias neutra (409), negativa (76) e positiva (15), representadas por um gráfico de barras com codificação cromática diferenciada, cinza para neutras, vermelho para negativas e verde para positivas. A predominância de manifestações neutras reflete o caráter majoritariamente descritivo ou informativo de parte dos registros simulados, enquanto o percentual de manifestações negativas (15,2%) evidencia o potencial do módulo de análise de sentimento para apoiar a triagem e priorização de casos críticos em cenários reais de ouvidoria. A aba analítica também serve como ferramenta de monitoramento do desempenho do modelo pelos desenvolvedores, permitindo identificar lacunas de cobertura na base de FAQ e orientar a curadoria contínua dos documentos de referência.

## Análise de Sentimento das Manifestações

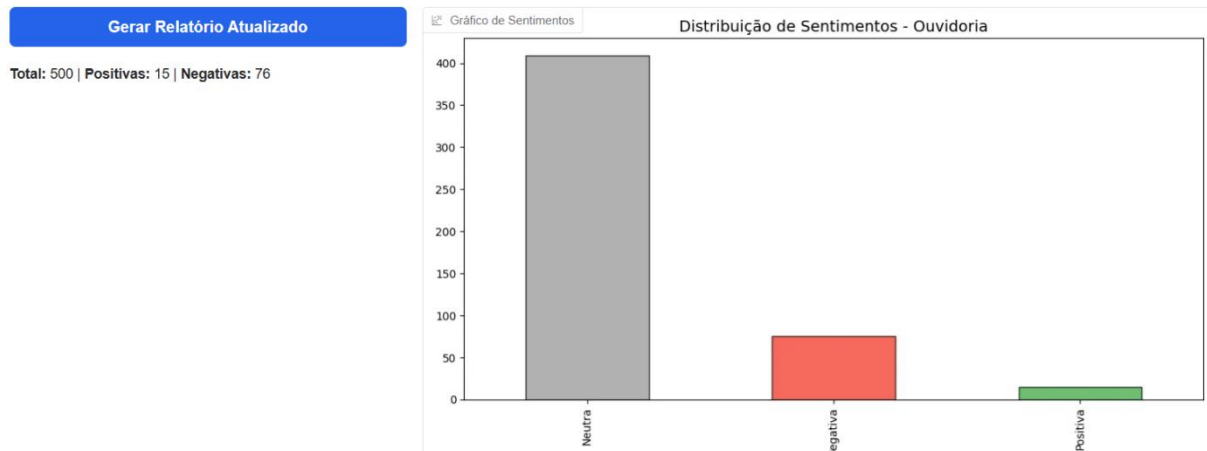


Figura 5 - Aba analítica da interface Gradio exibindo a distribuição de sentimentos das manifestações processadas, classificadas nas categorias neutra, negativa e positiva, a partir de um conjunto de 500 registros simulados da Ouvidoria SUS.

### Interface, Usabilidade e Execução em Baixo Custo

A interface *Gradio* permitiu a visualização e teste iterativo da solução diretamente no ambiente *Google Colab (GPU T4)*, sem necessidade de implantação em infraestrutura externa. Após o *upload* das bases obrigatórias, o sistema disponibiliza automaticamente um painel interativo renderizado no próprio notebook, possibilitando simular a experiência de um paciente ao interagir com a ouvidoria por meio do campo “Como posso ajudar você hoje?”. A Figura 6 apresenta a tela principal da interface, composta por duas abas funcionais: “Atendimento”, destinada à interação conversacional com o agente LLM, e “Dashboard de Gestão”, voltada ao monitoramento analítico das manifestações. A interface inclui aviso de conformidade com a LGPD e botão de acesso ao Termo de Uso, além de histórico de interações para rastreamento das consultas realizadas na sessão. A execução local do *Llama 3* via *Ollama* eliminou custos de API recorrentes, tornando a solução replicável em ambientes com recursos computacionais limitados.

## FAQ - Ouvidoria Inteligente da Saúde

Olá! Seja bem-vindo(a) à Ouvidoria da Saúde.

