



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS QUIXADÁ

CURSO DE GRADUAÇÃO EM ENGENHARIA DE SOFTWARE

BRUNO LIMA FERREIRA

DESENVOLVIMENTO DE UM *CHATBOT* USANDO *LARGE LANGUAGE MODEL*
PARA SUPORTE TÉCNICO INTERATIVO A APICULTORES

QUIXADÁ

2026

BRUNO LIMA FERREIRA

DESENVOLVIMENTO DE UM *CHATBOT* USANDO *LARGE LANGUAGE MODEL* PARA
SUPORTE TÉCNICO INTERATIVO A APICULTORES

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia de Software
do Campus Quixadá da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Engenharia de Software.
Orientador: Prof. Dr. Antonio Rafael Braga.

QUIXADÁ

2026

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F439d Ferreira, Bruno Lima.

Desenvolvimento de um chatbot usando large language model para suporte técnico interativo a apicultores / Bruno Lima Ferreira. – 2026.
39 f. : il.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá, Curso de Engenharia de Software, Quixadá, 2026.
Orientação: Prof. Dr. Antonio Rafael Braga.

1. Apicultura. 2. Inteligência Artificial. 3. RAG. 4. LLM. 5. Engenharia de Software. I. Título.
CDD 005.1

AGRADECIMENTOS

A conclusão deste trabalho marca o fim de um ciclo intenso e transformador. Mais do que um requisito acadêmico, este projeto representa a soma de esforços, noites de estudo e, principalmente, o apoio inestimável de pessoas que tornaram essa jornada possível.

Primeiramente, agradeço a Deus, por ter me dado saúde, sabedoria e força para persistir nos momentos em que o código parecia não compilar e o cansaço batia. A fé foi meu refúgio e minha renovação diária.

Aos meus pais, Jaylincoln Lopes Ferreira e Valneide Melo Lima, à minha tia Jacqueline Lopes Ferreira e ao meu irmão Guilherme Lima Ferreira, e aos meus avós, minha eterna gratidão. Vocês são minha base e meus maiores incentivadores. Obrigado por cada palavra de apoio, pelo suporte incondicional e por acreditarem no meu potencial, mesmo quando eu duvidava. Tudo o que conquistei até aqui tem a assinatura do amor e do sacrifício de vocês.

Ao meu orientador, professor Antonio Rafael Braga, agradeço imensamente pela condução deste trabalho. Obrigado pela paciência, pelas direções certas e por me guiar no desenvolvimento deste projeto, desde a concepção da ideia sobre a apicultura até a implementação final do chatbot. Sua mentoria foi fundamental para o meu amadurecimento como pesquisador e desenvolvedor.

Aos professores do curso de Engenharia de Software da UFC – Campus Quixadá. Sou grato não apenas pelo conhecimento técnico repassado, mas por me desafiarem a pensar criticamente e a resolver problemas complexos. Cada disciplina contribuiu para a construção do profissional que me torno hoje.

Aos meus amigos e colegas de curso, parceiros de "batalha". Agradeço pelas trocas de conhecimento, pela ajuda mútua na resolução de bugs, pelas conversas nos corredores e pelo companheirismo que tornou a carga mais leve. As amizades construídas aqui levarei para a vida inteira.

Por fim, agradeço à Universidade Federal do Ceará, em especial ao Campus de Quixadá, por ser um espaço de excelência e oportunidades, que me permitiu crescer pessoal e profissionalmente.

A todos que, direta ou indiretamente, contribuíram para que eu chegasse até aqui: meu muito obrigado.

RESUMO

A apicultura no semiárido brasileiro, especificamente no Sertão Central do Ceará, enfrenta desafios significativos relacionados à escassez de assistência técnica presencial e à dificuldade de acesso à informação especializada. Este trabalho apresenta o desenvolvimento de um assistente virtual inteligente integrado ao aplicativo móvel “Revise!”, projetado para fornecer suporte técnico a pequenos produtores. A solução utiliza a arquitetura RAG (*Retrieval-Augmented Generation*) para alinhar o poder gerativo de Grandes Modelos de Linguagem (LLMs) com a precisão técnica de manuais da Embrapa e SEBRAE. A metodologia englobou a estruturação de uma base de conhecimento vetorial, a implementação de uma API em *FastAPI* e a validação de campo com apicultores. Os testes comparativos demonstraram que o modelo de vetorização *BERT-PT* superou modelos genéricos multilíngues, reduzindo alucinações e garantindo maior aderência terminológica ao contexto regional. Os resultados indicam que o sistema é capaz de diagnosticar problemas sanitários e de manejo com alta precisão. A validação qualitativa final revelou que, embora haja demanda por interfaces de voz, o uso silencioso (texto) é preferível durante o manejo no apiário para evitar o estresse do enxame. Conclui-se que a ferramenta viabiliza o acesso democratizado ao conhecimento técnico, mitigando a lacuna de extensão rural na região.

Palavras-chave: apicultura; inteligência artificial; RAG; LLM; engenharia de software.

ABSTRACT

Beekeeping in the Brazilian semi-arid region, specifically in the Central Backlands of Ceará, faces significant challenges regarding the scarcity of on-site technical assistance and difficulty in accessing specialized information. This work presents the development of an intelligent virtual assistant integrated into the “Revise!” mobile application, designed to provide technical support to small producers. The solution employs the RAG (Retrieval-Augmented Generation) architecture to align the generative power of Large Language Models (LLMs) with the technical precision of manuals from Embrapa and SEBRAE. The methodology encompassed the structuring of a vector knowledge base, the implementation of a FastAPI backend, and field validation with beekeepers. Comparative tests demonstrated that the BERT-PT embedding model outperformed generic multilingual models, reducing hallucinations and ensuring greater terminological adherence to the regional context. The results indicate that the system is capable of diagnosing sanitary and management problems with high precision. Final qualitative validation revealed that, although there is a demand for voice interfaces, silent usage (text) is preferable during apiary management to avoid stressing the swarm. It is concluded that the tool enables democratized access to technical knowledge, mitigating the rural extension gap in the region.

Keywords: beekeeping; artificial intelligence; RAG; LLM; software engineering.

SUMÁRIO

1	INTRODUÇÃO	7
1.1	Objetivos	8
1.1.1	<i>Objetivo Geral</i>	8
1.1.2	<i>Objetivos Específicos</i>	8
1.2	Estrutura do Trabalho	9
2	FUNDAMENTAÇÃO TEÓRICA	10
2.1	Apicultura	10
2.2	<i>Large Language Models (LLMs)</i>	11
2.2.1	<i>Definição, Treinamento e Personalização</i>	12
2.2.2	<i>Recuperação Aumentada e Representação Vetorial</i>	12
2.2.3	<i>LLMs no Contexto Apícola</i>	13
2.3	<i>Design Inclusivo e Acessibilidade em Chatbots Apícolas</i>	13
2.3.1	<i>Princípios e Estratégias para Interfaces Acessíveis</i>	13
3	TRABALHOS RELACIONADOS	15
3.1	<i>FarmerChat: Chatbot Agrícola com RAG</i>	15
3.2	<i>PLLaMa: Modelo de Linguagem para Ciências Vegetais</i>	16
3.3	<i>Chatbots para Análise de Ribo-seq</i>	16
3.4	<i>Análise Comparativa</i>	17
4	METODOLOGIA	18
4.1	Coleta e Curadoria de Dados	18
4.2	Levantamento e Análise de Requisitos	19
4.3	Configuração do Modelo de Linguagem	20
4.4	Desenvolvimento do Sistema Conversacional	21
4.4.1	<i>Delimitação de Escopo e Autoria</i>	21
4.5	Integração e Testes de Funcionalidade	22
4.6	Avaliação e Validação	23
4.7	Análise de Dados	23
4.8	Aspectos Éticos	23
5	DESENVOLVIMENTO E RESULTADOS	25
5.1	Análise do Perfil e Requisitos do Usuário	25

5.1.1	<i>Conectividade e Infraestrutura</i>	25
5.1.2	<i>Preferências de Interação e Demandas</i>	26
5.2	Implementação do Ecossistema Inteligente	26
5.2.1	<i>Backend e Processamento de IA</i>	27
5.2.2	<i>Conectividade e Interface Móvel</i>	27
5.3	Avaliação Técnica do Modelo	28
5.3.1	<i>Validação da Arquitetura: A Necessidade do RAG</i>	29
5.3.2	<i>Seleção de Embedding: Impacto na Recuperação de Contexto</i>	29
5.3.3	<i>Avaliação Semântica (BERTScore)</i>	30
5.4	Análise Exploratória	30
6	CONCLUSÃO	32
6.1	Contribuições	32
6.2	Limitações e Desafios	32
6.3	Trabalhos Futuros	33
	REFERÊNCIAS	34
7	QUESTIONÁRIO APLICADO AOS APICULTORES	38

1 INTRODUÇÃO

Graças à rica biodiversidade e ao clima favorável no Brasil, a apicultura tem crescido rapidamente como uma atividade de grande importância socioeconômica no país, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2023). Apenas no ano de 2023, foram produzidas 64 mil toneladas de mel por 350 mil apicultores, sendo a maioria pequenos produtores (Araújo *et al.*, 2018). Além de gerar renda, a atividade promove a sustentabilidade agrícola e a conservação da biodiversidade por conta da polinização que as abelhas realizam; elas são responsáveis por cerca de 70% da polinização de culturas como frutas e grãos (Klosowski *et al.*, 2020). Nesse sentido, a produção de mel não traz benefícios apenas para o mercado local, como também movimenta a economia através das exportações: cerca de 80% do mel produzido é direcionado ao exterior (Cavalcante, 2023), o que demonstra a importância da apicultura como um pilar para o desenvolvimento rural.

No entanto, mesmo com todas essas vantagens, pequenos produtores enfrentam desafios significativos na prática da apicultura. Esses desafios se devem principalmente à falta de acesso a informações técnicas atualizadas e ao suporte especializado escasso, tornando o manejo de colmeias e o controle de pragas tarefas árduas, especialmente em regiões rurais com baixa infraestrutura (Cavalcante *et al.*, 2024). Além disso, a ausência de conscientização sobre o uso adequado de defensivos agrícolas prejudica a saúde das abelhas, comprometendo o manejo sustentável (Assad, 2024). Iniciativas como cursos do Serviço Nacional de Aprendizagem Rural (SENAR), assistência técnica da Emater e manuais do Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (SEBRAE) buscam mitigar esses problemas. Contudo, essas soluções enfrentam barreiras consideráveis, como a baixa acessibilidade devido à dispersão dos apicultores entre as regiões e a dificuldade de acesso para produtores sem domínio da tecnologia (Postelaro *et al.*, 2021).

