



INSTITUTO FEDERAL

Sertão Pernambucano

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO SERTÃO
PERNAMBUCANO
COORDENAÇÃO DO CURSO DE SISTEMAS PARA INTERNET
SISTEMAS PARA INTERNET**

MATHEUS RICARDO CARVALHO SILVA

O USO DE CHATBOTS COM IA GENERATIVA NO APOIO À AGRICULTURA

SALGUEIRO

2025

MATHEUS RICARDO CARVALHO SILVA

O USO DE CHATBOTS COM IA GENERATIVA NO APOIO À AGRICULTURA

Trabalho de Conclusão de Curso apresentado a Coordenação do curso de Sistemas Para Internet do Instituto Federal de Educação, Ciência e Tecnologia do Sertão Pernambucano, campus Salgueiro, como requisito parcial à obtenção do título de tecnólogo em Sistemas para internet.

Orientador(a): Prof. Marcelo Anderson Batista Dos Santos

SALGUEIRO

2025

Dados Internacionais de Catalogação na Publicação (CIP)

S586 Silva, Matheus Ricardo Carvalho Silva.

O uso de chatbots com IA generativa no apoio à agricultura / Matheus Ricardo Carvalho Silva Silva. - Salgueiro, 2025.
23 f. : il.

Trabalho de Conclusão de Curso (Sistemas para Internet) -Instituto Federal de Educação, Ciência e Tecnologia do Sertão Pernambucano, Campus Salgueiro, 2025.
Orientação: Prof. Dr. Marcelo Anderson Batista Dos Santos.

1. Inteligência artificial. 2. Agricultura Familiar. 3. Chatbot. 4. Agricultura 4.0. I. Título.

CDD 006.3

O uso de chatbots com IA generativa no apoio à agricultura

Matheus R. C. Silva¹, Marcelo Anderson Batista Dos Santos²

Instituto Federal de Educação Ciência e Tecnologia do Sertão Pernambucano
(IFSertaoPE)
BR 232, Km 508 – 56.000-000 – Salgueiro – PE – Brasil

matheus.ricardo@aluno.ifsertao-pe.edu.br, marcelo.santos@ifsertao-pe.edu.br

Abstract. *Family farming is fundamental to Brazil's economy and food security, but faces challenges due to the difficulty of accessing information and technical support. This paper proposes a chatbot based on Artificial Intelligence, using Large Language Models (LLMs) and Retrieval-augmented generation (RAG), to help farmers via WhatsApp. The solution provides guidance on public policies, product pricing and good agronomic practices. Validated with farmers, the chatbot proved to be efficient in providing essential information, promoting greater autonomy and optimization in agricultural management.*

Keywords: Artificial Intelligence. Family Farming. Chatbot. Agriculture 4.0

Resumo. *A agricultura familiar é fundamental para a economia e a segurança alimentar do Brasil, mas enfrenta desafios devido à dificuldade de acesso a informações e suporte técnico. Este trabalho propõe um chatbot baseado em Inteligência Artificial, utilizando Modelos de Linguagem de Grande Escala (LLMs) e Recuperação Aumentada por Geração (RAG), para auxiliar agricultores via WhatsApp. A solução fornece orientações sobre políticas públicas, precificação de produtos e boas práticas agrônômicas. Validado com agricultores, o chatbot demonstrou ser eficiente no fornecimento de informações essenciais, promovendo maior autonomia e otimização na gestão agrícola.*

1. Introdução

A agricultura desempenha um papel fundamental na sociedade, sendo responsável pela produção de alimentos e pelo fortalecimento da economia global. No Brasil, esse setor tem um impacto expressivo na economia nacional, consolidando-se como um dos principais motores do desenvolvimento. Em 2023, o país figurou como o terceiro maior exportador mundial de produtos agropecuários, atingindo aproximadamente USD 150,1 bilhões em exportações, ficando atrás apenas da União Europeia e dos Estados Unidos (TradeMap, ITC, 2023). Os produtos agrícolas não apenas sustentam a economia nacional por meio das grandes exportações, mas também desempenham um papel essencial no abastecimento interno, com os pequenos produtores sendo responsáveis por grande parte dos alimentos consumidos no país. Dada a relevância da agricultura para a economia e a segurança alimentar, torna-se essencial investir continuamente no aprimoramento da produção, garantindo maior eficiência, qualidade e sustentabilidade. Nesse contexto,

surge a Agricultura 4.0, caracterizada pela integração de tecnologias digitais, conectividade e automação em todas as etapas da cadeia produtiva, desde o planejamento até a comercialização. De acordo com Masshura (2023), a Agricultura 4.0 pode ser definida como um modelo de produção baseado em dados, inteligência artificial e conectividade, visando garantir a segurança alimentar, a rastreabilidade dos produtos e a sustentabilidade ambiental.

Apesar dos avanços tecnológicos, os agricultores familiares ainda enfrentam desafios significativos na gestão eficiente de suas culturas, muitas vezes devido à falta de conhecimento técnico e dificuldades no acesso a informações essenciais, como melhores práticas agronômicas e políticas públicas voltadas ao setor. A ausência de orientação adequada impacta diretamente a produtividade, a qualidade dos produtos e a rentabilidade dessas propriedades, limitando seu potencial de crescimento e sustentabilidade no mercado.

Para mitigar esses desafios, o presente trabalho propõe o desenvolvimento de uma solução tecnológica baseada em computação em nuvem, modelos de linguagem de grande escala (LLMs) com recuperação aumentada por geração (RAG) e interfaces intuitivas de comunicação via mensagens de texto e voz. A ferramenta utiliza Processamento de Linguagem Natural (PLN) para fornecer respostas precisas e contextualizadas, permitindo que os agricultores acessem informações de maneira simples e eficiente, sem a necessidade de conhecimento técnico avançado. Como resultado, obteve-se um software robusto e acessível, capaz de interagir com os agricultores em linguagem natural, oferecendo suporte em diferentes áreas, como manejo de culturas, acesso a políticas públicas e precificação de produtos agrícolas.

2. Referencial Teórico

Diante do contexto já apresentado de convergência entre inovação tecnológica e seus impactos na produção rural este referencial teórico aborda os conceitos fundamentais relacionados à Agricultura 4.0, às políticas públicas voltadas para o setor agropecuário e aos fundamentos da Inteligência Artificial (IA), com destaque na IA Generativa e suas aplicações juntamente com a apresentação dos trabalhos relacionados que demonstram como soluções baseadas em chatbots e modelos de linguagem podem contribuir para o aprimoramento do setor agrícola, destacando as diferenças e inovações do presente estudo em relação a pesquisas já existentes.