Seguimos a Lei Geral de Proteção de Dados Pessoais (LGPD). Ao continuar, você concorda com nosso [Termo de Uso](#)

### Como posso ajudar você hoje?

Histórico

Figura 6 - Interface interativa em Gradio da solução proposta, apresentando a aba “Atendimento” com campo de consulta ao agente LLM, aviso de conformidade com a LGPD e acesso ao histórico de interações da sessão.

## DISCUSSÃO

A solução descrita neste trabalho, se posiciona como contribuição ao ecossistema nascente de inteligência artificial aplicada às ouvidorias de saúde pública no Brasil. Diferentemente de projetos de grande escala, como o OuvidorSUS.IA do Ministério da Saúde, com horizonte de 24 meses e investimento de R\$ 5,2 milhões<sup>8</sup>, a presente proposta demonstra a viabilidade de uma abordagem funcional e reproduzível com recursos computacionais acessíveis, o que a torna relevante para municípios e estados com menor capacidade de investimento em tecnologia.

A literatura internacional, corrobora o potencial dos LLMs em contextos de atendimento ao paciente e serviços de saúde pública<sup>10,12,14</sup>. Wang et al. (2025) identificaram, em *survey* abrangente de agentes LLM em medicina, que os principais cenários de aplicação incluem suporte à decisão clínica, documentação médica, simulações de treinamento e otimização de serviços de saúde, categorias que se superpõem diretamente às funções das ouvidorias do SUS<sup>10</sup>. A abordagem *RAG*, especificamente, tem sido apontada como mecanismo eficaz para reduzir alucinações e aumentar a confiabilidade de respostas em domínios especializados de saúde<sup>6,7</sup>.

O sistema OuvidorSUS, atualmente em operação conforme disciplinado pela Portaria SE/MS nº 729/2020<sup>2</sup>, opera predominantemente com fluxos manuais de classificação e resposta. Ferramentas de análise de dados baseadas em PLN clássico, como as utilizadas no estudo da CGU

com *n-grams* e LDA<sup>9</sup>, oferecem capacidade descritiva e exploratória, mas não são capazes de gerar respostas conversacionais contextualizadas em tempo real. A abordagem baseada em agentes LLM com *RAG* representa um avanço qualitativo nesse sentido, pois integra recuperação semântica, geração contextualizada e interface conversacional em um único pipeline.

Comparativamente a chatbots baseados em árvores de decisão ou regras fixas, tecnologia mais amplamente disponível em portais de serviços públicos, os agentes LLM oferecem maior flexibilidade semântica, capacidade de lidar com consultas não previstas e possibilidade de adaptação dinâmica ao contexto da manifestação. A execução local do modelo *Llama 3* via *Ollama* agrega, ainda, vantagens de privacidade e independência de provedores de nuvem, aspectos críticos para sistemas que processam dados sensíveis de saúde sob o escopo da LGPD<sup>12</sup>. O Quadro 2 a seguir, sintetiza as diferenças entre as principais abordagens tecnológicas disponíveis no contexto das ouvidorias.

Quadro 2 - Comparação entre diferentes abordagens tecnológicas aplicáveis às ouvidorias, considerando flexibilidade semântica, capacidade de resposta conversacional, privacidade dos dados e custo de implantação.

<b>Tecnologia</b>	<b>Flexibilidade Semântica</b>	<b>Resposta Conversacional</b>	<b>Privacidade de Dados</b>	<b>Custo de Implantação</b>
Fluxo manual (OuvidorSUS atual)	N/A	Não	Alta	Baixo
Chatbot por regras/árvore de decisão	Baixa	Limitada	Alta	Baixo
PLN clássico ( <i>n-grams</i> , LDA)	Média	Não	Alta	Médio
LLM Naive RAG (proposta)	Alta	Sim	Alta (execução local)	Médio-Baixo
Advanced RAG ( <i>roadmap</i> )	Muito Alta	Sim	Alta (configurável)	Médio-Alto

Nota. N/A (Não Aplicável) indica que o critério não se aplica ao fluxo manual, por não envolver mecanismos automatizados de processamento ou interpretação semântica da linguagem.

