



VINICIUS HABIB ANDRADE

**ASSISTENTE INTELIGENTE PARA GESTÃO AGRÍCOLA
POR MEIO DE CHATBOT INTEGRADO AO WHATSAPP
COM INTELIGÊNCIA ARTIFICIAL NO MONITORAMENTO
DE LAVOURAS DE CAFÉ**

LAVRAS – MG

2025

VINICIUS HABIB ANDRADE

**ASSISTENTE INTELIGENTE PARA GESTÃO AGRÍCOLA POR MEIO DE
CHATBOT INTEGRADO AO WHATSAPP COM INTELIGÊNCIA ARTIFICIAL NO
MONITORAMENTO DE LAVOURAS DE CAFÉ**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Ciências da Computação, para a obtenção do título de Mestre.

Prof. DSc. Orientador Luiz Henrique Andrade Correia
Orientador

**LAVRAS – MG
2025**

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Andrade, Vinicius Habib.

Assistente inteligente para gestão agrícola por meio de chatbot integrado ao
whatsapp com inteligência artificial no monitoramento de lavouras de café /
Vinicius Habib Andrade. - 2025.

106 p. : il.

Orientador: Luiz Henrique Andrade Correia

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.
Bibliografia.

1. Agricultura 5.0. 2. Inteligência Artificial. 3. Chatbot. 4. Monitoramento
Agrícola. 5. Gestão Agrícola. I. Andrade Correia, Luiz Henrique. II. Universidade
Federal de Lavras. III. Título.

VINICIUS HABIB ANDRADE

**ASSISTENTE INTELIGENTE PARA GESTÃO AGRÍCOLA POR MEIO DE
CHATBOT INTEGRADO AO WHATSAPP COM INTELIGÊNCIA ARTIFICIAL NO
MONITORAMENTO DE LAVOURAS DE CAFÉ**

**INTELLIGENT ASSISTANT FOR AGRICULTURAL MANAGEMENT THROUGH
AN AI-POWERED CHATBOT INTEGRATED WITH WHATSAPP FOR
MONITORING COFFEE CROPS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência da Computação, área de concentração em Ciências da Computação, para a obtenção do título de Mestre.

APROVADA em 2 de dezembro de 2025.

Prof. André de Lima Salgado UFLA

Prof. Renata Andrade Reis UFLA

Prof. Júlio Cezar Estrella USP

Prof. DSc. Orientador Luiz Henrique Andrade Correia
Orientador

**LAVRAS – MG
2025**

A meu filho Miguel e a minha esposa Mayra por todo o apoio, carinho e compreensão ao longo desta caminhada e aos meus pais, Lourdes e Sérgio.

AGRADECIMENTOS

Agradeço a toda a minha família pelo carinho e apoio, a meu filho e esposa pelo porto seguro, conselhos e incentivos, que não mediram esforços para que eu chegasse até esta etapa na caminhada da minha vida.

Ao professor Luiz Correia por toda a orientação, paciência, ensinamentos e auxílios no desenvolvimento e implementação do trabalho.

Agradeço à Universidade Federal de Lavras e, em especial, ao Departamento de Ciência da Computação no Programa de Pós-Graduação em Ciência da Computação, pela oportunidade concedida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

"Entrega o teu caminho ao Senhor, confia nele, e ele tudo fará"

(Salmo 37:5)

RESUMO

A agricultura contemporânea enfrenta o desafio de produzir mais alimentos com menos recursos, conciliando eficiência produtiva, sustentabilidade ambiental e competitividade econômica. Nesse cenário, a gestão baseada em dados torna-se fundamental para apoiar decisões estratégicas e operacionais no campo. Este trabalho propõe e avalia a utilização de um agente conversacional com inteligência artificial, integrado ao WhatsApp, como solução para centralizar e interpretar informações agrícolas. O sistema desenvolvido organiza dados climáticos, financeiros, estratégicos e operacionais, oferecendo recomendações acessíveis e personalizadas para agricultores, com ênfase no cultivo do café. A pesquisa insere-se no contexto da agricultura inteligente, alinhada aos princípios da agricultura 5.0, explorando o potencial da Internet das Coisas (IoT) e da inteligência artificial para promover práticas agrícolas mais eficientes, sustentáveis e orientadas por dados. Os resultados obtidos indicam o fortalecimento da autonomia dos pequenos e médios produtores, a redução de desperdícios, o uso racional de insumos e a melhoria da produtividade agrícola.