A falta de um apoio técnico eficiente para os apicultores do sertão central do Ceará, somada à oportunidade de usar a tecnologia para ajudar, é a principal motivação para este projeto. Isso ocorre porque muitos pequenos produtores dependem de um conhecimento prático que nem sempre gera bons resultados (Bernardo *et al.*, 2023). Nesse cenário, a engenharia de *software* oferece as ferramentas necessárias para mudar essa situação. Como a apicultura é uma área com grande potencial de crescimento (IBGE, 2023), este trabalho busca desenvolver uma solução tecnológica para facilitar as práticas diárias e, assim, melhorar a vida e o trabalho desses produtores.

Para superar essa barreira de comunicação entre o produtor e o conhecimento técnico, é necessária uma tecnologia para ser a ponte que os une. As interfaces conversacionais, conhecidas como *chatbots*, são ideais para essa função, pois se baseiam no diálogo natural, diminuindo a complexidade de aplicativos tradicionais (Capra *et al.*, 2021). Essa abordagem não só promove a inclusão digital ao oferecer um "especialista virtual" (Serasa Experian, 2023), como também faz uso direto dos recentes avanços em inteligência artificial.

Nesse contexto, os avanços recentes na apicultura de precisão, como sensores e aplicativos para monitoramento de colmeias, demonstram um novo potencial das tecnologias digitais nesse setor (Alleri *et al.*, 2023). Nesse mesmo sentido, os benefícios da tecnologia de Modelos de Linguagem Grandes (do inglês, *Large Language Models* — LLMs), capazes de processar linguagem natural e integrar bases de conhecimento, já têm sido aplicados na agricultura para fornecer orientações personalizadas a pequenos agricultores, superando barreiras de alfabetização tecnológica por meio de interfaces intuitivas (Elijah *et al.*, 2020). Apesar dessas inovações, não há registros de *chatbots* voltados especificamente para apicultores, que poderiam integrar dados de aplicativos apícolas e manuais técnicos, como os do SEBRAE, para oferecer respostas acessíveis e contínuas. Essa lacuna representa uma oportunidade para desenvolver soluções que promovam a inclusão digital e a sustentabilidade na apicultura.

1.1 Objetivos

1.1.1 *Objetivo Geral*

O trabalho tem o propósito de criar e validar um *chatbot* baseado em LLM que ofereça suporte técnico interativo, *acessível e adaptado* às necessidades de apicultores do sertão central do Ceará.

1.1.2 *Objetivos Específicos*

- a) Desenvolver um *chatbot* utilizando um modelo de linguagem aberto integrado a uma Interface de Programação de Aplicações (API) e uma base de conhecimento apícola estruturada, capaz de responder em linguagem simples a consultas sobre manejo de colmeias e produção de mel.
- b) Testar e avaliar o *chatbot* em situações práticas de apicultura, medindo sua precisão nas respostas por meio de métricas como BERTScore, a facilidade de uso por apicultores e a

- satisfação dos usuários em cenários como controle de pragas e planejamento de colheitas.
- c) Mapear os desafios técnicos e contextuais do uso de LLMs na apicultura, incluindo limitações de acesso à internet, variações regionais nas práticas apícolas e barreiras de alfabetização tecnológica, propondo soluções ou ajustes para implementações futuras.

1.2 Estrutura do Trabalho

O restante deste trabalho está organizado em cinco capítulos adicionais. O Capítulo 2 aborda os conceitos teóricos que embasam o desenvolvimento do *chatbot*. O Capítulo 3 discute trabalhos relacionados, destacando lacunas que justificam a proposta. O Capítulo 4 detalha os procedimentos metodológicos utilizados, enquanto o Capítulo 5 apresenta o desenvolvimento e os resultados obtidos. Por fim, o Capítulo 6 apresenta as conclusões e sugestões de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo apresenta-se a fundamentação teórica que sustenta o desenvolvimento do projeto. A seção 2.1 contextualiza a apicultura e suas principais demandas técnicas. Em seguida, a seção 2.2 explora a tecnologia de LLMs, detalhando sua definição, treinamento e os desafios de sua aplicação no contexto apícola. Por fim, a seção 2.3 discute os princípios de *design* inclusivo e acessibilidade, que são cruciais para garantir que o *chatbot* seja uma ferramenta eficaz para produtores com diferentes níveis de familiaridade tecnológica.

2.1 Apicultura

A apicultura, a prática de manejo de colônias de abelhas, principalmente da espécie *Apis mellifera*, é uma atividade milenar voltada para a produção de mel, cera, própolis, geleia real e pólen, além de fornecer serviços de polinização indispensáveis à agricultura (Araújo *et al.*, 2018). Essa atividade, com raízes históricas profundas, evoluiu de métodos tradicionais para técnicas modernas que sustentam sistemas agrícolas e promovem a subsistência de comunidades rurais (Bernardo *et al.*, 2023). Reconhecida por seu baixo impacto ambiental e por sua capacidade de integrar-se a outras práticas agrícolas, a apicultura é essencial para a sustentabilidade (Postelaro *et al.*, 2021), especialmente em contextos de recursos limitados.

No Brasil, a atividade ganha contornos únicos a partir da introdução da abelha africana (*Apis mellifera scutellata*) em 1957, que, ao hibridizar com as abelhas europeias já existentes, dá origem à abelha africanizada (Kerr, 1967). Este novo polihíbrido demonstra vantagens notáveis, como maior adaptação, robustez, produtividade e resistência a doenças (Jong, 1996), fatores que impulsionam o desenvolvimento da apicultura em diversas regiões do país. Hoje, o Brasil se destaca no cenário mundial por seu potencial de produção, favorecido pela diversidade de floradas, condições climáticas e pela rusticidade das abelhas africanizadas, que permitem a obtenção de produtos de alta qualidade e, frequentemente, orgânicos (Nogueira-Couto, 2006; Arruda *et al.*, 2004).

A Região Nordeste, em particular, demonstra um crescimento expressivo. O bioma Caatinga, predominante no semiárido, oferece um pasto apícola diversificado e livre de contaminações químicas, sendo uma região promissora para a atividade (Arruda *et al.*, 2004). O estado do Ceará, inserido nesse contexto, figura como um dos maiores produtores de mel do Nordeste (IBGE, 2011). Municípios localizados na região do Baixo Jaguaribe, como Limoeiro do Norte,

ocupam posições de destaque no *ranking* nacional de produção (Lima, 2012). Essa região é caracterizada por uma rica flora apícola e um grande número de apicultores, que, no entanto, ainda exploram predominantemente o mel, havendo grande potencial para a diversificação da produção, como a de própolis (Lima, 2012).

Apesar dos benefícios e do potencial, a apicultura brasileira, e em especial a cearense, enfrenta desafios significativos. Um dos principais adversários em escala global é o ácaro *Varroa destructor*, que chega ao Brasil na década de 1970 (Jong *et al.*, 1982). Contudo, uma vantagem competitiva notável da apicultura brasileira é que as abelhas africanizadas demonstram um elevado grau de tolerância a esta praga (Jong *et al.*, 1982; Medina-Flores *et al.*, 2014), o que, na maioria das vezes, dispensa o uso de tratamentos químicos (Jong, 1996; Castilhos *et al.*, 2021). Apesar disso, o ácaro ainda pode impactar negativamente a saúde e a produtividade das colônias (Castilhos *et al.*, 2023).

Para os apicultores familiares no sertão central do Ceará, os desafios são ampliados pela falta de acesso a informações técnicas atualizadas e por um suporte especializado escasso (Postelaro *et al.*, 2021; Reges, 2014). A qualidade e a padronização dos produtos, como o mel, ainda são um desafio, com variações decorrentes do processamento e armazenamento inadequados (Reges, 2014). Muitos produtores dependem de um conhecimento prático que nem sempre garante os melhores resultados (Bernardo *et al.*, 2023).

Esses desafios demandam soluções inovadoras. É neste ponto que o uso de tecnologias modernas, como *chatbots* baseados em LLMs, demonstra grande potencial para transformar o setor, especialmente para pequenos produtores com baixa alfabetização tecnológica (Martinho *et al.*, 2022; Alleri *et al.*, 2023). Essas ferramentas podem fornecer suporte técnico em tempo real, aliviando a dependência de assistência presencial, frequentemente escassa em áreas rurais (Rosário *et al.*, 2024), e auxiliando na padronização de boas práticas de manejo, essenciais para garantir a qualidade dos produtos apícolas da região.

2.2 Large Language Models (LLMs)

Os LLMs são sistemas de inteligência artificial baseados em redes neurais profundas, projetados para compreender, gerar e interagir em linguagem natural com alta precisão e coerência (Piper; Mejri, 2025). Sua capacidade de processar perguntas complexas de forma contextualmente relevante os torna ferramentas poderosas para aplicações conversacionais em diversas áreas, incluindo o suporte técnico.

2.2.1 Definição, Treinamento e Personalização

A evolução dos LLMs é impulsionada pela arquitetura *Transformer* (Vaswani *et al.*, 2017), que utiliza um mecanismo de atenção (*self-attention*) para ponderar a importância das palavras em um texto, capturando relações de longo alcance de forma eficiente. Isso confere aos LLMs a habilidade de manter a coerência em diálogos e entender nuances da linguagem, tornando-os ideais para interações de suporte técnico (Chatzigeorgiou *et al.*, 2025).

O funcionamento dos LLMs baseia-se tradicionalmente em duas fases: pré-treinamento e ajuste fino (*fine-tuning*). No pré-treinamento, o modelo aprende padrões linguísticos e conhecimento factual a partir de vastos conjuntos de dados textuais (Zhao *et al.*, 2023). Posteriormente, no ajuste fino, ele pode ser adaptado a um domínio específico utilizando um conjunto de dados menor e focado (OpenReview, 2023). Embora o ajuste fino seja uma técnica robusta para personalização, estratégias baseadas em instruções (*Prompt Engineering*) mostram-se eficazes para adaptar o comportamento do modelo sem a necessidade de retreino computacionalmente custoso.

2.2.2 Recuperação Aumentada e Representação Vetorial

Para superar limitações de conhecimento estático e alucinações, utiliza-se a arquitetura de Recuperação Aumentada por Geração (RAG), proposta originalmente por Lewis *et al.* (Lewis *et al.*, 2020). O RAG permite que o modelo consulte uma base de conhecimento externa dinâmica antes de gerar uma resposta, combinando memória paramétrica (do LLM) com memória não-paramétrica (documentos externos).