A implementação atual apresenta limitações relevantes que devem ser consideradas antes de qualquer implantação em produção. Primeiro, o armazenamento vetorial em memória (*in-memory*) não é escalável para volumes de dados da magnitude do sistema OuvidorSUS, sendo adequado apenas para prototipagem. Segundo, o uso de dados fictícios impossibilita a avaliação do desempenho do modelo em distribuições reais de manifestações, o que pode mascarar problemas

de cobertura semântica e viés. Terceiro, a ausência de etapas de re-ranking e recuperação híbrida limita a precisão do sistema em consultas ambíguas ou com vocabulário técnico especializado.

Kohandel Gargari e Habibi (2025) documentam os desafios da implementação de RAG em contextos médicos, incluindo dependência da qualidade e atualidade das bases de conhecimento externas; riscos remanescentes de alucinações mesmo com recuperação de contexto, complexidade e heterogeneidade do conhecimento médico em diferentes formatos (texto, tabelas, fluxogramas), e custos computacionais e operacionais associados à manutenção dessas arquiteturas<sup>7</sup>. Todos esses desafios são pertinentes ao contexto das ouvidorias do SUS e devem ser endereçados no planejamento de implantação em produção.

Adicionalmente, a avaliação qualitativa por inspeção manual das respostas geradas, embora adequada para prototipagem, não substitui estudos controlados com avaliadores especializados e métricas automáticas robustas, como *ROUGE*, *BERTScore* ou avaliação por *LLM-as-judge*<sup>12,14</sup>.

Com base nas limitações identificadas e nas tendências da literatura especializada<sup>7,10</sup>, propõe-se o seguinte *roadmap* evolutivo para a solução:

*Orquestração via LangChain*: Implementação de *wrappers* de LLM para estruturação de fluxos complexos de *Advanced RAG*, incluindo roteamento de consultas, gerenciamento de memória de sessão e integração com múltiplas bases de conhecimento;

*Embeddings de Alta Performance*: Adoção do modelo *BGE-M3* via *Ollama*, que suporta representações vetoriais densas e esparsas simultaneamente, com desempenho superior em *benchmarks* multilíngues comparado ao *MiniLM*;

*Persistência Vetorial Escalável*: Migração do armazenamento em memória para *PostgreSQL* com a extensão *pgvector*, viabilizando a persistência, atualização incremental e consulta eficiente de bases de embeddings em escala de produção compatível com o volume do sistema OuvidorSUS;

*Recuperação Híbrida*: Combinação de busca semântica vetorial com busca lexical por palavras-chave (BM25), estratégia que demonstra ganhos consistentes de *recall* em domínios com terminologia técnica específica, como o vocabulário das ouvidorias de saúde<sup>7</sup>;

*Re-ranking por Cross-Encoder*: Refinamento dos resultados recuperados utilizando um *Cross-Encoder* para reordenação dos *chunks* com base na relevância contextual em relação à consulta, aumentando a precisão do contexto injetado no *prompt* e, conseqüentemente, a acurácia das respostas geradas<sup>7</sup>.

## CONCLUSÃO

Este trabalho demonstrou a viabilidade técnica de um agente LLM com arquitetura *Naive RAG* aplicado ao contexto da Ouvidoria SUS, utilizando ferramentas de código aberto e infraestrutura de baixo custo. A solução proposta se mostrou capaz de realizar triagem semântica de manifestações, recuperar contextos relevantes de bases de FAQ e gerar respostas coerentes com a persona institucional do serviço de ouvidoria, com potencial de aplicação em municípios e estados - com recursos tecnológicos limitados.

O alinhamento com o arcabouço normativo das Portarias GM/MS nº 2.416/2014 e SE/MS nº 729/2020, somado à convergência com iniciativas nacionais como o OuvidorSUS.IA e o estudo da CGU com PLN, confere relevância prática e política à proposta. O *roadmap* para *Advanced RAG* delineado representa uma agenda de pesquisa e desenvolvimento com potencial de impacto direto na eficiência e qualidade do atendimento ao cidadão no SUS, contribuindo para a realização dos objetivos institucionais das ouvidorias, tais como escuta qualificada, resposta ágil e subsídio informado à gestão pública em saúde.