Palavras-chave: agricultura 5.0; inteligência artificial; chatbot; monitoramento agrícola; gestão agrícola

ABSTRACT

Contemporary agriculture faces the challenge of producing more food with fewer resources, balancing productive efficiency, environmental sustainability, and economic competitiveness. In this context, data-driven management becomes essential to support strategic and operational decision-making in the field. This study proposes and evaluates the use of an artificial intelligence-based conversational agent, integrated with WhatsApp, as a solution to centralize and interpret agricultural information. The developed system organizes climatic, financial, strategic, and operational data, providing accessible and personalized recommendations for farmers, with emphasis on coffee cultivation. The research is situated within the context of smart agriculture, aligned with the principles of Agriculture 5.0, exploring the potential of the Internet of Things (IoT) and artificial intelligence to promote more efficient, sustainable, and data-driven agricultural practices. The results obtained indicate strengthened autonomy of small and medium-sized producers, reduced waste, more rational use of inputs, and improved agricultural productivity.

Keywords: agriculture 5.0; artificial intelligence; chatbot; agricultural monitoring; agricultural management

INDICADORES DE IMPACTO

O desenvolvimento de um assistente inteligente integrado ao WhatsApp para suporte à gestão agrícola e ao monitoramento de lavouras de café apresenta impactos sociais, tecnológicos, econômicos e ambientais que dialogam diretamente com as demandas contemporâneas da agricultura digital e com a realidade produtiva da região Sul de Minas Gerais, território onde se concentram os potenciais usuários da solução. Socialmente, o trabalho contribui para a redução das desigualdades relacionadas ao acesso à informação tecnológica no meio rural, uma vez que disponibiliza um sistema de fácil utilização baseado em linguagem natural, incorporado a um aplicativo amplamente difundido entre pequenos e médios produtores. Esse formato reduz barreiras de letramento digital, democratiza ferramentas avançadas de análise e fortalece a autonomia dos agricultores na tomada de decisão cotidiana. Os testes realizados com usuários reais demonstram que a solução facilita a interpretação de dados climáticos, estratégicos, operacionais e financeiros, oferecendo recomendações consistentes que auxiliam no manejo do dia a dia e ampliam a capacidade de resposta diante de eventos adversos, especialmente aqueles relacionados ao clima. No âmbito tecnológico, o assistente representa uma inovação por combinar inteligência artificial generativa, técnicas de recuperação aumentada por contexto e integração contínua com diferentes fontes de dados, estabelecendo um fluxo de operação robusto que limita alucinações, aumenta a confiabilidade das respostas e demonstra a aplicação prática de princípios da Agricultura 5.0 no contexto do café. A arquitetura desenvolvida, apoiada em armazenamento persistente e workflows modulares, favorece escalabilidade, reprodutibilidade e possibilidade de adoção por instituições parceiras, como cooperativas, serviços de assistência técnica e setores de extensão universitária. Do ponto de vista econômico, o uso da ferramenta apresenta potencial significativo de otimização operacional, ao fornecer análises que podem reduzir desperdícios de insumos, aprimorar o uso de recursos hídricos, orientar práticas mais eficientes de manejo e fortalecer o planejamento estratégico das lavouras. Esses elementos contribuem para maior sustentabilidade financeira das propriedades, redução de custos e aumento potencial de produtividade, impactando positivamente o desenvolvimento econômico regional. Há também impactos ambientais associados, pois decisões mais bem informadas tendem a reduzir o uso excessivo de insumos e minimizar riscos de degradação do solo e da vegetação, alinhando o sistema às diretrizes de produção responsável e mitigação de efeitos climáticos. O caráter extensionista do trabalho revela-se pela interação direta com produtores rurais e técnicos da região, pelo uso de dados oriundos das propriedades e pelo retorno efetivo das análises como

forma de apoio à comunidade, cumprindo o papel de integração entre universidade e sociedade. As ações dialogam com as áreas temáticas comunicação, educação, meio ambiente e tecnologia e produção, ao mesmo tempo em que se articulam com diversos Objetivos de Desenvolvimento Sustentável, como agricultura sustentável, saúde e bem-estar, educação de qualidade, energia limpa, crescimento econômico, inovação, redução das desigualdades, cidades sustentáveis, produção responsável, ação climática, vida terrestre e parcerias. Dessa forma, o trabalho evidencia contribuição robusta, integrada e de impacto para a transformação digital no território cafeeiro.