2.1 Agricultura 4.0 e revolução do Agro

Na era dos dados e informação é natural pensar que as tecnologias que vem sendo desenvolvidas exponencialmente no mundo eletrônico sejam aplicáveis não só na indústria e nos centros urbanos como também no meio rural. Existe uma quantidade massiva de fatores, processos e informações no ambiente e produção agrícola. A integração de tecnologias digitais avançadas nesse setor em busca de promover maior eficiência, produtividade, sustentabilidade é o que conhecemos como agricultura 4.0 a revolução tecnológica de ponta em prol da produção agrícola (MASSRUHÁ E LEITE, 2017). São diversas áreas tecnológicas que já estão sendo utilizadas de forma conjunta gerando soluções inovadoras. Áreas de conhecimento como *big data* que envolve geração

e processamento massivo de dados (CONEGLIAN; SEGUNDO; SANTANA, 2017), internet das coisas que permite que máquinas e dispositivos diversos se conectem e comuniquem dados através da internet (MOUHA et al, 2021), robótica que estuda a capacidade de sistemas autônomos sentirem e agirem sobre o mundo físico cumprindo objetivos determinados (MATARIĆ, 2014), IA cujo campo de estudo trabalha no desenvolvimento de sistemas capazes de realizar tarefas que, normalmente, exigiriam inteligência humana (TEIXEIRA, 2019) etc. As integrações entre as tecnologias a fim de produzir soluções inovadoras são um largo campo aberto para estudo e implementação real.

2.2 Políticas Públicas voltadas para o Agro

A agricultura desempenha um papel fundamental no desenvolvimento socioeconômico do Brasil, sendo responsável não apenas pela segurança alimentar da população, mas também pela geração de empregos e pelo fortalecimento da economia nacional. Diante desse cenário, o governo federal tem investido na implementação de diversas políticas públicas para fomentar o setor agropecuário, especialmente no apoio aos pequenos produtores e agricultores familiares. O Ministério do Desenvolvimento Agrário e Agricultura Familiar (MDA) lidera a formulação e execução de políticas voltadas ao fortalecimento da agricultura familiar, promovendo ações que abrangem desde o financiamento da produção até a comercialização e assistência técnica. Atualmente, são 27 políticas e programas que contemplam diferentes aspectos da atividade rural, incluindo incentivos financeiros, linhas de crédito, apoio à agroindústria, acesso a mercados e segurança alimentar (Brasil, 2024)

2.3 Fundamentos de IA, PLN e IA Generativa

Inteligência é um conceito amplo e multidisciplinar uma vez que diferentes tipos de tarefas requerem diferentes abordagens. Diferente da programação tradicional, a Inteligência Artificial, de modo geral, representa a capacidade de um computador de realizar tarefas sem conhecimento prévio do problema a ser resolvido, entregando soluções de forma consistente, lógica e correta. Para isso, utiliza habilidades como reconhecimento de padrões, tomada de decisões, classificação, análise de sentimentos e aprendizado a partir de dados. Segundo Russel e Norvig (2012) em tradução livre “A IA atualmente abrange uma enorme variedade de subcampos, que vão do geral (aprendizagem e percepção) ao específico, como jogar xadrez.”

2.3.1 IA Generativa e PLN

A Inteligência Artificial Generativa (GenAI), especialmente os LLMs, tem transformado diversos setores ao possibilitar a criação de novos conteúdos, como textos, imagens e sons, com base em padrões aprendidos a partir de grandes volumes de dados. Diferente dos métodos tradicionais, que dependem de regras predefinidas, LLMs como o GPT-4 (OpenAi, 2023) apresentam uma abordagem mais adaptável e dinâmica, permitindo a geração de textos coerentes e contextualmente relevantes. Essas capacidades tornam a GenAI uma tecnologia essencial para aplicações como chatbots e sistemas de

recomendação, ampliando sua utilidade em diferentes domínios. (JOSHI, 2025). A conversão de áudio para texto, também conhecida como transcrição automática, utiliza técnicas de Processamento de Linguagem Natural (PLN) e reconhecimento de fala para transformar discursos falados em texto escrito. O PLN é um campo de pesquisa que busca desenvolver métodos e sistemas para o tratamento computacional da linguagem humana, abrangendo tanto a compreensão quanto a geração de textos. Segundo Caseli e Nunes (2024), o PLN pode ser dividido em duas grandes subáreas: a Interpretação de Linguagem Natural (NLU – Natural Language Understanding), que envolve a análise e compreensão de textos por máquinas, e a Geração de Linguagem Natural (NLG – Natural Language Generation), que trata da criação automática de textos compreensíveis e contextualmente adequados.

Essa tecnologia é fundamental para desenvolver interfaces de voz que permitem a interação dos agricultores com sistemas digitais de forma mais intuitiva e acessível. Assim como existe a geração de texto, há também a geração de voz, que consiste na transformação de texto escrito em fala artificialmente gerada. Essa tecnologia permite que sistemas computacionais "leiam" informações em voz alta, facilitando o acesso a conteúdo por meio auditivo.

2.4 LLM, história, desafios e ferramentas

Os LLMs ou para o português modelos de linguagem de grande escala referem-se a modelos que utilizam aprendizado de máquina com uma quantidade robusta de dados a fim de conseguir reconhecer e produzir a linguagem humana ou compreender e interpretar dados complexos, devido à possibilidade de seu treinamento em larga escala que permite que os modelos LLM aproximem a performance e desempenho humano em diversas tarefas. Esses modelos se apoiam na arquitetura de *transformers* com algoritmos de *attention* (Vaswani et al., 2023). Os transformadores utilizam *self attention* conseguindo identificar palavras relacionadas entre si em uma sentença possuindo uma capacidade maior para processar dados em paralelo permitindo assim que estes sejam mais eficientes no seu treinamento tendo maior reconhecimento de dependência entre palavras e padrões podendo analisar também problemas não sequenciais. Dessa forma esses modelos deram um salto evolucionar no desenvolvimento de redes neurais, tornando possível que modelos que usem esses algoritmos consigam compreender de forma superior contextos maiores e complexos.

Em linhas gerais a arquitetura de transformadores possibilitou um novo limiar para o aprendizado profundo de máquinas, viabilizando por exemplo os modelos LLM e resolvendo problemas complexos que com algoritmos de redes neurais mais tradicionais a exemplo da *Recurrent Neural Network* (Rede Neural Recorrente) não seria possível resolver. Traduções precisas que necessitam de um forte entendimento de contexto, análises textuais profundas e também geração de textos coerentes podendo ter diversos estilos e domínios são essas algumas das capacidades que os LLMs adquiriram com o uso da arquitetura de *transformers*. Por entenderem relações semânticas entre palavras distantes dentro de um texto, esses modelos tornam-se extremamente eficientes para tarefas como resumo de textos, resposta a perguntas e podendo ser usado também para programação assistida.

Outro importante contribuidor no avanço dos LLMs é a escalabilidade do treinamento, que se beneficia de hardware especializado uma vez que o paralelismo é um ponto forte dos transformadores sendo então, GPUs e TPUs, peças chaves para processar grandes volumes de dados. Esse aumento exponencial na capacidade computacional viabilizou modelos cada vez maiores e mais sofisticados, como o GPT-4 (OpenAI, 2023) e LLaMA 3, que se destacam pela precisão e versatilidade para atender diferentes aplicações. No entanto, apesar de seu grande potencial, os LLMs apresentam desafios, como viés nos dados de treinamento, alto custo computacional e necessidade de alinhamento para evitar respostas incorretas ou prejudiciais.