A transição de sistemas manuais e ferramentas de PLN clássico para arquiteturas de agentes LLM com *RAG* não prescinde de governança de dados, validação clínica rigorosa e conformidade regulatória. A colaboração entre profissionais de ciência de dados, gestores de saúde e especialistas em regulação é condição necessária para que a tecnologia proposta transcenda o estágio de prototipagem e alcance implantação responsável em escala no sistema público de saúde brasileiro.

### Contribuição dos autores

Mara Dantas Pereira: Conceituação; Curadoria de dados; Análise formal; Investigação; Metodologia; Visualização; Escrita - rascunho original; Escrita - revisão e edição.

Leonardo Andrade Santos Reginaldo: Conceituação; Curadoria de dados; Investigação; Metodologia; Recursos; Programas; Escrita - rascunho original; Escrita - revisão e edição.

Míria Dantas Pereira: Investigação; Validação; Escrita - revisão e edição.

### Conflito de interesses

Os autores declaram não haver conflitos de interesses relacionados à publicação deste trabalho. A pesquisa foi realizada sem financiamento externo e sem vínculo com empresas ou organizações que possam ter interesse nos resultados apresentados.

## Disponibilidade de Dados

Os dados de pesquisa não estão publicamente disponíveis. As bases utilizadas neste estudo foram elaboradas com dados fictícios, em conformidade com os requisitos éticos e de privacidade estabelecidos pela Lei Geral de Proteção de Dados Pessoais (LGPD - Lei nº 13.709/2018), conforme justificado no manuscrito. Os dados disponíveis estão sob demanda, mediante solicitação justificada aos autores correspondentes.

## REFERÊNCIAS

1. Brasil. Ministério da Saúde. Portaria GM/MS nº 2.416, de 7 de novembro de 2014. Estabelece os requisitos para contratualização dos Hospitais Especializados em Oncologia e as diretrizes das Ouvidorias do SUS. Brasília: Ministério da Saúde; 2014. Disponível em: [https://bvsmms.saude.gov.br/bvs/2014/prt2416\\_07\\_11\\_2014.html](https://bvsmms.saude.gov.br/bvs/2014/prt2416_07_11_2014.html)
2. Brasil. Ministério da Saúde. Portaria SE/MS nº 729, de 29 de dezembro de 2020. Consolida normas da Secretaria-Executiva do Ministério da Saúde. Brasília: Ministério da Saúde; 2020. Disponível em: [https://bvsmms.saude.gov.br/bvs/saudelegis/se/2020/prt0729\\_30\\_12\\_2020.html](https://bvsmms.saude.gov.br/bvs/saudelegis/se/2020/prt0729_30_12_2020.html)
3. Brasil. Ministério da Saúde. Relatório de Gestão OuvSUS. Brasília: Ministério da Saúde; 2024. Disponível em: [https://www.gov.br/saude/pt-br/canais-de-atendimento/ouvsus/ouvidoria-em-numeros/relatorios-de-gestao/relatorio-ouvsus-versao-final\\_ascom\\_compressed.pdf](https://www.gov.br/saude/pt-br/canais-de-atendimento/ouvsus/ouvidoria-em-numeros/relatorios-de-gestao/relatorio-ouvsus-versao-final_ascom_compressed.pdf)
4. Brasil. Ministério da Saúde. Manual das Ouvidorias do SUS. Brasília: Ministério da Saúde; 2023. Disponível em: <https://www.gov.br/saude/pt-br/canais-de-atendimento/ouvsus/arquivos/manual-das-ouvidorias-do-sus.pdf>
5. Zhao WX, Zhou K, Li J, Tang T, Wang X, Hou Y, et al. A survey of large language models. arXiv preprint. 2023; arXiv:2303.18223. Disponível em: <https://arxiv.org/abs/2303.18223>
6. Gao Y, Xiong Y, Gao X, Jia K, Pan J, Bi Y, et al. Retrieval-augmented generation for generative artificial intelligence in medicine. *npj Health Systems*. 2025;2:3. doi:10.1038/s44401-024-00004-1
7. Kohandel Gargari O, Habibi G. Enhancing medical AI with retrieval-augmented generation: a mini narrative review. *Digital Health*. 2025;11:20552076251337177. doi:10.1177/20552076251337177. PMID: PMC12059965.