IMPACT INDICATORS

The development of an intelligent assistant integrated into WhatsApp to support agricultural management and the monitoring of coffee plantations presents social, technological, economic, and environmental impacts that directly align with contemporary demands of digital agriculture and with the productive reality of the southern region of Minas Gerais, where the potential users of the solution are concentrated. Socially, the work contributes to reducing inequalities related to access to technological information in rural areas by offering an easy-to-use system based on natural language, embedded in an application widely adopted by small and medium-scale farmers. This approach lowers digital literacy barriers, democratizes access to advanced analytical tools, and strengthens farmers' autonomy in daily decision-making. Tests conducted with real users indicate that the solution facilitates the interpretation of climatic, strategic, operational, and financial data, providing consistent recommendations that support day-to-day management and expand the ability to respond to adverse events, especially those related to climate variability. From a technological perspective, the assistant represents an innovation by combining generative artificial intelligence, retrieval-augmented generation techniques, and continuous integration with different data sources, establishing a robust operational workflow that reduces hallucinations, increases the reliability of responses, and demonstrates the practical application of Agriculture 5.0 principles in the coffee production context. The developed architecture, supported by persistent storage and modular workflows, promotes scalability, reproducibility, and the potential for adoption by partner institutions such as cooperatives, technical assistance services, and university extension sectors. From an economic perspective, the system shows significant potential for operational optimization by providing analyses capable of reducing input waste, improving water resource management, guiding more efficient cultivation practices, and strengthening the strategic planning of coffee farms. These factors contribute to greater financial sustainability, reduced operational costs, and potential productivity gains, positively impacting regional economic development. Environmental impacts are also present, as better-informed decisions tend to reduce excessive input use and minimize risks of soil and vegetation degradation, aligning the system with guidelines for responsible production and climate impact mitigation. The extension-oriented nature of the work becomes evident through direct interaction with local farmers and technicians, through the use of data originating from rural properties, and through the effective return of analyses as a form of community support, fulfilling the role of integrating the university with broader society. The actions align with thematic

areas such as communication, education, environment, and technology and production, while simultaneously connecting with several Sustainable Development Goals, including sustainable agriculture, good health and well-being, quality education, clean energy, economic growth, innovation, reduction of inequalities, sustainable communities, responsible production, climate action, life on land, and partnerships. Thus, the work demonstrates a robust, integrated, and impactful contribution to the digital transformation of the coffee-growing sector.

LISTA DE FIGURAS

Figura 4.1 – Arquitetura geral do assistente inteligente agrícola	56
Figura 4.2 – <i>Workflow</i> N8N	59
Figura 4.3 – Workflow do nó <code>retornaTempo</code> para obtenção de dados meteorológicos . .	67
Figura 4.4 – Workflow de integração do Supabase Vector Store e Embeddings Google Gemini no N8N	68
Figura 4.5 – Workflow N8N do nó <code>retornaURL_financeiro</code>	70
Figura 4.6 – Workflow N8N do nó <code>retornaURL_estratégico</code>	71
Figura 6.1 – Interações do assistente inteligente na iteração climática e financeira	92
Figura 6.2 – Interações do assistente inteligente na iteração estratégica e operacional . .	93

LISTA DE TABELAS

Tabela 6.1 – Métricas estatísticas de acurácia das previsões climáticas fornecidas pelo <i>chatbot</i> em comparação com o termômetro ambiente (período total de 7 dias).	82
Tabela 6.2 – Métricas estatísticas de acurácia das previsões climáticas do <i>chatbot</i> por período do dia, comparadas com as medições locais.	82
Tabela 6.3 – Métricas de avaliação das operações <i>INSERT</i> , <i>DELETE</i> e <i>READ</i> realizadas pelo <i>chatbot</i> no banco de dados.	85
Tabela 6.4 – Métricas de avaliação das consultas (<i>READ</i>) realizadas pelo <i>chatbot</i> em comparação com o banco de dados.	85
Tabela 6.5 – Métricas de avaliação operacional das respostas do <i>chatbot</i> baseadas em artigo científico armazenado em <i>embeddings</i>	87
Tabela 6.6 – Resultados das escalas <i>Likert</i> (1 = discordo totalmente; 5 = concordo totalmente).	89

LISTA DE QUADROS

Quadro 3.1 – Comparativo de Abordagens em <i>Chatbots</i> Agrícolas	55
---	----

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Motivação	20
1.2	Justificativa	21
1.3	Objetivo Geral	22
1.4	Objetivos Específicos	22
1.5	Organização do Trabalho	23
2	REFERENCIAL TEÓRICO	24
2.1	Agricultura Inteligente	24
2.1.1	Evolução da Agricultura: da Tração Animal à Agricultura 5.0	25
2.1.2	Características da Agricultura 5.0	25
2.1.3	Benefícios, Desafios e Perspectivas	26
2.2	Inteligência Artificial	27
2.2.1	Definição e Conceitos Fundamentais	27
2.2.2	Tecnologias da Inteligencia Artificial	29
2.2.3	Impacto da IA na Gestão Administrativa	30
2.2.4	Limitações Técnicas e Desafios Éticos da Inteligência Artificial	30
2.3	<i>Large Language Model</i>	31
2.3.1	Fundamentos e Evolução dos Modelos de Linguagem	31
2.3.2	Modelos de Linguagem Pequenos (<i>SLMs</i>) vs. Grandes (<i>LLMs</i>)	32
2.3.3	Arquiteturas de Modelos de Linguagem	33
2.3.4	Arquitetura <i>RAG</i>	34
2.3.5	Protocolos de Comunicação entre Agentes	35
2.3.6	Pré-treinamento e <i>Fine-tuning</i>	36
2.3.7	Aspectos Éticos e Legais	38
2.4	<i>Chatbot</i>	39
2.4.1	Definição e Conceitos Básicos de <i>Chatbots</i>	39
2.4.2	Tipos e Aplicações de <i>Chatbots</i>	40
2.4.3	Componentes e Tecnologias de <i>Chatbots</i>	41
2.4.4	Funcionamento de um Modelo de <i>Chatbot</i>	43
2.4.5	Avaliação de <i>Chatbots</i>	44
2.4.6	Uso do <i>WhatsApp</i> por produtores rurais	45