2.4.1 LLM e RAG

Representando uma das inovações mais relevantes na área de inteligência artificial, os LLMs são muito úteis em particular no que diz respeito ao processamento de linguagem natural (NLP). Esses modelos, como o GPT-3 e GPT-4 (OpenAI, 2023), são projetados para entender e gerar texto de forma similar à linguagem humana, utilizando arquiteturas complexas de aprendizado profundo, como os transformadores (Hadi, 2023). Na linha do tempo dos LLMs observamos o desenvolvimento inicial de modelos de linguagem, que evoluíram de abordagens baseadas em regras e estatísticas para técnicas mais sofisticadas que incorporam grandes quantidades de dados e poder computacional (Hadi, 2023).

Modelos LLM pela sua enorme base de dados utilizados para treinamento exige também um poder computacional inviável para indivíduos ou pequenas corporações. Dessa forma mesmo com um alto poder de entendimento da linguagem humana e resolução de tarefas, em casos que se necessite informações específicas de domínio, atualizadas ou mesmo melhorar a precisão de respostas para aplicações únicas faz-se necessário um meio para que o modelo pré treinado possa se adaptar a essas situações.

O processo de RAG integra informações atualizadas no processo de funcionamento do modelo, sem a necessidade de se submeter a um novo processo iterativo de treino (Marques, Ruben. 2024). Resolvendo assim os problemas relacionados a qualidade, confiabilidade, precisão das respostas do modelo.

3. Trabalhos Relacionados

Nesta seção, discutiremos três trabalhos relevantes que tratam do desenvolvimento de *chatbots* e suas aplicações, destacando as inovações e diferenças em relação ao trabalho proposto. A começar pelo trabalho “AI-Powered Decision Support Systems for Sustainable Agriculture Using AI-Chatbot Solution” Asolo et al. (2024) propõem um sistema de suporte à decisão para a agricultura sustentável baseado em um *chatbot* de IA utilizando LLMs como Llama2 (META AI, 2023) e Falcon (TII, 2023) para fornecer recomendações em tempo real a agricultores. O sistema coleta e processa dados agrícolas por meio de sensores, imagens de satélite e previsões meteorológicas, permitindo otimização no manejo de culturas e recursos naturais. Os resultados indicaram que a abordagem foi eficaz na entrega de respostas rápidas e precisas, destacando o potencial da IA para melhorar a tomada de decisões no setor agrícola. Diferente dessa abordagem, o presente trabalho não traz suporte para tomadas de decisões precisas e pautadas sobre indicadores do interesse para a plantação entretanto o protótipo aqui desenvolvido dispõe

de orientações gerais acesso a informações de interesse sobre políticas públicas, precificação de produtos e orientação agrônômica via WhatsApp. Enquanto Asolo et al. (2024) priorizam a otimização da produção agrícola por meio de dados ambientais e algoritmos preditivos, nossa solução visa reduzir barreiras de acesso à informação para pequenos agricultores, permitindo consultas intuitivas em linguagem natural sobre oportunidades governamentais e precificação de mercado.

O estudo de Zhang et al. (2023) intitulado “Automatic Rice Disease Detection and Assistance Framework Using Deep Learning and a Chatbot” apresenta uma aplicação móvel chamada E-Crop Doctor, que detecta doenças em folhas de arroz e recomenda pesticidas apropriados para os agricultores. A detecção das doenças é realizada por meio de um modelo de aprendizado profundo baseado nos algoritmos YOLOv3 Tiny e YOLOv4 Tiny, treinados para reconhecer três doenças principais: *brown spot*, *leaf blast* e *hispa*. Além disso, o sistema inclui um chatbot chamado "docCrop", que oferece suporte 24/7 aos agricultores, respondendo dúvidas sobre controle de pragas e recomendando tratamentos com base na infecção detectada. O sistema utiliza redes neurais convolucionais (CNNs) para identificar as doenças a partir de imagens capturadas por smartphones. O modelo foi treinado em um conjunto de 762 imagens, dividido entre treinamento, validação e teste. Para viabilizar o uso em dispositivos móveis, os pesquisadores converteram o modelo para *TensorFlow Lite*, garantindo eficiência e funcionamento offline. O chatbot foi desenvolvido com a API Kommunicate, permitindo uma interface interativa para os agricultores. a ferramenta mostrou-se eficiente na identificação das doenças, reduzindo a necessidade de especialistas no campo e oferecendo respostas rápidas e confiáveis via chatbot. O sistema demonstrou potencial para melhorar a produtividade agrícola e minimizar perdas causadas por pragas e doenças. Todavia Enquanto o sistema de Zhang et al. é especificamente voltado para a detecção de doenças em arroz e se concentra em um aspecto muito particular da agricultura. O nosso projeto abrange uma gama mais ampla de tópicos, incluindo manejo de culturas e acesso a informações de mercado. Além disso, nossa solução é baseada em computação em nuvem, permitindo acessibilidade e escalabilidade para um maior número de usuários.

O artigo de Mostaco et al. (2018) “AgronomoBot: A Smart Answering Chatbot Applied to Agricultural Sensor Networks” descreve o AgronomoBot, um chatbot inteligente para auxiliar na aquisição de dados agrícolas por meio de uma Rede de Sensores Sem Fio (WSN). O objetivo principal é proporcionar interação remota com o ambiente agrícola por meio de uma interface baseada em linguagem natural, permitindo que agricultores e especialistas tenham acesso rápido e intuitivo a informações sobre as condições do solo, clima e outros fatores relevantes para a produção agrícola. Para alcançar esse objetivo, os autores desenvolveram o AgronomoBot, um *chatbot* integrado à API do Telegram, que utiliza o serviço de cognição IBM Watson para processar e interpretar mensagens de usuários. O *chatbot* acessa dados coletados por sensores instalados em uma vinícola, permitindo consultas sobre variáveis como temperatura do solo e do ar, umidade relativa do ar, umidade do solo, precipitação e velocidade do vento. A arquitetura do sistema combina três módulos principais: (i) interface de comunicação via Telegram, (ii) serviço IBM Watson para interpretação da linguagem natural e (iii) API REST conectada à rede de sensores. Os resultados obtidos indicam que o AgronomoBot foi capaz de interagir de maneira eficaz com os usuários, interpretando suas intenções e fornecendo respostas precisas sobre as variáveis ambientais monitoradas. Além disso, o AgronomoBot mostrou

potencial para automatizar processos agrícolas, melhorando a acessibilidade dos dados e a tomada de decisão no campo. Entre os benefícios observados, destacam-se a capacidade de operar continuamente, atender múltiplos usuários simultaneamente e disponibilizar relatórios em gráficos ou formato de documento. Este trabalho não é integrado a sensores e dispositivos agrícolas que estão em campo, ele tem uso e propósito geral orientando o agricultor em outros processos oferecendo suporte abrangente e acessível a agricultores familiares, visando melhorar a produtividade e a sustentabilidade com uma abordagem que necessita de menos recursos para que se comece a ter proveitos uma vez que não é uma ferramenta singular para ser integrada a outras.