Esse processo depende da criação de *embeddings*, que são representações vetoriais densas onde palavras ou frases com significados semânticos semelhantes são mapeadas para pontos próximos no espaço vetorial (Mikolov *et al.*, 2013). Esses vetores são armazenados em bancos de dados vetoriais (*vector databases*), otimizados para busca de similaridade em alta escala (Johnson *et al.*, 2019). A recuperação da informação relevante é realizada frequentemente por meio da medida de distância do cosseno, garantindo que o contexto fornecido ao LLM seja semanticamente alinhado à consulta do usuário.

2.2.3 LLMs no Contexto Apícola

A aplicação de LLMs em *chatbots* de suporte técnico especializado oferece vantagens como escalabilidade, ao atender múltiplos usuários simultaneamente, e personalização, ao fornecer recomendações contextualizadas (Rosário *et al.*, 2024), assim o suporte para a apicultura pode se beneficiar também. A escolha por modelos *open-source*, como os da família *LLaMA*, é estratégica, pois proporciona maior transparência, flexibilidade e redução de custos, sendo ideal para o desenvolvimento de uma solução sustentável em ambientes com recursos limitados (Zhao *et al.*, 2023).

Contudo, a implementação de LLMs exige atenção a desafios importantes. Além da alucinação — a geração de informações incorretas, que deve ser mitigada ancorando as respostas em uma base validada (Gautam, 2025; Shi *et al.*, 2025; Kim *et al.*, 2024) — há o desafio do viés linguístico. Como a maioria dos modelos é treinada predominantemente em inglês, pode haver dificuldades na compreensão de dialetos regionais e termos técnicos da apicultura brasileira. Outros obstáculos incluem a limitação da janela de contexto e memória para manter diálogos longos e o custo computacional em produção, que, mesmo com modelos abertos, demanda recursos significativos para uma inferência ágil.

2.3 Design Inclusivo e Acessibilidade em *Chatbots* Apícolas

A concepção de soluções tecnológicas que promovem acessibilidade e inclusão é fundamental para garantir que seus benefícios alcancem um público amplo. No contexto deste trabalho, o *design* inclusivo é um fator essencial para atender às necessidades de pequenos produtores rurais que frequentemente enfrentam desafios de acesso e familiaridade com ferramentas digitais.

2.3.1 Princípios e Estratégias para Interfaces Acessíveis

O desenvolvimento de interfaces acessíveis parte de princípios como clareza e simplicidade, seguindo diretrizes como as da Associação Brasileira de Normas Técnicas (ABNT) (2022; 2025). Para o *chatbot* apícola, isso se traduz em uma linguagem natural e contextualizada, um *design* visual minimalista, um fluxo conversacional intuitivo e um *feedback* claro e imediato. A adoção de interfaces com menos texto e mais elementos visuais pode ser particularmente benéfica para usuários com baixa escolaridade (Capra *et al.*, 2021; Sociedade Brasileira de

Computação, 2024).

Além da interface, a arquitetura do sistema deve ser planejada para contextos rurais. É crucial otimizar o *chatbot* para operar em ambientes de conectividade limitada, o que pode incluir a compressão de respostas e o uso de interações assíncronas (Hughesnet, 2022; TIAI, 2025). Iniciativas como o "Marco para a inclusão digital no campo" (FPA, 2024) validam essa necessidade. A aplicação de metodologias ágeis, combinada a uma abordagem centrada no usuário, permite um desenvolvimento iterativo, com coleta contínua de *feedback* dos apicultores para garantir que suas necessidades guiem o projeto (Pressman; Maxim, 2021).

A integração desses princípios tem o potencial de democratizar o acesso à informação técnica na apicultura. Experiências no agronegócio, como o Chatbot Serasa Experian Agro (Serasa Experian, 2023), demonstram a viabilidade da inteligência artificial. Contudo, para que a tecnologia seja confiável, é imperativo mitigar seus riscos, como o problema das "alucinações" (Kim *et al.*, 2024). Isso valida a tese de que uma solução eficaz exige não apenas uma interface acessível, mas também uma curadoria rigorosa da base de dados, garantindo a precisão e a confiabilidade da assistência oferecida.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta uma revisão de trabalhos relacionados ao desenvolvimento de *chatbots* baseados em LLMs, com foco em aplicações voltadas para acessibilidade e suporte técnico em contextos agrícolas. Os trabalhos analisados destacam avanços em *chatbots* agrícolas, modelos especializados para ciências agrárias e aplicações em bioinformática, identificando contribuições relevantes e lacunas que reforçam a proposta de um *chatbot* para apicultores, adaptado a usuários com baixa alfabetização tecnológica. A seguir, discutem-se três trabalhos principais, seguidos de uma análise comparativa com o projeto proposto.

3.1 *FarmerChat*: Chatbot Agrícola com RAG

Singh *et al.* (2024) desenvolvem o *FarmerChat*, um *chatbot* baseado em LLMs voltado para fornecer suporte agrícola personalizado a pequenos agricultores em países de baixa e média renda. O sistema é projetado para superar as limitações de serviços tradicionais de extensão agrícola, oferecendo respostas contextuais e acessíveis em escala.

O *FarmerChat* utiliza *Retrieval-Augmented Generation* (RAG) com modelos como *GPT-4* e *GPT-3.5*, integrando uma base de conhecimento composta por dados estruturados e não estruturados, como manuais, tabelas de culturas e vídeos. Esses dados são processados por técnicas de *auto-summarization* e *embeddings* vetoriais, o que garante precisão nas respostas. Implantado em plataformas populares como WhatsApp e Telegram, o sistema suporta seis idiomas, incluindo Swahili e Hindi, e interações multimodais (texto, voz, vídeo), atendendo usuários com baixa alfabetização digital.

Avaliações qualitativas, com entrevistas envolvendo mais de 300 usuários, e quantitativas, com 75% de consultas respondidas com sucesso e 71% de precisão contextual, indicam alta satisfação (90%) e melhorias em práticas agrícolas, como manejo de pragas e produtividade. No entanto, o *FarmerChat* não aborda apicultura, apresenta respostas por vezes técnicas demais para usuários com baixa instrução e depende de conexão à internet, o que restringe sua eficácia em áreas rurais remotas.

Diferentemente do *FarmerChat*, este projeto utiliza *LLaMA* com respostas simplificadas, integrando dados específicos e manuais técnicos, como os do SEBRAE, para maior acessibilidade e relevância no contexto apícola.

3.2 *PLLaMa*: Modelo de Linguagem para Ciências Vegetais

Yang *et al.* (2024) desenvolvem o *PLLaMa*, um LLM de código aberto baseado no *LLaMA-2*, projetado para aplicações em ciências vegetais, incluindo apicultura. O modelo visa fornecer respostas precisas e contextuais para suporte técnico em *chatbots* agrícolas, abordando a lacuna de especialização em domínios técnicos.

O *PLLaMa* é treinado em duas etapas: pré-treinamento contínuo com 1.676.389 artigos de 750 periódicos de ciências vegetais, totalizando 2.278.433 textos, e ajuste por instruções com 1.030 *prompts*, incluindo comandos personalizados para ciências vegetais. O treinamento utiliza recursos computacionais significativos e disponibiliza códigos publicamente.

Testes demonstram 60% de acurácia em um *quiz* de ciências vegetais e 89% em tarefas específicas, superando o *GPT-3.5* (78%); as respostas são validadas por especialistas como precisas. Contudo, o modelo carece de revisão por pares, tem foco amplo que dilui a especificidade para apicultura e exige alto poder computacional, o que limita sua implementação. A avaliação é restrita a cenários específicos, sem testes extensivos em apicultura.

Ao contrário do *PLLaMa*, este projeto utiliza uma base de conhecimento mais específica, com dados de aplicativos de gestão de colmeias e manuais técnicos, e otimiza o *LLaMA* para respostas acessíveis, aumentando a relevância e a usabilidade no contexto apícola.

3.3 Chatbots para Análise de *Ribo-seq*

Ding *et al.* (2025) propõem o uso de *chatbots* baseados em LLMs para facilitar a análise de dados de perfilamento de ribossomos (*Ribo-seq*). O artigo revisa como esses *chatbots* podem mitigar desafios em bioinformática, promovendo acessibilidade e eficiência na interpretação de dados ômicos.

Os autores sugerem a integração de *chatbots* com LLMs em fluxos de trabalho para automatizar o pré-processamento de dados e interpretar resultados. A abordagem destaca interfaces intuitivas que permitem a pesquisadores com habilidades computacionais limitadas realizar análises complexas.

Embora o artigo indique potencial na análise de dados, a falta de aplicações diretas, o risco de vieses e preocupações com a privacidade limitam a implementação prática. Este projeto busca ultrapassar as limitações identificadas utilizando RAG com uma base curada e Engenharia de Prompt para especialização comportamental, sem o alto custo computacional do *fine-tuning*.

3.4 Análise Comparativa

Os trabalhos revisados avançam no uso de LLMs para suporte técnico, mas apresentam limitações que este projeto supera. O *FarmerChat* (Singh *et al.*, 2024) oferece um *chatbot* acessível, porém sem foco em apicultura. O *PLLaMa* (Yang *et al.*, 2024) especializa o modelo para ciências vegetais, mas com baixa especificidade para apicultura e alto custo computacional. A proposta de Ding *et al.* (2025) carece de aplicações práticas imediatas.

Este projeto utiliza *LLaMA* com RAG em dados apícolas e respostas simplificadas, garantindo maior acessibilidade e relevância. O Quadro 1 compara os trabalhos com o projeto proposto.