8. Sindicato dos Trabalhadores em Processamento de Dados de Mato Grosso (SINDPD-MT). Ferramenta de IA promete agilizar demandas da Ouvidoria do SUS [Internet]. 2025 [citado em 2026 jun 5]. Disponível em: <https://sindpd-mt.org.br/ferramenta-ia-agilizar-demandas-ouvidoria-do-sus/>
9. Brasil. Controladoria-Geral da União (CGU). CGU apresenta estudo inédito com uso de inteligência artificial para qualificar escuta nas ouvidorias [Internet]. Brasília: CGU; 2025 [citado em 2026 jun 5]. Disponível em: <https://www.gov.br/ouvidorias/pt-br/assuntos/noticias/2025/cgu-apresenta-estudo-inedito-com-uso-de-inteligencia-artificial-para-qualificar-escuta-nas-ouvidorias>
10. Wang W, Ma Z, Wang Z, Wu C, Ji J, Chen W, et al. A survey of LLM-based agents in medicine: How far are we from Baymax? arXiv preprint. 2025; arXiv:2502.11211 [cs.CL]. ACL 2025 Findings. doi:10.48550/arXiv.2502.11211
11. Nature Portfolio. AI agent in healthcare: applications, evaluations, and future directions. npj Digital Medicine. 2026. doi:10.1038/s44387-026-00076-4
12. Maity S, Saikia MJ. Large language models in healthcare and medical applications: a review. Bioengineering (Basel). 2025;12(6):631. doi:10.3390/bioengineering12060631. PMID: PMC12189880.
13. Lewis P, Perez E, Piktus A, Petroni F, Karpukhin V, Goyal N, et al. Retrieval-augmented generation for knowledge-intensive NLP tasks. Advances in Neural Information Processing Systems. 2020;33:9459–9474.
14. Busch F, Kather JN, Johner C, Moser M, Truhn D, Adams LC, et al. Current applications and challenges in large language models for patient care: a systematic review. Communications Medicine. 2025;5:19. doi:10.1038/s43856-024-00717-2
15. Brasil. Lei nº 13.709, de 14 de agosto de 2018. Lei Geral de Proteção de Dados Pessoais (LGPD). Brasília: Presidência da República; 2018. Disponível em: [https://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2018/lei/113709.htm](https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/113709.htm)

## Este preprint foi submetido sob as seguintes condições:

- Os autores declaram que os necessários Termos de Consentimento Livre e Esclarecido de participantes ou pacientes na pesquisa foram obtidos e estão descritos no manuscrito, quando aplicável.
- Os autores declaram que a elaboração do manuscrito seguiu as normas éticas de comunicação científica.
- Os autores declaram que estão cientes que são os únicos responsáveis pelo conteúdo do preprint e que o depósito no SciELO Preprints não significa nenhum compromisso de parte do SciELO, exceto sua preservação e disseminação.
- Os autores declaram que os dados, aplicativos e outros conteúdos subjacentes ao manuscrito estão referenciados.
- O manuscrito depositado está no formato PDF.
- Os autores declaram que a pesquisa que deu origem ao manuscrito seguiu as boas práticas éticas e que as necessárias aprovações de comitês de ética de pesquisa, quando aplicável, estão descritas no manuscrito.
- Os autores declaram que uma vez que um manuscrito é postado no servidor SciELO Preprints, o mesmo só poderá ser retirado mediante pedido à Secretaria Editorial do SciELO Preprints, que afixará um aviso de retratação no seu lugar.
- Os autores concordam que o manuscrito aprovado será disponibilizado sob licença [Creative Commons CC-BY](#).
- O autor submissor declara que as contribuições de todos os autores e declaração de conflito de interesses estão incluídas de maneira explícita e em seções específicas do manuscrito.
- Os autores declaram que o manuscrito não foi depositado e/ou disponibilizado previamente em outro servidor de preprints ou publicado em um periódico.
- Caso o manuscrito esteja em processo de avaliação ou sendo preparado para publicação mas ainda não publicado por um periódico, os autores declaram que receberam autorização do periódico para realizar este depósito.
- O autor submissor declara que todos os autores do manuscrito concordam com a submissão ao SciELO Preprints.