4. Metodologia

Este trabalho possui uma natureza exploratória, com foco na prototipagem e na implementação de um modelo funcional para a solução proposta. A abordagem adotada baseia-se em etapas estruturadas, visando a criação de um protótipo que atenda às necessidades do pequeno agricultor. Para conceber o ConectaAgro (nome dado à solução desenvolvida) foi realizada a definição das funcionalidades essenciais para o protótipo, considerando o objetivo principal de ampliar a disponibilidade e acessibilidade de informações para o pequeno agricultor. Após a análise do contexto e das necessidades desse público, foram identificadas três áreas prioritárias para o desenvolvimento do *chatbot*. O acesso a políticas públicas, orientação agrônômica e precificação de produtos. Para cada área de conhecimento foi necessário realizar também uma extensa busca por conteúdos base para conhecimento do modelo de modo a enriquecer as respostas tornando-as também mais confiáveis e precisas.

4.1 Desenvolvimento da solução

O *backend* (termo que se refere ao módulo do sistema responsável por recepção, tratamento, processamento, envio de dados. É essencial para o funcionamento de sistemas complexos) foi construído com a linguagem de programação TypeScript utilizando o Node.js, responsável por gerenciar as interações entre os agricultores e o sistema, integrando funcionalidades como o envio e recebimento de mensagens pelo WhatsApp. A comunicação com o WhatsApp foi viabilizada por meio da biblioteca “@whiskeysockets/baileys” (versão 6.7.2), que oferece uma alternativa para integração com o WhatsApp Web.

Outras bibliotecas utilizadas no *backend* incluem “dotenv” (16.4.5), empregada para carregar variáveis de ambiente com segurança e configurar o sistema de maneira prática; “@hapi/boom” (^10.0.1), que padroniza e trata erros, permitindo o envio de mensagens claras em caso de falhas; “openai” (4.47.1), que integra o modelo de IA da OpenAI para fornecer respostas inteligentes aos agricultores com base nos conteúdos coletados bem como é utilizado para consumir o modelo Whisper responsável pela transcrição de áudio para texto no tratamento das mensagens de áudio que são recebidas.

A funcionalidade de coleta de preços regionais disponibilizados pelo Ceasa Pernambuco foi desenvolvida utilizando Python. A biblioteca “requests” foi usada para realizar requisições HTTP e acessar os dados publicados no site oficial do Ceasa-Pe;

“BeautifulSoup” para fazer o *parsing* do HTML e extrair informações estruturadas, como tabelas de preços. Bibliotecas “os” e “io” para manipulação de arquivos e fluxos de dados, possibilitando a persistência local das informações extraídas em tempo de execução que posteriormente foram salvos como arquivo no vetor de conhecimento do modelo assistente da OpenAi. Biblioteca “re” para aplicar expressões regulares na organização e tratamento dos dados e “json” para estruturar as informações coletadas em um formato compatível com o *backend*.

Para garantir escalabilidade e eficiência, a aplicação foi implantada em um ambiente de computação em nuvem utilizando os serviços da Amazon Web Services (AWS). O Amazon EC2 foi utilizado para hospedar o *backend* com um sistema linux ubuntu 24.02 instalado e o software pm2 em sua versão 5.4.0 para manter a aplicação em execução no sistema operacional. API Gateway permitiu a criação e o gerenciamento de APIs *RESTful* para roteamento seguro e eficiente de requisições. AWS Lambda executou funções *serverless* específicas, otimizando custos e escalabilidade; o Amazon EventBridge integrou os eventos de cron utilizados para diariamente recuperar dados atualizados do Ceasa de forma a possibilitar automatização dessa tarefa; e o Amazon CloudWatch forneceu métricas e logs detalhados para monitoramento e diagnóstico da aplicação (Utilizado principalmente para verificar os logs dos lambdas).

4.2 Validação das funcionalidades com NPS

Para avaliar a aceitação e eficácia do *chatbot* desenvolvido, foi realizada uma pesquisa de *Net Promoter Score* (NPS) junto a uma associação de agricultores localizada no Sítio do Uri. O NPS, metodologia criada por Frederick Reichheld (2003), é amplamente utilizado para medir a lealdade e satisfação dos usuários por meio de uma única pergunta central: “Em uma escala de 0 a 10, o quanto você recomendaria este produto/serviço a um amigo ou colega?”. A validação ocorreu por meio de um questionário *online* que foi enviado para os membros da associação com a única pergunta descrita a cima que podia ser respondida de forma anônima. O número de testes do protótipo foi enviado aos membros da associação permitindo que interagissem livremente com a ferramenta e explorassem suas funcionalidades. Ao todo foram coletadas 7 respostas.

5. Conecta Agro: Quebrando Barreiras no Agronegócio

O ConectaAgro é uma solução experimental para aproximar o agricultor dos mais recentes avanços tecnológicos como Inteligência Artificial (IA), para viabilizar a inclusão digital do agricultor familiar. O objetivo central é agregar valor ao cotidiano do pequeno produtor por meio da disponibilização de dados e informações centralizadas, que promovem maior eficiência e produtividade no manejo de suas atividades agrícolas. Para o desenvolvimento do protótipo, foram utilizadas não apenas ferramentas de IA, mas também um conjunto diversificado de recursos tecnológicos que potencializam a solução.

Foi desenvolvido um *chatbot* inteligente que orienta o agricultor através do Whatsapp para que este tenha acesso a informação de qualidade e em tempo real podendo buscar por políticas públicas para captar recurso ou participar de ações do governo para compra de produtos do campo, boas práticas agrônômicas e inclusive precificar o seu produto e pesquisar por preços de acordo com o mercado atual da região. As informações fornecidas

pelo *chatbot* são originadas de fontes confiáveis e amplamente reconhecidas, como domínios do governo federal, portais de pesquisa pública e bases de dados especializadas. Um exemplo significativo é a utilização da pesquisa de preços realizada pelo Ceasa-Pe, que semanalmente disponibiliza um levantamento detalhado sobre os produtos comercializados na região, garantindo dados confiáveis para os agricultores.

Destaca-se a interatividade com o agricultor, que, em sua maioria, não detém conhecimento para domínio e manipulação de sistemas digitais e tecnológicos. No entanto, por intermédio dos modelos com capacidade de PLN e de uma ferramenta de comunicação já estabelecida entre os agricultores, essas barreiras são quebradas, viabilizando uma conversação simples, sem necessidade de muitas instruções adicionais. Dessa forma, o agricultor atende suas necessidades utilizando o saber tecnológico e digital que ele mesmo já possui, eliminando a necessidade de uma curva de aprendizado elevada para aprender a navegar no fluxo de um sistema institucional público, por exemplo. Além da facilidade em sua utilização mantendo-se o modelo com acesso a informações atualizadas e alinhadas com a realidade local do usuário ele terá acesso sempre em tempo real de forma rápida acesso a informações sem dependência de terceiros e intensificando sua autonomia.

5.1 Definição de funcionalidades

A partir das funcionalidades que definem o escopo de conhecimento do *chatbot* é importante esclarecer como o modelo pode auxiliar em cada área. A funcionalidade de acesso a políticas públicas busca oferecer inclusão de informações sobre programas governamentais, linhas de crédito e subsídios disponíveis para o pequeno agricultor essa funcionalidade é crucial para possibilitar o acesso a recursos materiais e financeiros que auxiliem no fortalecimento da produção agrícola. A área de orientação agrônômica viabiliza acesso a conhecimento de boas práticas de manejo agrícola e orientações técnicas, visando à otimização da produtividade e à sustentabilidade das culturas. Essa funcionalidade foi priorizada devido à falta de assistência técnica frequente em regiões mais isoladas. A precificação de produtos visa auxiliar o agricultor na definição de preços justos para seus produtos, com base em dados de mercado atualizados e regionais. Essa funcionalidade busca evitar que o agricultor tenha prejuízos durante a comercialização de sua produção, promovendo maior autonomia financeira.