Quadro 1 – Comparação entre os trabalhos relacionados e o projeto proposto

Característica	<i>FarmerChat</i>	<i>PLLaMa</i>	<i>Ribo-seq</i>	Proposto
Domínio	Agricultura geral	Ciências vegetais	Bioinformática	Apicultura
Modelo LLM	<i>GPT-4, GPT-3.5</i>	<i>LLaMA-2</i>	<i>GPT-4</i>	<i>LLaMA</i>
Técnica Principal	RAG	<i>Fine-Tuning</i>	<i>Prompt Engineering</i>	RAG
Acessibilidade	Multimodal	Técnica	Intuitiva	Simplificada
Dados específicos	Manuais agrícolas	Artigos científicos	Dados ômicos	Manuais apícolas
Avaliação	Implantação Piloto	Quiz Técnico	Análise Visual	Usuário (apicultores)
Métricas	Taxa de Sucesso	Perplexidade	Qualidade	Análise Temática
Limitações	Conexão Internet	Custo Computac.	Teórica	Regionalização

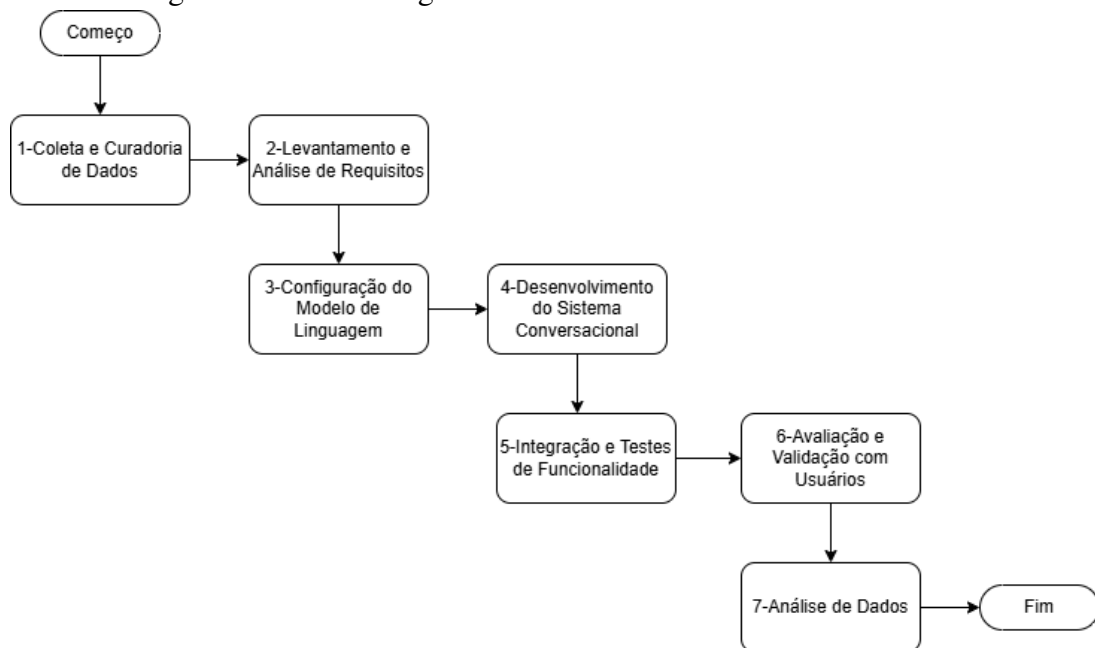
Fonte: Elaborado pelo autor.

Este projeto, portanto, distingue-se ao propor uma solução que integra a flexibilidade de um modelo *open-source* com a confiabilidade de dados apícolas curados, visando entregar uma experiência de suporte técnico que se adapta à realidade dos apicultores do sertão central do Ceará.

4 METODOLOGIA

Neste capítulo, apresentam-se os passos necessários para a realização deste trabalho. O processo tem início com a Coleta e Curadoria de Dados (seção 4.1), etapa fundamental para obter os insumos do projeto. Com base nesses dados, realiza-se o Levantamento e Análise de Requisitos (seção 4.2), definindo o escopo do sistema. Em seguida, é feita a Configuração do Modelo de Linguagem (seção 4.3), onde a inteligência do *chatbot* é preparada. Com a base definida, o Desenvolvimento do Sistema Conversacional (seção 4.4) foca na construção da ferramenta, que passa pela Integração e Testes de Funcionalidade (seção 4.5). Por fim, a solução é submetida à Avaliação e Validação com Usuários (seção 4.6) e os resultados são processados na Análise de Dados (seção 4.7).

Figura 1 – Fluxograma da Metodologia



Fonte: Elaborado pelo autor.

4.1 Coleta e Curadoria de Dados

A fase inicial do trabalho dedica-se à obtenção de informações tanto do contexto dos usuários quanto do domínio técnico da apicultura. Essa etapa é realizada através de uma abordagem mista:

- *Entrevistas Semiestruturadas*: A consulta envolve um grupo de 5 apicultores atuantes na região do Sertão Central do Ceará. A seleção dos participantes contempla desde produtores

iniciantes até veteranos no manejo. A aplicação do questionário ocorre de forma híbrida: parte das entrevistas é realizada presencialmente e parte via aplicativo de mensagens (*WhatsApp*), conforme a disponibilidade do produtor. Em todos os casos, há mediação assistida para o preenchimento do formulário, garantindo o esclarecimento de dúvidas em tempo real.

- *Curadoria da Base de Conhecimento (Dados para RAG)*: Para a construção da memória técnica do *chatbot*, são selecionados e processados 8 documentos fundamentais que cobrem o escopo técnico e a realidade prática regional:
 1. *Apicultura Nordestina: Principais Mercados, Riscos e Oportunidades*;
 2. *Criação de Abelhas (Apicultura) – 2ª Edição*;
 3. *Biologia das abelhas*;
 4. *Manejo integrado na apicultura*;
 5. *Guia de Plantas Visitadas por Abelhas na Caatinga*;
 6. *Manual de Apicultura em Modo de Produção Biológico*;
 7. *A Polinização Agrícola por Insetos no Brasil*;
 8. *Apicultura: Manual do Agente de Desenvolvimento Rural*.

4.2 Levantamento e Análise de Requisitos

A partir dos dados coletados nas entrevistas e da análise dos manuais técnicos, é possível traçar o perfil do usuário e definir as funcionalidades essenciais do sistema. O objetivo desta etapa é traduzir as dores relatadas pelos apicultores em especificações técnicas de *software*. As informações são organizadas em um documento de especificação, detalhando os requisitos funcionais (RF) e não funcionais (RNF):

- *Requisitos Funcionais (RF)*:
 - (RF1): O sistema deve ser capaz de processar e responder a perguntas sobre manejo de colmeias, pragas e doenças, feitas em linguagem comum.
 - (RF2): O sistema deve fornecer orientações sobre o calendário apícola e as práticas certas para cada época do ano.
 - (RF3): O sistema deve ser capaz de explicar conceitos sobre os produtos da colmeia (mel, própolis, cera, etc.).
- *Requisitos Não Funcionais (RNF)*:
 - (RNF1 - Usabilidade): A interface do *chatbot* deve ser limpa e fácil de usar, pensada

para apicultores com pouca experiência em tecnologia.

- (*RNF2 - Acessibilidade*): A linguagem das respostas do *chatbot* deve ser simples, direta e usar termos familiares aos produtores.
- (*RNF3 - Desempenho*): O sistema deve funcionar adequadamente mesmo com internet de baixa taxa de transferência, comum em áreas rurais.
- (*RNF4 - Compatibilidade*): A solução deve funcionar corretamente em celulares mais simples (modelos de entrada).

A priorização desses requisitos segue o método *MoSCoW* (*Must-have, Should-have, Could-have, Won't-have*), para garantir que o desenvolvimento se concentre no que é mais crítico para o sucesso do projeto.

4.3 Configuração do Modelo de Linguagem

A configuração do modelo de linguagem é a etapa central no desenvolvimento da inteligência do *chatbot*. A abordagem adotada combina as técnicas de RAG (*Retrieval-Augmented Generation*) e Engenharia de Prompt (*Prompt Engineering*) de forma complementar. Com base nos critérios de desempenho e comunidade de suporte, o modelo base selecionado é o *Llama 3 8B*, executado via infraestrutura da *Groq Cloud*. Trata-se de um LLM *open-source* que oferece um balanço ideal entre capacidade de compreensão e a viabilidade de inferência. Essa escolha aproveita a capacidade nativa do modelo de seguir instruções complexas (*instruction-following*) sem a necessidade de retreino.

Para garantir que o *chatbot* forneça respostas precisas e se comunique adequadamente com o público-alvo, implementa-se uma arquitetura composta por duas camadas lógicas. O RAG é o mecanismo responsável por conectar o LLM a uma base de conhecimento externa e confiável, buscando trechos relevantes nos manuais para garantir a factualidade das respostas e minimizar alucinações. Por sua vez, a Engenharia de Prompt, através de Instruções de Sistema (*System Prompts*), define a *persona* do modelo como um assistente técnico prestativo que utiliza linguagem simples.

O processo de implementação segue frentes paralelas: a construção do sistema RAG e o desenvolvimento iterativo dos *prompts*. Para a representação vetorial da base de conhecimento, utiliza-se o modelo especialista *BERT-PT* (*ruanchaves/bert-base-portuguese-cased-assin2-similarity*), processado localmente. Os vetores gerados são armazenados no *ChromaDB*, banco de dados vetorial que permite buscas de similaridade semântica para recuperar os trechos

de manuais mais relevantes para cada consulta.

4.4 Desenvolvimento do Sistema Conversacional

O desenvolvimento do sistema segue uma arquitetura modular, centrada em uma API *RESTful* que atua como o núcleo orquestrador e serve de ponte para a integração com o aplicativo preexistente “Revise!”. O “Revise!” é um sistema de monitoramento de colônias de abelhas focado em auxiliar apicultores a salvar as revisões de suas colmeias através de uma experiência de usuário pensada para o uso em campo, onde se utilizam luvas e capacete.

4.4.1 Delimitação de Escopo e Autoria

A contribuição autoral deste Trabalho de Conclusão de Curso concentra-se integralmente no desenvolvimento do ecossistema inteligente, compreendendo: a construção da API *RESTful* em *FastAPI* (*backend*); a implementação da arquitetura RAG e vetorização da base de dados com *ChromaDB*; e a integração e engenharia de *prompt* com o modelo *Llama 3* na nuvem. O aplicativo móvel preexistente é utilizado apenas como interface de usuário (*frontend*).

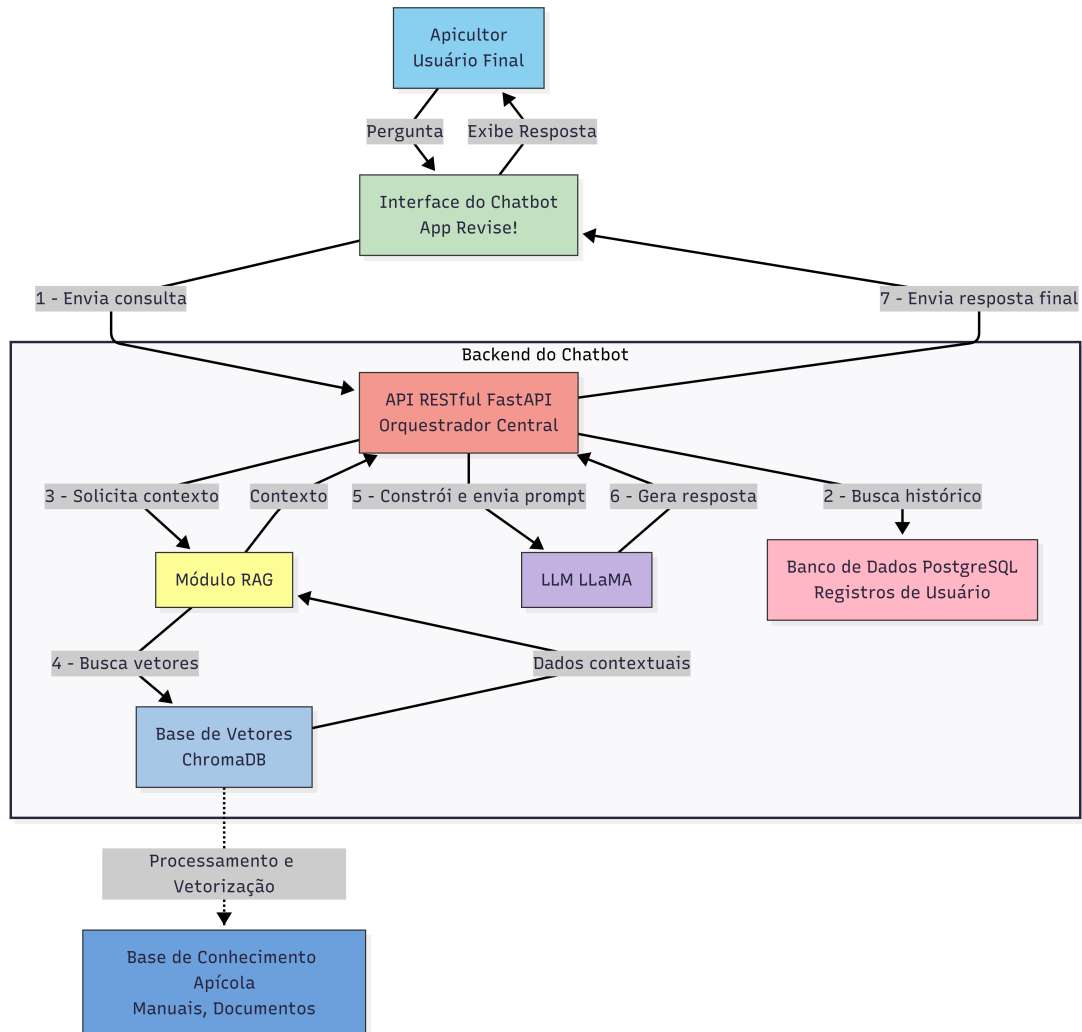
A escolha das tecnologias para o desenvolvimento do *backend* prioriza a facilidade de desenvolvimento e o rápido ciclo de implementação. O *backend* é hospedado em uma Máquina Virtual (VM) Linux institucional, que dispõe de 4 GB de memória RAM. Para garantir a persistência do serviço, utiliza-se o utilitário *GNU Screen* para gerenciar a execução da API, com acesso via protocolo *SSH*.

A solução é composta por três camadas: o *frontend*, o *backend* (desenvolvido em *Python* com *FastAPI*) e a camada de dados. Esta última utiliza o banco de dados relacional *PostgreSQL* para histórico e o banco de vetores *ChromaDB* para alimentar o módulo RAG. O fluxo de uma consulta ocorre da seguinte forma:

1. O apicultor envia sua consulta através da funcionalidade de *chat* no aplicativo;
2. O aplicativo envia uma requisição *HTTP* para a API *FastAPI*;
3. O *backend* recebe a consulta e pode acessar o *PostgreSQL* para buscar o histórico do usuário;
4. O *backend* encaminha a pergunta para o Módulo RAG;
5. O Módulo RAG busca os trechos de texto mais relevantes no *ChromaDB* utilizando o modelo *BERT-PT*;

6. O RAG retorna os dados contextuais para o *backend*;
7. O *backend* constrói o *prompt* final (contexto + pergunta);
8. O *backend* envia o *prompt* completo para o modelo *Llama 3* na *Groq Cloud*;
9. O LLM gera a resposta técnica e a retorna para o *backend*;
10. O *backend* retorna a resposta em formato *JSON* para o aplicativo, que a exibe na interface.

Figura 2 – Diagrama da Arquitetura de Software Proposta para o Trabalho



Fonte: Elaborado pelo autor.

4.5 Integração e Testes de Funcionalidade

Após o desenvolvimento, a fase de testes garante a operação integrada por meio de uma estratégia progressiva: *testes unitários* no *backend*, *testes de integração* para verificar a comunicação da arquitetura e *testes de funcionalidade (end-to-end)* baseados nos requisitos funcionais, como:

1. *Caso de Teste - Diagnóstico de Praga:*

- *Ação do Usuário:* Enviar uma consulta como “notei abelhas com asas deformadas na colmeia, o que pode ser?”.
- *Resultado Esperado:* O sistema deve retornar uma resposta clara sugerindo a possibilidade da patologia DAA e recomendando ações de prevenção conforme os manuais.

2. *Caso de Teste - Consulta de Manejo:*

- *Ação do Usuário:* Enviar uma pergunta como “qual o melhor período para a colheita de mel na minha região?”.
- *Resultado Esperado:* O *chatbot* deve fornecer uma resposta contextualizada com o calendário apícola local.

4.6 Avaliação e Validação

A estratégia de validação prioriza a robustez técnica, dividindo-se em duas etapas. A fase principal consiste na validação técnica, onde o sistema é submetido a um *benchmark* de perguntas reais abrangendo sanidade, manejo e produção, com o objetivo de mensurar a eficácia da recuperação de contexto (RAG) e a segurança do *embedding* especialista. De forma complementar, realiza-se uma prova de conceito com um apicultor especialista, visando confirmar a utilidade prática da interface e a aderência às condições reais de uso no campo.

4.7 Análise de Dados

O processamento dos resultados fundamenta-se em métricas de Engenharia de Software e Processamento de Linguagem Natural. Para a performance do modelo, aplica-se a métrica *BERTScore*, calculando a similaridade semântica (F1-Score) entre as respostas geradas e o gabarito técnico elaborado pelo autor. Paralelamente, os dados qualitativos são tratados através de uma análise temática simplificada, focada em identificar restrições de usabilidade e conectividade que impactem a viabilidade da solução.

4.8 Aspectos Éticos

A pesquisa é conduzida em conformidade com os preceitos éticos da Resolução 510/2016 do Conselho Nacional de Saúde. A participação dos apicultores é voluntária e condicionada ao aceite de um Termo de Consentimento Livre e Esclarecido (TCLE) digital. O termo

detalha os objetivos acadêmicos, a garantia de anonimato e o direito de desistência. Nenhum dado sensível que permita a identificação direta dos voluntários é divulgado nos resultados.

5 DESENVOLVIMENTO E RESULTADOS

Neste capítulo, apresentam-se os resultados obtidos no desenvolvimento do sistema, desde a análise do perfil dos usuários até a avaliação técnica e qualitativa da solução final integrada ao aplicativo “Revise!”.

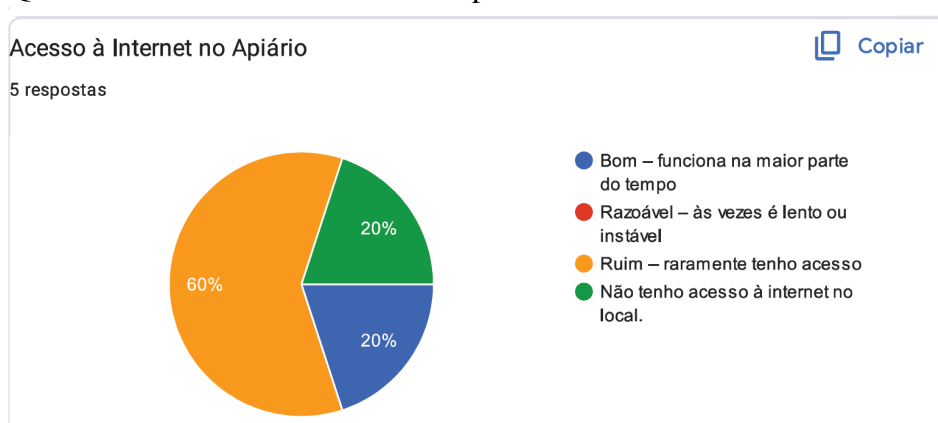
5.1 Análise do Perfil e Requisitos do Usuário

A fase inicial do desenvolvimento consiste na análise dos dados coletados junto a uma amostra de cinco apicultores ativos, visando alinhar as funcionalidades do *chatbot* às reais necessidades do campo. Esta etapa gera resultados quantitativos que fundamentam as decisões de arquitetura e *design* do sistema.

5.1.1 Conectividade e Infraestrutura

Um dado crítico para a viabilidade técnica do projeto é o mapeamento da qualidade do acesso à internet nos apiários. Conforme os resultados obtidos na pesquisa preliminar, observa-se uma infraestrutura de comunicação desafiadora para grande parte dos produtores. Conforme ilustrado na Figura 3, embora 60% dos entrevistados classifiquem seu acesso como “Bom”, uma parcela significativa de 40% dos produtores relata ter acesso apenas “Razoável”, “Ruim” ou “Inexistente” no local de manejo.

Figura 3 – Qualidade do acesso à internet dos apicultores no local de trabalho



Fonte: Elaborado pelo autor com base na pesquisa realizada.

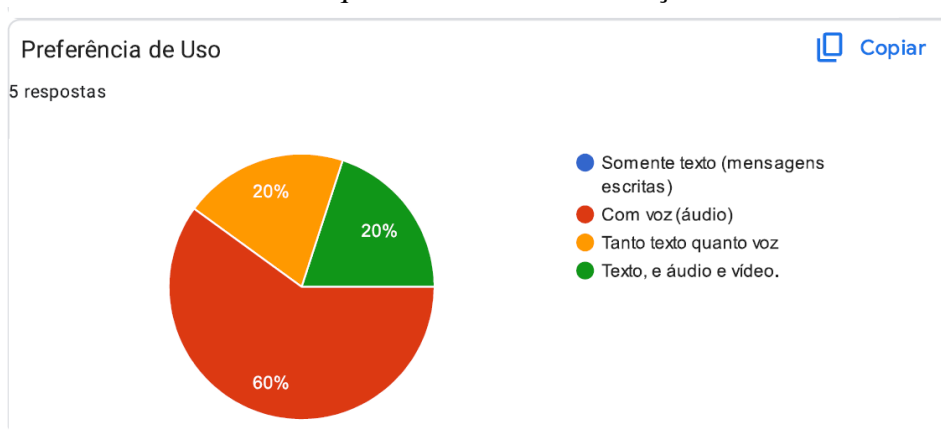
Este cenário de conectividade intermitente justifica a decisão arquitetural de centralizar todo o processamento computacional no servidor remoto. Nessa abordagem, a carga

pesada de inteligência artificial e vetorização é executada externamente, minimizando o tráfego de dados e o consumo de bateria no dispositivo móvel do usuário.