As funcionalidades selecionadas refletem a realidade enfrentada pelos pequenos agricultores, especialmente aqueles que residem em áreas rurais e possuem menor acesso à educação formal ou à tecnologia. Além disso, elas endereçam desafios como o acesso limitado às ações governamentais e a necessidade de suporte técnico para maximizar os resultados no campo. Essa etapa foi fundamental para estabelecer o escopo do protótipo e garantir que as soluções propostas fossem úteis e alinhadas às necessidades do público-alvo.

5.2 Base de dados para RAG

Para sustentar as respostas do modelo a construção da base de dados para a implementação da técnica de RAG é um processo importante que envolveu a coleta e organização de materiais provenientes de fontes confiáveis, garantindo a relevância e a

precisão das informações disponibilizadas pelo protótipo. As fontes selecionadas foram agrupadas em três categorias principais, de acordo com as funcionalidades definidas previamente.

O material relacionado às políticas públicas foi coletado diretamente do portal oficial do Governo Federal, especificamente na seção dedicada ao Ministério do Desenvolvimento Agrário e Agricultura Familiar (MDA), acessível em gov.br/mda. Foram extraídos conteúdos sobre documentos necessários para participação em programas governamentais, como o Cadastro Nacional da Agricultura Familiar (CAF), além de guias e instruções para iniciativas como o Programa de Aquisição de Alimentos (PAA), o Programa Nacional de Fortalecimento da Agricultura Familiar (PRONAF), o Programa Nacional de Alimentação Escolar (PNAE) e o Garantia-Safra. Esses materiais fornecem subsídios essenciais para orientar os agricultores na adesão e no aproveitamento dessas políticas.

As orientações agronômicas foram coletadas a partir de artigos científicos e portais especializados, como o Agrolink, que disponibiliza uma ampla gama de informações para agricultores. Em particular, a seção AgrolinkFito (agrolink.com.br/agrolinkfito.com.br) foi utilizada para acessar conteúdos sobre insumos e defensivos agrícolas, incluindo instruções detalhadas sobre aplicação, dosagem, medidas de segurança e melhores práticas no manejo agrícola. A seleção desse material buscou garantir que as orientações técnicas fossem baseadas em evidências e práticas recomendadas.

Para a funcionalidade de precificação, optou-se pela consulta a dados regionais atualizados, seguindo o modelo já implementado pelo CEASA Pernambuco. Essa entidade realiza semanalmente levantamentos de preços dos produtos agrícolas comercializados em sua central de abastecimento, disponibilizando as tabelas no site oficial (ceasape.org.br/cotacao). Para automatizar o acesso a esses dados, aplicou-se a técnica de web scraping, ou raspagem de dados, que permite recuperar páginas HTML e coletar conteúdos relevantes diretamente da web. Essa abordagem possibilitou a extração automatizada das tabelas de preços atualizadas e a geração de arquivos estruturados, que foram integrados à base de dados do protótipo. Esses procedimentos garantiram que a base de dados fosse abrangente, confiável e constantemente atualizada, permitindo ao ConectaAgro oferecer informações precisas e relevantes para os agricultores familiares.

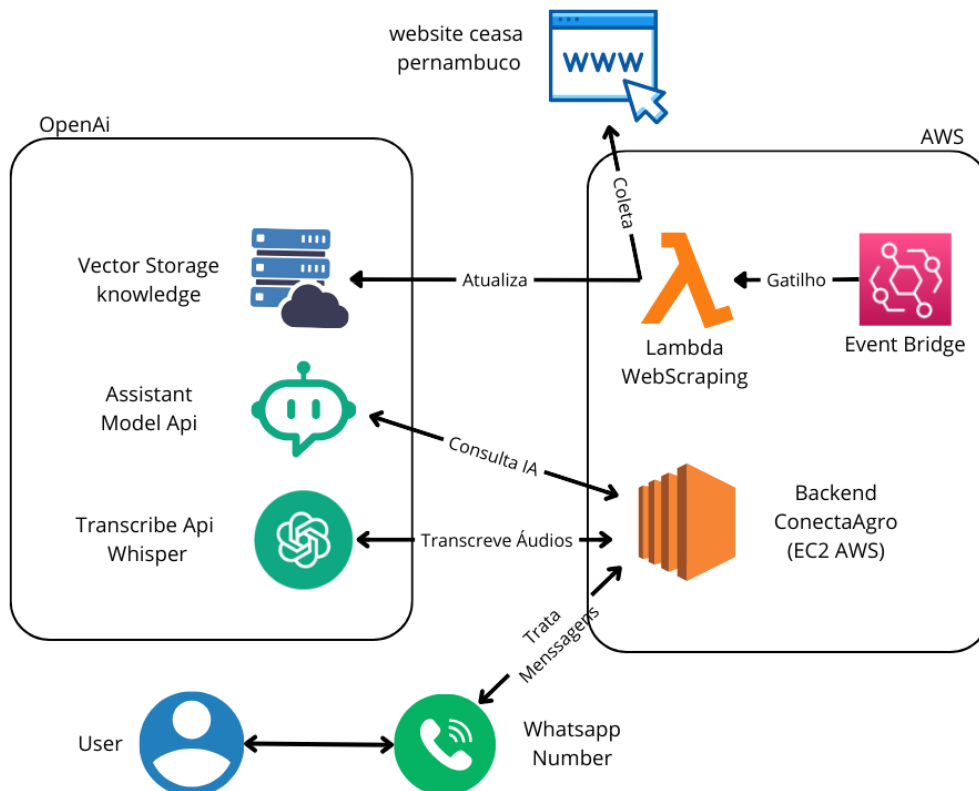


Figura 1 – Arquitetura do sistema

Na Figura 1, podemos observar a arquitetura do sistema que foi desenvolvido, no qual vale comentar o *vector storage knowledge*, que é o vetor de armazenamento para o conhecimento disponibilizado para o assistente. É acessando esse vetor via API que se torna possível atualizar o conhecimento dinamicamente. O processo de RAG é realizado internamente pela própria plataforma da OpenAi uma vez que o vetor esteja associado ao assistente. Através da biblioteca “baileys” eventos são gerados para as ações que chegam até o número de Whatsapp conectado. Tornando-se possível tratar esse evento (nesse caso, as mensagens de conversas individuais) abstraindo o conteúdo da mesma, enviando como parâmetro de entrada para o modelo e retornando a resposta gerada pelo assistente que está hospedado na OpenAi diretamente para o contato que iniciou a conversa. O Amazon Event Bridge permite configurar *cron jobs* que são gatilhos baseado em tempo, ou seja, de tempos em tempos (nesse caso diariamente) A função lambda responsável pela *web scrapping* é invocada e executa seu código acessando então o site da Ceasa-Pe e obtendo sua estrutura html. Dentro desse html existe uma tabela com informações sobre os preços que é então percorrida a fim de coletar esses dados e partir deles gerar um documento JSON. Esse documento é então escrito/sobescrito no *vector storage* e hospedado nos servidores da OpenAi por meio da API disponibilizada pela própria. A aplicação é executada sobre um ec2 da AWS que é uma máquina virtual contendo o código do sistema que gerencia o recebimento de mensagens e faz as solicitações para o modelo assistente e o modelo de transcrição de áudio para texto.