5.1.2 Preferências de Interação e Demandas

Quanto à interface humano-computador (IHC), os dados revelam uma forte inclinação dos apicultores para interfaces conversacionais por áudio, em detrimento da digitação. Embora a aceitação da ferramenta de assistente virtual seja unânime, com 100% de percepção de utilidade máxima (5/5), há divergência quanto ao modo de uso. Conforme demonstra a Figura 4, 60% dos participantes indicam preferência exclusiva pelo uso de voz (áudio), enquanto apenas 20% optam exclusivamente por texto e 20% aceitariam ambos os formatos.

Figura 4 – Preferência dos usuários quanto ao modo de interação



Fonte: Elaborado pelo autor com base na pesquisa realizada.

Diante deste cenário, e considerando o escopo temporal deste trabalho, opta-se por desenvolver a versão inicial baseada em texto — que atende plenamente a 40% da base (texto + híbrido) e é funcional para os demais. Contudo, estes dados definem a implementação de funcionalidades de *Speech-to-Text* como o requisito prioritário para a evolução futura do sistema.

5.2 Implementação do Ecossistema Inteligente

A etapa de construção consolida a transição do protótipo para uma arquitetura funcional e robusta. O objetivo é criar um sistema capaz de suportar o processamento pesado de inteligência artificial mantendo a agilidade necessária para o uso em dispositivos móveis no campo.

5.2.1 Backend e Processamento de IA

O núcleo da aplicação utiliza o *framework FastAPI*, escolhido pela facilidade de desenvolvimento e agilidade na criação de rotas. A arquitetura é projetada para sanitizar as entradas dos usuários antes de submetê-las ao modelo de linguagem, garantindo a segurança da aplicação.

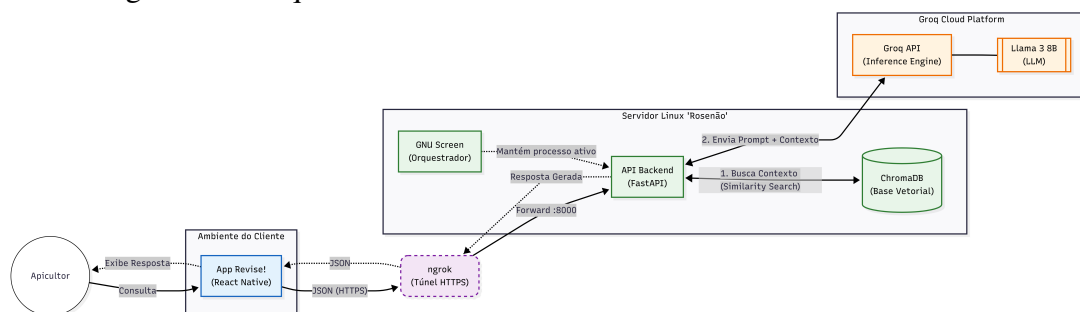
Para o motor de recuperação (RAG), o sistema é configurado para buscar os 10 trechos mais relevantes da base de conhecimento para cada pergunta. A segmentação dos manuais utiliza blocos de 1.000 caracteres com sobreposição de 200 caracteres, uma estratégia definida para preservar o contexto técnico completo das explicações. A vetorização é realizada pelo modelo *BERT-PT*, otimizado para a língua portuguesa.

A inferência de resposta é delegada à infraestrutura da *Groq Cloud*, executando o modelo *Llama 3 8B*. Essa integração permite que o sistema processe respostas complexas em milissegundos, superando as limitações de *hardware* local.

5.2.2 Conectividade e Interface Móvel

A ponta final do sistema é o aplicativo móvel “Revise!”, desenvolvido em *React Native*. O aplicativo é projetado para operar como um cliente leve, estabelecendo a comunicação com o servidor remoto por meio do protocolo *HTTPS*. Nessa arquitetura, o dispositivo móvel delega todo o processamento pesado de dados para o *backend*, o que garante o desempenho da solução mesmo em aparelhos com recursos de *hardware* limitados. A Figura 5 ilustra o fluxo de dados implementado, enquanto a Figura 6 apresenta a interface final utilizada pelos apicultores.

Figura 5 – Diagrama da Arquitetura Final do Sistema



Fonte: Elaborado pelo autor.

Figura 6 – Interface final do assistente técnico no aplicativo móvel Revise!



Fonte: Elaborado pelo autor.

5.3 Avaliação Técnica do Modelo

Para validar a premissa arquitetural de que modelos de linguagem genéricos são insuficientes para o suporte técnico especializado, define-se um conjunto de testes padronizado (*benchmark*) baseado em um *gabarito técnico (ground-truth) elaborado pelo autor*, composto por seis perguntas reais. O objetivo é demonstrar a necessidade do fluxo RAG, a superioridade da recuperação com o modelo especialista e a fidelidade semântica das respostas através da métrica *BERTScore*.

O Quadro 2 lista as perguntas submetidas aos modelos, abrangendo domínios críticos como Sanidade, Manejo e Produção.

Quadro 2 – Conjunto de Perguntas de Teste (Benchmark)

ID	Pergunta do Apicultor
Q1	Notei algumas abelhas com as asas deformadas andando na frente da colmeia. O que pode ser isso?
Q2	Qual é a melhor época para fazer a colheita do mel aqui na região?
Q3	Estou vendo umas formigas atacando o apiário. Posso passar qualquer veneno em volta das caixas?
Q4	Minhas abelhas estão ficando sem comida por causa da seca. Como faço alimentação artificial?
Q5	O enxame está muito bravo e defensivo, atacando longe da caixa. É normal?
Q6	O que é puxada de cera?

Fonte: Elaborado pelo autor.

5.3.1 Validação da Arquitetura: A Necessidade do RAG

Para comprovar a importância da integração com a base de conhecimento, compare-se o desempenho do modelo *Llama 3* em dois cenários: “Puro” (confiando apenas em seu treinamento prévio) e “Com RAG” (acessando os manuais vetorizados).

Os resultados confirmam a hipótese de que o modelo sem RAG, embora gere textos fluentes, falha em fornecer suporte técnico preciso. O Quadro 3 apresenta um comparativo direto das respostas obtidas para as questões críticas de sanidade (Q1) e manejo (Q3).

Quadro 3 – Comparativo de Respostas: Modelo Puro vs. Modelo com RAG

Critério	Llama 3 Puro (Sem RAG)	Llama 3 + RAG (Com Contexto)
<i>Diagnóstico na Q1</i>	Vago. Sugere causas genéricas como <i>má nutrição, genética</i> ou <i>doenças diversas</i> .	Preciso. Identifica a patologia específica descrita nos manuais: <i>Deformidade Alar dos Adultos (DAA)</i> .
<i>Causa Raiz na Q1</i>	Não estabelece vínculo claro com vetores de transmissão.	Relaciona corretamente o sintoma à transmissão viral pelo ácaro <i>Varroa destructor</i> .
<i>Recomendação na Q3</i>	Genérica. Sugere <i>limpeza do local</i> e <i>repelentes naturais</i> .	Específica. Recupera técnicas dos manuais locais: uso de graxa ou óleo queimado nos pés dos caletes.
<i>Fonte da Informação</i>	Conhecimento prévio do treino (Internet global).	Baseado estritamente nos manuais técnicos do SEBRAE e Embrapa.

Fonte: Elaborado pelo autor com base nos testes realizados.

A diferença torna-se evidente na análise da Pergunta Q1. Enquanto o modelo puro sugere causas vagas, o sistema com RAG, ao recuperar o contexto do manual sanitário, permite que o LLM diagnostique corretamente a patologia. Isso evidencia que, sem a arquitetura RAG proposta, a ferramenta seria incapaz de atuar como um assistente técnico confiável.

5.3.2 Seleção de Embedding: Impacto na Recuperação de Contexto

A escolha do modelo de vetorização (*embedding*) foca na capacidade de capturar o contexto vernáculo da apicultura brasileira. Comparou-se o modelo *all-MiniLM-L6-v2* (multilíngue) com o *BERT-PT* (específico para português). O teste destaca como a qualidade da recuperação de contexto influencia a assertividade do LLM na geração da resposta final:

– *Recuperação de Detalhes (Pergunta Q3)*: O modelo *MiniLM* recupera contextos genéricos,

levando o LLM a sugerir soluções comuns como *óleo de hortelã*. Já o *BERT-PT* captura a semântica do manejo rural brasileiro, fornecendo contextos que permitem ao LLM sugerir as técnicas exatas descritas nos manuais, como o uso de *graxa ou algodão nos pés dos cavaletes*.

- *Segurança e Aderência à Base (Perguntas Q4 e Q6)*: Nas questões onde a resposta não consta nos manuais, a recuperação imprecisa pelo *MiniLM* induz o LLM a utilizar o conhecimento externo do treino (*Knowledge Leakage*). O *BERT-PT*, por fornecer contextos com maior relevância semântica, permite que o LLM identifique a ausência de informações específicas e, orientado pelo *prompt*, admita o desconhecimento, evitando alucinações técnicas que poderiam induzir o produtor ao erro.

Essa precisão na recuperação fundamenta a escolha do *BERT-PT*, conforme a matriz apresentada no Quadro 4.

Quadro 4 – Matriz de Decisão para Seleção de Embedding

Critério	MiniLM (Multilíngue)	BERT-PT (Especialista)
Precisão na Busca	Baixo (Genérico)	Alto (Específico)
Confiabilidade da Resposta	Favorece alucinações técnicas pelo LLM	Favorece detecção de ausência de contexto pelo LLM
Aderência ao Manual	Baixa	Alta

Fonte: Elaborado pelo autor.

5.3.3 Avaliação Semântica (*BERTScore*)

Para a validação semântica das respostas, adota-se a métrica *BERTScore*, que utiliza *embeddings* contextuais para calcular a similaridade de significado entre o texto gerado e o gabarito técnico. Os resultados da Tabela 1 apresentam um F1-Score médio de 0,6685. Este índice demonstra correspondência semântica satisfatória, validando a capacidade do sistema em fornecer orientações tecnicamente alinhadas aos manuais oficiais.

5.4 Análise Exploratória

Para fechar o ciclo de desenvolvimento, a versão final do aplicativo “Revise!” — integrada ao *backend Llama 3* e otimizada com *BERT-PT* — é submetida à avaliação prática de um apicultor especialista com 6 anos de experiência. Esta etapa possui um caráter eminentemente exploratório, visando o levantamento de ideias, pensamentos e *insights* críticos que possam

Tabela 1 – Avaliação de similaridade semântica utilizando BERTScore (Modelo: BERT-PT)

Questão (ID)	Precision	Recall	F1-Score
1 (Asas Deformadas)	0,6361	0,6919	0,6629
2 (Colheita/Época)	0,6639	0,7280	0,6945
3 (Formigas/Veneno)	0,6474	0,7096	0,6771
4 (Alimentação)	0,6202	0,6617	0,6403
5 (Agressividade)	0,6210	0,6711	0,6451
6 (Puxada de Cera)	0,6725	0,7108	0,6911
Média Geral	<i>0,6435</i>	<i>0,6955</i>	<i>0,6685</i>

Fonte: Elaborado pelo autor.

orientar a evolução do projeto, não pretendendo ser uma validação estatística exaustiva devido à amostragem restrita.