6. Resultados e Discussão

Ao final deste trabalho conseguimos desenvolver um *chatbot* que utiliza modelos LLM de IA para abstrair conhecimento e responde pelo WhatsApp cujo propósito é auxiliar o agricultor no seu dia a dia para que este venha a ter informações sobre melhores práticas agronômicas, recursos do governo, preços e orientações para precificar seu produto. Seguindo o fluxo proposto da aplicação ao interagirmos com o *chatbot* ele oferece ao usuário suas funcionalidades:

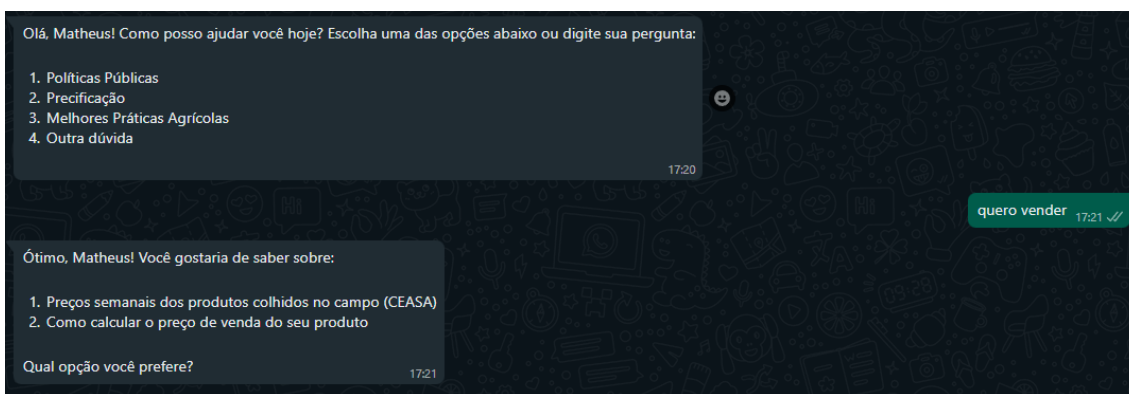


Figura 2 - Interação precificação

Na interação através do WhatsApp o agricultor pode navegar por opções ou digitar diretamente o que é de seu interesse como demonstrado na figura 2. Vale salientar que o sistema já possui suporte para receber áudios.

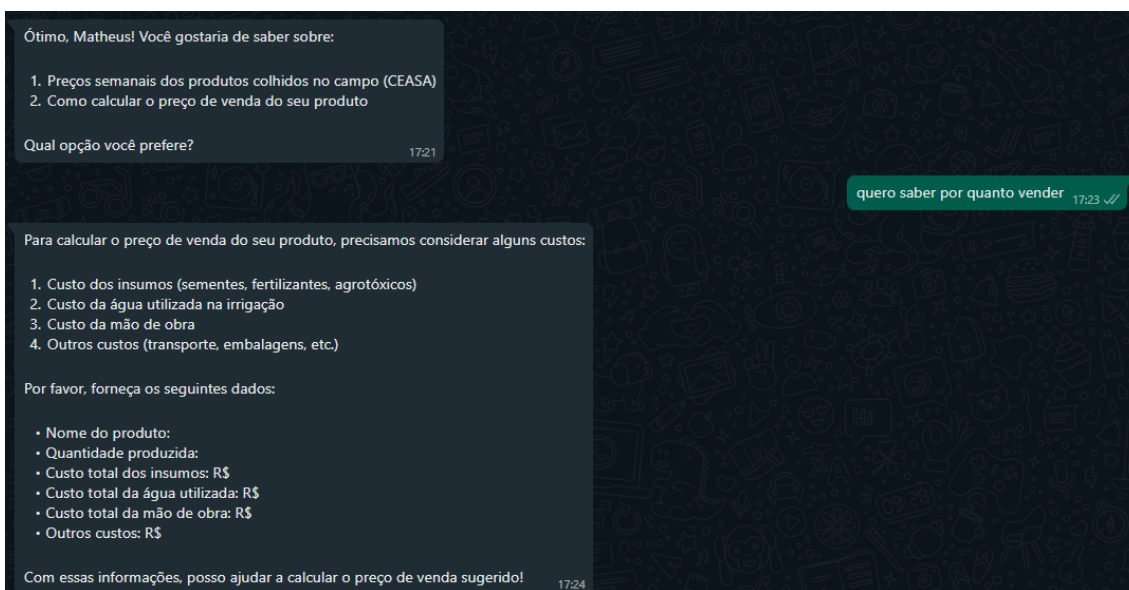


Figura 3 - Interação precificação 2

É possível solicitar os preços de um determinado produto conforme consta no site da Ceasa-Pe, na figura 3 optamos por solicitar orientações para um cálculo de custo personalizado.

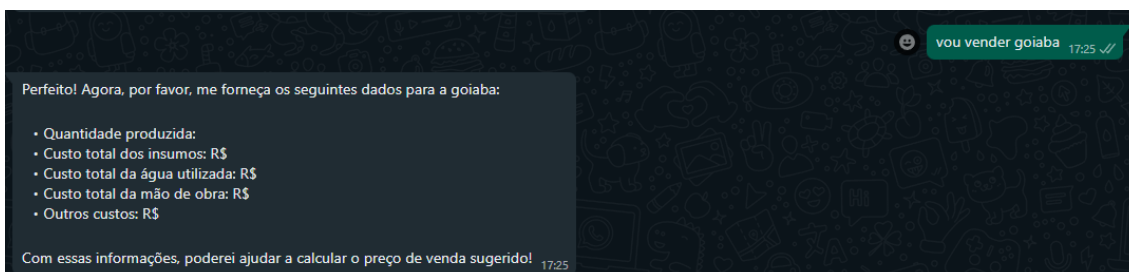


Figura 4 - Interação precificação 3

Podemos prosseguir com a interação inserindo as informações solicitadas, que levam o agricultor a refletir sobre seus próprios gastos e a registrar detalhadamente esses dados para análise (Figura 4).

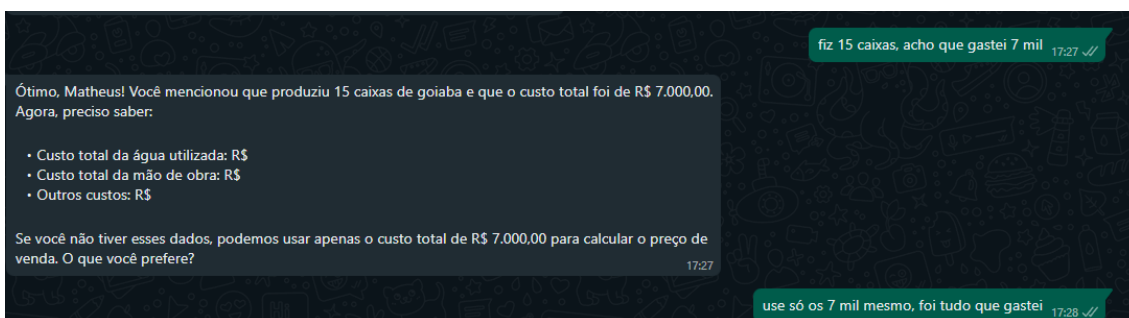


Figura 5 - Interação precificação 4

Conforme a figura 5 podemos analisar que a interação funciona de maneira fluida e que apesar de solicitar diversas informações o agricultor pode conversar e resumir dados ou prosseguir informando custo a custo conforme solicitado.