O teste de campo revela pontos cruciais sobre a usabilidade: o especialista elogia a velocidade de resposta e confirma a exatidão técnica das orientações fornecidas, corroborando a eficácia da técnica RAG para o domínio. Contudo, o achado mais relevante ocorre ao confrontar a demanda por comandos de voz com a prática de manejo. Ao ser questionado sobre a funcionalidade de áudio, o especialista refuta a utilidade durante o manejo direto das colmeias, oferecendo um pensamento técnico sobre o comportamento das abelhas:

“Porque nós não falamos quando estamos mexendo com as colmeias. Tentamos perturbar o menos possível com sons e cheiros, para mexer a menor quantidade de tempo possível.”

Essa observação refina o entendimento dos requisitos: embora a interface de voz seja desejável para momentos de planejamento, a interface textual silenciosa permanece indispensável para a segurança e redução de estresse do enxame durante o trabalho de campo.

6 CONCLUSÃO

O presente trabalho dedica-se ao desenvolvimento e à avaliação técnica de um assistente virtual inteligente voltado para o suporte técnico na apicultura, com foco nos pequenos produtores do Sertão Central do Ceará. A motivação central da pesquisa reside na escassez de assistência técnica presencial e na necessidade de democratizar o acesso a informações de manejo, pragas e produção de mel contidas em manuais técnicos institucionais.

Afirma-se que o objetivo geral é alcançado quanto à viabilidade tecnológica. A arquitetura proposta, que combina Grandes Modelos de Linguagem (LLMs) com a técnica RAG (*Retrieval-Augmented Generation*), prova-se indispensável para o domínio em questão. Os experimentos detalhados no Capítulo 5 demonstram que, sem a vetorização dos manuais e o uso de modelos especialistas (como o *BERT-PT*), as respostas da Inteligência Artificial carecem de especificidade técnica. A implementação resulta em um artefato de *software* robusto, tecnicamente capaz de fornecer diagnósticos contextualizados, embora sua eficácia operacional no cotidiano dos produtores ainda careça de validação em larga escala.

6.1 Contribuições

As principais contribuições deste estudo para a área de Engenharia de Software aplicada à Agropecuária incluem:

- *Artefato de Software*: O desenvolvimento de uma infraestrutura completa em *FastAPI* integrada ao *ChromaDB* para buscas semânticas, servindo como um *backend* acessível para aplicações rurais.
- *Curadoria de Dados*: A estruturação de um *corpus* técnico composto por 8 manuais fundamentais da Embrapa e SEBRAE, transformando documentos estáticos em uma base de conhecimento dinâmica e consultável.
- *Avaliação de Arquitetura*: A demonstração empírica de que modelos genéricos (*Baseline*) não substituem sistemas especialistas, justificando o uso de RAG e modelos de *embedding* em português para domínios técnicos sensíveis.

6.2 Limitações e Desafios

Apesar dos resultados técnicos satisfatórios, o desenvolvimento enfrenta desafios inerentes ao contexto e limitações metodológicas importantes:

- *Ausência de Validação de Campo Abrangente*: O estudo limitou-se a uma análise exploratória com um único especialista. Portanto, não houve validação do sistema com uma base representativa de apicultores, o que impede afirmar, neste momento, que a ferramenta possui aderência ou usabilidade comprovada para a população-alvo da região.
- *Conectividade*: Conforme identificado na pesquisa, uma parcela significativa dos apicultores possui acesso instável à internet nos apiários. A dependência atual da nuvem limita o uso da ferramenta em zonas de sombra digital.

6.3 Trabalhos Futuros

A partir das lacunas identificadas, especialmente a necessidade de testes com usuários reais, sugerem-se as seguintes linhas para a continuidade deste projeto:

1. *Validação de Campo e Usabilidade*: Realizar ciclos de testes com uma base amostral estatisticamente significativa de produtores rurais. Esta é a etapa prioritária para aferir a real aceitação da tecnologia e identificar barreiras de uso em diferentes perfis sociodemográficos.
2. *Avaliação Comparativa de Arquiteturas*: Realizar um estudo exaustivo comparando os resultados de similaridade semântica (*BERTScore*) entre todas as combinações de arquitetura, incluindo testes sistemáticos com e sem RAG, além da avaliação de desempenho entre diferentes modelos de linguagem e modelos de *embedding*.
3. *Interface Híbrida Adaptativa*: Desenvolver um sistema que ofereça comandos de voz para planejamento e uma interface textual silenciosa para o manejo direto, respeitando o comportamento biológico das abelhas.
4. *Computação na Borda (Edge AI)*: Pesquisar a viabilidade de utilizar modelos de linguagem quantizados que operem diretamente no dispositivo móvel, visando o funcionamento *offline*.
5. *Multimodalidade*: Expandir a API para processar imagens, permitindo que o produtor envie fotos dos quadros da colmeia para diagnóstico visual de pragas.

REFERÊNCIAS

- ALLERI, M.; AMOROSO, S.; CATANIA, P.; VERDE, G. L.; ORLANDO, S.; RAGUSA, E.; SINACORI, M.; VALLONE, M.; VELLA, A. Recent developments on precision beekeeping: A systematic literature review. **Journal of Agriculture and Food Research**, v. 14, p. 100726, 2023. Disponível em: <https://doi.org/10.1016/j.jafr.2023.100726>. Acesso em: 20 maio 2025.
- ARAÚJO, K. S. d. S. *et al.* Beekeeping in brazil: A bibliographic review. In: RANZ, R. E. R. (Ed.). **Beekeeping**. Rijeka: IntechOpen, 2018. cap. 5. Disponível em: <https://doi.org/10.5772/intechopen.80548>. Acesso em: 11 jun. 2025.
- ARRUDA, C. M. F.; MARCHINI, L. C.; MORETTI, A. C. C. C.; OTSUK, I. P.; SODRÉ, G. S. Características físico-químicas de amostras de méis de *Apis mellifera* L., 1758 (hymenoptera, apidae) da região da chapada do araripe, município de santana do cariri, estado do ceará. In: **Boletim de Indústria Animal**. [S. l.: s. n.], 2004. v. 61, p. 141–150.
- ASSAD, A. **Desafios e perspectivas para o futuro da apicultura no Brasil**. A.B.E.L.H.A., 2024. Disponível em: <https://abelha.org.br/dia-do-mel-desafios-e-perspectivas-para-o-futuro-da-apicultura-no-brasil>. Acesso em: 20 maio 2025.
- Associação Brasileira de Normas Técnicas. **NBR 17060**: Acessibilidade em aplicativos móveis. Rio de Janeiro: ABNT, 2022.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 17225**: Acessibilidade em ambientes digitais: diretrizes para conteúdo de texto e imagens. Rio de Janeiro, 2025.
- BERNARDO, E. D.; SILVA, L. F.; SILVA, L. F.; MEDEIROS, L. C. R.; OLIVEIRA, M. J. C.; SANTOS, S. C. L. Sem abelhas, sem alimento: sensibilização acerca da importância das abelhas e da apicultura na comunidade escolar de currais novos/rn. In: SILVEIRA, J. H. P. (Ed.). **Meio Ambiente, Sustentabilidade e Tecnologia**. Belo Horizonte: Editora Poisson, 2023. v. 15, p. 73–79.
- CAPRA, E. P.; FERREIRA, S. B. L.; MARQUES, J. M. Acessibilidade de interfaces web para cuidadores com baixa escolaridade: Aspectos e reflexões. **Conexões - Ciência e Tecnologia**, v. 15, n. 1, p. 119–130, 2021. Disponível em: <https://conexoes.ifce.edu.br/index.php/conexoes/article/download/2087/1571/8102>. Acesso em: 11 jun. 2025.
- CASTILHOS, D.; BERGAMO, G. C.; KASTELIK, J. P. A survey of honey bee colony losses in brazil in 2018-2019. **Brazilian Journal of Animal and Environmental Research**, v. 4, n. 4, p. 5017–5041, 2021.
- CASTILHOS, D. *et al.* Varroa destructor infestation levels in africanized honey bee colonies in brazil from 1977 when first detected to 2020. **Apidologie**, v. 54, n. 5, 2023.
- CAVALCANTE, D. **A apicultura atende, plenamente, o tripé da sustentabilidade**. A.B.E.L.H.A., 2023. Disponível em: <https://abelha.org.br/a-apicultura-atende-plenamente-o-tripe-da-sustentabilidade>. Acesso em: 14 maio 2025.
- CAVALCANTE, S.; ARAÚJO, L.; FRANÇOSO, R.; CORREIA, L.; CARVALHO, A.; SANTOS, J.; ALVES, M.; SANTOS, L. Meliponicultura: avaliação da viabilidade econômica e benefícios

em pequena e média escala - perspectivas dos produtores. **Caderno Pedagógico**, v. 21, p. e12236, 12 2024. Disponível em: <https://ojs.studiespublicacoes.com.br/ojs/index.php/cadped/article/view/12236>. Acesso em: 11 jun. 2025.

CHATZIGEORGIOU, D.; PAPPAS, N.; GIANNAKOU, A. Llm-based chatbots in language learning: Exploring the transformative potential of ai for enhanced language learning. **ERIC**, v. 14, n. 5, p. 888, 2025. Disponível em: <https://files.eric.ed.gov/fulltext/EJ1455392.pdf>. Acesso em: 11 jun. 2025.

DING, Z. *et al.* Exploring the potential of large language model–based chatbots in challenges of ribosome profiling data analysis: a review. **Briefings in Bioinformatics**, v. 26, n. 1, 2025. Disponível em: <https://academic.oup.com/bib/article/26/1/bbae641/7922579>. Acesso em: 23 jun. 2025.

ELIJAH, O.; RAHMAN, T. A.; ORIKUMHI, I.; LEOW, C. Y.; HINDIA, M. N. Role of iot technology in agriculture: A systematic literature review. **Sensors**, v. 20, n. 8, p. 2225, 2020. Disponível em: <https://www.mdpi.com/2079-9292/9/2/319>. Acesso em: 20 maio 2025.

FPA. **Marco para a inclusão digital no campo avança no Senado**. Agência FPA, 2024. Disponível em: <https://agencia.fpagropecuaria.org.br/2024/07/03/marco-para-a-inclusao-digital-no-campo-avanca-no-senado>. Acesso em: 11 jun. 2025.