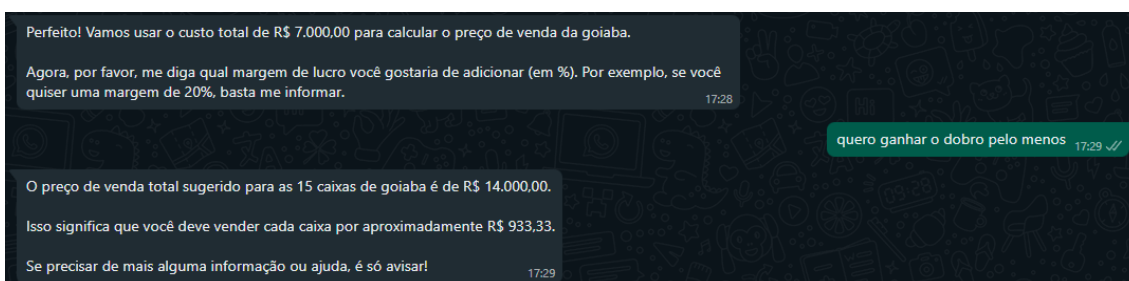


Figura 6 - Interação precificação 5

Ao final do processo é retornado ao agricultor todas as informações necessárias para que ele venda o seu produto a um preço mínimo sem que perca dinheiro e lucre com sua produção (figura 6).



Figura 7 - Interação políticas públicas

Alterando o tema da conversa podemos também obter informações referente a políticas públicas. A partir daqui o usuário pode perguntar sobre qualquer tema que esteja no escopo do assistente. Observa-se que a orientação é realizada com base nos documentos anexados para o assistente por meio do método RAG já apresentado. (figura 7)

O difenoconazol é um fungicida que deve ser usado com cuidado. Aqui estão algumas orientações sobre como utilizá-lo:

- *Manejo Integrado*:** É importante usar uma combinação de métodos para controlar as doenças, como:
 - Usar sementes saudáveis.
 - Plantar variedades resistentes.
 - Fazer a rotação de culturas.
 - Aplicar na época certa.
- *Alternância de Fungicidas*:** Para evitar que os fungos se tornem resistentes, alterne o uso de fungicidas com diferentes mecanismos de ação.
- *Aplicação*:**
 - Use o produto apenas nas culturas para as quais ele está registrado.
 - Siga as recomendações da bula quanto à dose, intervalo e número de aplicações.
 - Sempre consulte um Engenheiro Agrônomo para orientações específicas.
- *Precauções*:**
 - Utilize Equipamentos de Proteção Individual (EPIs) ao manusear o produto.
 - Não aplique o produto em condições de estresse das plantas, como frio excessivo ou seca.
 - Evite a aplicação em áreas próximas a culturas sensíveis.
- *Monitoramento*:** Acompanhe a saúde das plantas e a eficácia do produto, ajustando as práticas conforme necessário.

Essas práticas ajudarão a garantir que o difenoconazol seja eficaz e seguro para suas culturas [40:0+source].

Precisa de mais alguma informação sobre melhores práticas agrícolas? 14:34

Figura 8 - Interação orientações agrônômicas

Na figura 8 consultamos o assistente a respeito do uso do fungicida difenoconazol, é possível extrair também informações mais específicas uma vez que temos informações sobre esse produto na base de conhecimento.

O preço do maracujá é o seguinte:

- Maracujá (Cx. 15 a 18 kg, Primeira):
 - Preço mínimo: R\$ 100,00
 - Preço médio: R\$ 110,00
 - Preço máximo: R\$ 120,00
- Maracujá (Cx. 15 a 18 kg, Segunda):
 - Preço mínimo: R\$ 70,00
 - Preço médio: R\$ 80,00
 - Preço máximo: R\$ 90,00

Esses preços são referentes ao dia 04/10/2024 [140:0+source] [140:1+source].

Se precisar de mais alguma informação sobre precificação, estou aqui para ajudar! 21:14

Figura 9 - Interação consulta de preços

Ao questionar sobre preços de produtos é retornado o produto a quantidade vendida e o preço. No caso do exemplo da figura 9 o maracujá é vendido em caixas de 15 a 18 kg e pode ser dividido em duas categorias como produto de primeira e segunda, com faixas de preço com classificações de mínimo, médio e máximo.

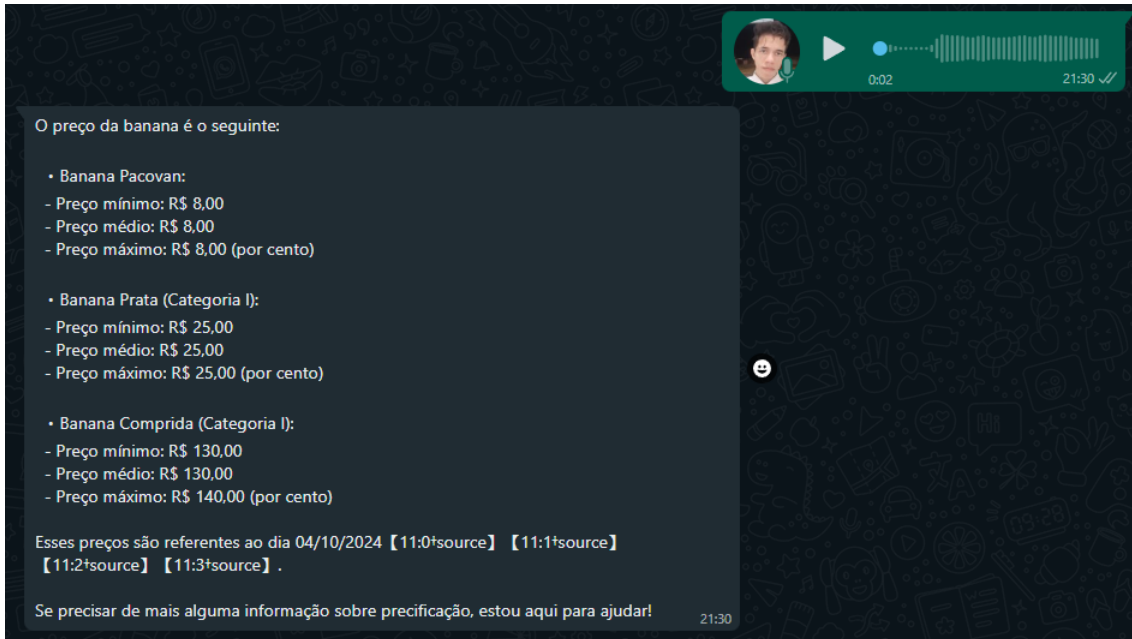


Figura 10 - Interação consulta de preços por voz

Na figura 10 testamos também a funcionalidade de áudio no qual é perguntado: “Qual o preço da banana?” No caso da banana que possui diversos tipos, o assistente retorna também os valores separados pelas classificações do produto. Vale ressaltar que todas as informações nos testes e demonstrações são meramente ilustrativas.