GAUTAM, S. Impact of high data quality on llm hallucinations. **International Journal of Computer Applications**, v. 187, n. 4, p. 23–28, 2025. Disponível em: <https://ijcaonline.org/archives/volume187/number4/gautam-2025-ijca-924909.pdf>. Acesso em: 11 jun. 2025.

Hughesnet. **Inclusão Digital no Campo: benefícios da internet rural via satélite**. Hughesnet, 2022. Disponível em: <https://www.hughesnet.com.br/noticias/inclusao-digital-no-campo-beneficios-da-internet-rural-via-satelite>. Acesso em: 11 jun. 2025.

IBGE. **Censo Agropecuário: Brasil, grandes regiões, unidades da federação e municípios**. Instituto Brasileiro de Geografia e Estatística, 2011. Disponível em: <http://www.ibge.gov.br>. Acesso em: 10 jan. 2012.

IBGE. **Produção da Pecuária Municipal 2023**. Instituto Brasileiro de Geografia e Estatística, 2023. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9107-producao-da-pecuaria-municipal.html>. Acesso em: 14 maio 2025.

JOHNSON, J.; DOUZE, M.; JÉGOU, H. Billion-scale similarity search with gpus. **IEEE Transactions on Big Data**, v. 7, n. 3, p. 535–547, 2019. Disponível em: <https://arxiv.org/abs/1702.08734>.

JONG, D. D. Africanized honey bees in brazil, forty years of adaptation and success. **Bee World**, v. 77, n. 2, p. 67–70, 1996.

JONG, D. D.; MORSE, R. A.; EICKWORT, G. C. Mite pests of honey bees. **Annual Review of Entomology**, v. 27, n. 1, p. 229–252, 1982.

KERR, W. E. The history of the introduction of african bees to brazil. **South African Bee Journal**, v. 39, n. 2, p. 3–5, 1967.

KIM, H. *et al.* A survey of hallucination problems based on large language models. In: **Proceedings of the 2024 International Conference on Artificial Intelligence and Computer Engineering**. [S. n.], 2024. Disponível em: <https://www.ewadirect.com/proceedings/ace/article/view/17851>. Acesso em: 11 jun. 2025.

KLOSOWSKI, A. L. M.; KUASOSKI, M.; BONETTI, M. B. P. Apicultura brasileira: Inovação e propriedade industrial. **Embrapa**, XXIX, n. 1, p. 41–58, 2020. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/214016/1/Apicultura-brasileira.pdf>. Acesso em: 11 jun. 2025.

LEWIS, P.; PEREZ, E.; PIKTUS, A.; PETRONI, F.; KARPUKHIN, V.; GOYAL, N.; KÜTTLER, H.; LEWIS, M.; YIH, W.-t.; ROCKTÄSCHEL, T.; RIEDEL, S.; KIELA, D. Retrieval-augmented generation for knowledge-intensive nlp tasks. In: **Advances in Neural Information Processing Systems**. [S. n.], 2020. v. 33, p. 9459–9474. Disponível em: <https://arxiv.org/abs/2005.11401>.

LIMA, A. O. N. **Produção de própolis por abelha melífera africanizada (*Apis mellifera* L.) na Caatinga do Baixo Jaguaribe Cearense**. Tese (Tese de Doutorado) – Universidade Federal do Ceará, Fortaleza, CE, 2012.

MARTINHO, C.; FERRADEIRA, C.; CATITA, J.; FAUSTINO-ROCHA, A. Apicultura: revisão de literatura. **Revista Lusófona de Ciência e Medicina Veterinária**, Lisboa, v. 12, p. 1–17, 2022. Disponível em: <https://revistas.ulusofona.pt/index.php/rlcmv/article/view/8343>. Acesso em: 11 jun. 2025.

MEDINA-FLORES, C. A.; GUZMÁN-NOVOA, E.; HAMIDUZZAMAN, M.; ARÉCHIGA-FLORES, C. F.; LÓPEZ-CARLOS, M. A. Africanized honey bees (*Apis mellifera*) have low infestation levels of the mite *Varroa destructor* in different ecological regions in Mexico. **Genetics and Molecular Research**, v. 13, n. 3, p. 7282–7293, 2014.

MIKOLOV, T.; CHEN, K.; CORRADO, G.; DEAN, J. Efficient estimation of word representations in vector space. **arXiv preprint arXiv:1301.3781**, 2013. Disponível em: <https://arxiv.org/abs/1301.3781>.

NOGUEIRA-COUTO, R. H. **Apicultura: Manejo e produtos**. 3. ed. Jaboticabal: FUNEP, 2006.

OpenReview. **Learning Dynamics of LLM Finetuning**. 2023. Disponível em: <https://openreview.net/forum?id=tPNHOoZF19>. Acesso em: 11 jun. 2025.

PIPER, W.; MEJRI, K. How the choice of llm and prompt engineering affects chatbot effectiveness. **Electronics**, v. 14, n. 5, p. 888, 2025. Disponível em: <https://www.mdpi.com/2079-9292/14/5/888>. Acesso em: 11 jun. 2025.

POSTELARO, E. R.; AQUINO, M. D. H.; JUNIOR, E. F. Apicultura familiar: sua importância no cenário econômico, social e ecológico. **Interface Tecnológica**, Taquaritinga, v. 18, n. 1, p. 298–307, 2021. Disponível em: <https://revista.fatectq.edu.br/interfacetecnologica/article/download/1124/628/5072>. Acesso em: 11 jun. 2025.

PRESSMAN, R. S.; MAXIM, B. R. **Engenharia de Software: Uma abordagem profissional**. 9. ed. Porto Alegre: AMGH Editora, 2021.

REGES, S. C. N. **Caracterização dos méis ofertados pela apicultura e meliponicultura no Jaguaribe cearense**. Dissertação (Dissertação de Mestrado) – Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Limoeiro do Norte, CE, 2014.

ROSÁRIO, P. C. M.; MEDEIROS, J. F.; LOPES, G. L.; PAULINO, P. D. Importância socioeconômica da apicultura para as mulheres do p.a tiradentes, baraúna. **Cadernos de Agroecologia**, Rio de Janeiro, v. 19, n. 1, 2024. Disponível em: <https://cadernos.aba-agroecologia.org.br/cadernos/article/view/8632>. Acesso em: 10 jun. 2025.

Serasa Experian. **Chatbot Serasa Experian Agro**: distribuidores e produtores rurais ganham agilidade no campo com análise de crédito entregue em até 90 segundos por i.a. Serasa Experian, 2023. Disponível em: <https://www.serasaexperian.com.br/sala-de-imprensa/agronegocios/chatbot-serasa-experian-agro-distribuidores-e-produtores-rurais-ganham-agilidade-no-campo-com-analise-c>. Acesso em: 11 jun. 2025.

SHI, H. *et al.* **LLM as a Judge**: Evaluating llm outputs and the challenge of hallucinations. Factored AI, 2025. Disponível em: <https://www.factored.ai/knowledge-hub/llm-hallucination-evaluation>. Acesso em: 11 jun. 2025.

SINGH, A. *et al.* **Farmer.Chat**: Scaling ai-powered agricultural services for smallholder farmers. 2024. Disponível em: <https://arxiv.org/abs/2409.08916>. Acesso em: 23 jun. 2025.

Sociedade Brasileira de Computação. Grandes desafios para diversidade, equidade e inclusão (dei) no desenvolvimento de software. In: **Anais do Workshop sobre Aspectos Sociais, Humanos e Econômicos de Software (WASHES)**. Porto Alegre: SBC, 2024. Disponível em: <https://sol.sbc.org.br/index.php/washes/article/view/29456>. Acesso em: 02 fev. 2026.

TIAI. **Inclusão Digital em Comunidades Rurais**: Transformando vidas com tecnologia. TIAI, 2025. Disponível em: https://tiai.com.br/blog/posts/inclusao_digital_em_comunidades_rurais_transformando_vidas_com_tecnologia.html. Acesso em: 11 jun. 2025.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. Attention is all you need. In: **Advances in Neural Information Processing Systems**. [S. n.], 2017. v. 30. Disponível em: <https://arxiv.org/abs/1706.03762>. Acesso em: 11 jun. 2025.

YANG, X. *et al.* **PLLaMa**: An open-source large language model for plant science. 2024. Disponível em: <https://arxiv.org/abs/2401.01600>. Acesso em: 23 jun. 2025.

ZHAO, W. X. *et al.* **A Survey of Large Language Models**. 2023. Disponível em: <https://arxiv.org/abs/2303.18223>. Acesso em: 11 jun. 2025.

7 QUESTIONÁRIO APLICADO AOS APICULTORES

Este apêndice apresenta o formulário utilizado para a coleta de dados durante a etapa de levantamento de requisitos deste trabalho. O objetivo desta pesquisa consistiu em identificar o perfil tecnológico, os principais desafios produtivos e as expectativas dos apicultores do Sertão Central do Ceará quanto ao uso de ferramentas de assistência virtual.

1. *Sobre sua Rotina e Desafios:* No seu dia a dia com as colmeias, quais são os dois maiores desafios que você enfrenta? (Exemplos: controle de pragas, alimentação, enxameação, problemas com a rainha, clima, floração, etc.)
2. *Suas Principais Dúvidas:* Que dúvidas sobre apicultura você mais tem no dia a dia e gostaria de tirar de forma rápida e confiável pelo celular? (Exemplos: doenças, troca de rainha, tipos de alimento, boas práticas, legislação, etc.)
3. *Fontes de Informação Atuais:* Quando você tem uma dúvida sobre apicultura hoje, onde você costuma procurar ajuda? (Marque todas as opções que se aplicam)
 - Falo com outros apicultores mais experientes;
 - Entro em contato com um técnico ou agrônomo;
 - Pesquiso em grupos de *WhatsApp* ou *Facebook*;
 - Pesquiso no *Google* ou *YouTube*;
 - Consulto manuais ou livros (como os do SEBRAE/SENAR);
 - Não costumo pesquisar, uso minha própria experiência;
 - Outro.
4. *Acesso à Internet no Apiário:* Como você classificaria o sinal de internet no local onde ficam seus apiários?
 - Bom – funciona na maior parte do tempo;
 - Razoável – às vezes é lento ou instável;
 - Ruim – raramente tenho acesso;
 - Não tenho acesso à internet no local.
5. *Utilidade de um Assistente Virtual:* Numa escala de 1 a 5, o quanto você acha que um assistente virtual no celular para tirar dúvidas sobre apicultura ajudaria no seu trabalho? (Sendo 1 = pouco útil e 5 = muito útil).
6. *Preferência de Uso:* Como você gostaria que o assistente funcionasse?
 - Somente texto (mensagens escritas);
 - Com voz (áudio);

- Tanto texto quanto voz;
- Outro.