Figura 11 - gráfico NPS

Conforme figura 11 no NPS a avaliação dos usuários foi muito positiva. A pesquisa NPS foi realizada por meio de formulário eletrônico com preenchimento anônimo e um total de 7 respostas contendo a seguinte pergunta de avaliação “Em uma escala de 0 a 10, o quanto você recomendaria o ConectaAgro a um amigo ou colega?”.

Os respondentes podem ser classificados em três categorias. Os promotores, que atribuem notas 9 ou 10, são usuários altamente satisfeitos e propensos a recomendar o serviço. Os neutros, que dão notas 7 ou 8, estão relativamente satisfeitos, mas não demonstram lealdade, podendo facilmente migrar para alternativas concorrentes. Já os detratores, que avaliam com notas 6 ou inferiores, são usuários insatisfeitos que podem impactar negativamente a reputação do serviço ao compartilhar experiências desfavoráveis. Essa segmentação é proposta por Reichheld (2003).

O NPS é calculado pela fórmula:

$$NPS = (% \text{ Promotores} - \% \text{ Detratores})$$

- Promotores: 4 agricultores (57,14%)
- Neutros: 3 agricultores (42,86%)
- Detratores: 0 agricultores (0%)

Substituindo na fórmula:

$$NPS = 57,14\% - 0\% = 57,14\%$$

Um NPS de 57 indica que a maioria dos usuários está satisfeita e provavelmente recomendaria o ConectaAgro, uma vez que um NPS acima de 50 indica um número significativamente maior de promotores em relação aos detratores. Apesar do resultado positivo, existe uma oportunidade de converter os usuários neutros (notas 8) em promotores, por meio de pequenas melhorias no serviço, o que poderia elevar ainda mais a lealdade dos usuários.

7. Considerações Finais

Este trabalho apresentou uma solução tecnológica para facilitar o acesso do pequeno agricultor a informações de qualidade e em tempo real, por meio de um *chatbot* disponível 24 horas por dia. A implementação da ferramenta demonstrou ser viável e, conforme os resultados obtidos na validação por meio do NPS, os agricultores manifestaram interesse em explorar ainda mais a utilização do sistema. A disponibilização de conhecimento acessível, rápido e confiável é uma realidade já consolidada em diversas áreas, estando presente no cotidiano de muitas pessoas, porém ainda possui baixa aderência entre pequenos produtores rurais. Os resultados sugerem que a adoção de tecnologias baseadas em Inteligência Artificial e Processamento de Linguagem Natural pode contribuir para a democratização do acesso à informação no setor agrícola, auxiliando na tomada de decisão e na melhoria da produtividade. Todavia existem desafios e melhorias a serem explorados em trabalhos futuros, incluindo a validação da qualidade das respostas fornecidas pelo assistente, a integração de tecnologias para leitura e interpretação de imagens, além da expansão da base de conhecimento do *chatbot*, garantindo que ele abranja um conjunto ainda mais amplo de informações relevantes para os agricultores. Dessa forma, este estudo contribui para a inserção da Agricultura 4.0 no contexto da agricultura familiar, abrindo caminho para novas pesquisas e aprimoramentos tecnológicos que possam ampliar o impacto da digitalização no campo.

Referencias

ASOLO, Emmanuel et al. AI-Powered decision support systems for sustainable agriculture using AI-Chatbot solution. *Journal of Digital Food, Energy & Water Systems*, v. 5, n. 1, 2024.

BRASIL. Ministério do Desenvolvimento Agrário e Agricultura Familiar. Conheça as políticas e programas do MDA. 2024. Disponível em: <https://www.gov.br/mda/pt-br/noticias/2024/07/conheca-as-politicas-e-programas-do-mda>. Acesso em: 16 mar. 2025.

Caseli, H.M.; Nunes, M.G.V. (org.) *Processamento de Linguagem Natural: Conceitos, Técnicas e Aplicações em Português*. 2 ed. BPLN, 2024. Disponível em: <https://brasileiraspln.com/livro-pln/2a-edicao>.

- CONEGLIAN, Caio Saraiva; SEGUNDO, José Eduardo Santarem; SANT'ANA, Ricardo César Gonçalves. Big Data: fatores potencialmente discriminatórios em análise de dados. Em *Questão*, v. 23, n. 1, p. 62-86, 2017.
- JOSHI, Satyadhar. Review of Gen AI models for financial risk management. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, v. 11, n. 1, p. 709-723, 2025.
- MARQUES, Ruben Alexandre Dias. APLICAÇÃO DE RAG EM MODELOS LLM COM BASES DE DADOS VETORIAIS. 2024. Tese de Doutorado.
- MASSRUHÁ, Silvia Maria Fonseca Silveira; LEITE, MA de A. Agro 4.0-rumo à agricultura digital. 2017.
- MASSRUHÁ, Silvia Maria Fonseca Silveira et al. A transformação digital no campo rumo à agricultura sustentável e inteligente. 2020.
- MATARIĆ, Maja J. Introdução à robótica. Editora Blucher, 2014.
- META AI. **LLaMA 2: Open Foundation and Fine-Tuned Chat Models**. 2023. Disponível em: <https://www.llama.com/>. Acesso em: 8 mar. 2025.
- MOSTACO, Gustavo Marques et al. AgronomoBot: a smart answering Chatbot applied to agricultural sensor networks. In: 14th international conference on precision agriculture. 2018. p. 1-13.
- MOUHA, Radouan Ait Radouan Ait et al. Internet of things (IoT). *Journal of Data Analysis and Information Processing*, v. 9, n. 02, p. 77, 2021.
- Muhammad Usman Hadi, Qasem Al Tashi, Rizwan Qureshi, et al. Large Language Models: A Comprehensive Survey of its Applications, Challenges, Limitations, and Future Prospects. *TechRxiv*. November 16, 2023.
- OPENAI. GPT-4 Technical Report. 2023. Disponível em: <https://openai.com/research/gpt-4>. Acesso em: 8 mar. 2025.
- PEREIRA, João Eduardo Souza. Evolução das políticas agropecuárias 2000-2020 e a

sustentabilidade ambiental. 2022.

REICHHELD, Frederick F. The One Number You Need to Grow. Harvard Business Review, v. 81, n. 12, p. 46-54, 2003.

RUSSEL, Stuart; NORVIG, Peter. Artificial intelligence—a modern approach 3rd Edition. The Knowledge Engineering Review, v. 3, 2012.

TECHNOLOGY INNOVATION INSTITUTE. **Falcon Language Models**. 2023. Disponível em: <https://huggingface.co/tiiuae>. Acesso em: 8 mar. 2025.

TEIXEIRA, João. O que é inteligência artificial. E-galáxia, 2019.

ZHANG, Yang et al. Attention is all you need: utilizing attention in AI-enabled drug discovery. Briefings in bioinformatics, v. 25, n. 1, p. bbad467, 2024.