2.4.7	Diferença entre Assistente Agrícola via <i>WhatsApp</i> e Sistemas Conversacionais Baseados em LLMs	46
2.4.8	Segurança e Proteção de Dados	47
2.4.9	Ferramentas e Tecnologias de Suporte	48
3	ESTADO DA ARTE EM <i>CHATBOTS</i> AGRÍCOLAS	50
4	ARQUITETURA TECNOLÓGICA DO ASSISTENTE INTELIGENTE AGRÍCOLA	56
4.1	Servidor de Aplicação	56
4.2	Biblioteca <i>Baileys</i>	58
4.3	Plataforma N8N	59
4.3.1	Nó <i>POST</i>	60
4.3.2	Nó <i>Code</i>	60
4.3.3	Nó <i>AI Agent</i>	61
4.3.4	Nó <i>Google Gemini Chat Model</i>	62
4.3.5	Nó <i>Simple Memory</i>	62
4.3.6	Nó <i>Get_many_financeiro</i>	63
4.3.7	Nó <i>Create_a_row_financeiro</i>	63
4.3.8	Nó <i>Delete_a_row_financeiro</i>	64
4.3.9	Nó <i>Calculator</i>	64
4.3.10	Nó <i>Get_many_estratégico</i>	65
4.3.11	Nó <i>Create_a_row_estratégico</i>	65
4.3.12	Nó <i>Delete_a_row_estratégico</i>	65
4.3.13	Nó <i>retornaTempo</i>	66
4.3.14	Workflow <i>retornaTempo</i>	66
4.3.15	Nó <i>Supabase Vector Store e Embeddings Google Gemini</i>	66
4.3.16	Workflow de integração do Supabase Vector Store Embeddings Google Gemini	67
4.3.17	Nó <i>retornaURL_financeiro</i>	69
4.3.18	Workflow <i>retornaURL_financeiro</i>	69
4.3.19	Nó <i>retornaURL_estratégico</i>	70
4.3.20	Workflow <i>retornaURL_estratégico</i>	70
4.3.21	Nó HTTP Request	71

5	METODOLOGIA	72
5.1	Tipo de Pesquisa	73
5.2	<i>Design Science Research (DSR)</i>	73
5.2.1	Identificação do problema	74
5.2.2	Definição dos objetivos da solução	75
5.2.3	Construção do artefato	76
5.2.4	Avaliação da solução	77
5.2.5	Comunicação dos resultados	78
6	RESULTADOS	79
6.1	Avaliações Quantitativas	79
6.1.1	Avaliação dos Dados Climáticos	79
6.1.1.1	Protocolo experimental, instrumentação e processamento dos dados	80
6.1.2	Avaliação dos Dados Financeiros e Estratégicos	83
6.1.2.1	Métricas adotadas para avaliação das operações do <i>chatbot</i>	83
6.1.3	Avaliação dos Dados Operacionais	86
6.1.3.1	Métricas adotadas para avaliação das respostas do <i>chatbot</i>	86
6.1.3.2	Resultados obtidos	87
6.2	Avaliação Qualitativa	88
6.2.1	Questionário Avaliativo — Avaliação Humana	88
6.2.2	Resultados da Avaliação Humana	89
6.2.3	Resultados qualitativos	91
6.3	Demonstração do Assistente Inteligente em Operação	91
7	CONCLUSÃO	94
7.1	Conclusão	94
7.2	Trabalhos Futuros	95
	REFERÊNCIAS	97

1 INTRODUÇÃO

A agricultura é um dos setores mais estratégicos para a humanidade, desempenhando papel central no fornecimento de alimentos, matérias-primas e insumos para diversas cadeias produtivas. Contudo, esse setor enfrenta desafios crescentes impostos por fatores como o crescimento populacional, as mudanças climáticas, a escassez de recursos hídricos e a necessidade de práticas ambientalmente sustentáveis (Food and Agriculture Organization of the United Nations, 2019). Nesse contexto, a busca por soluções inovadoras que aliem produtividade, eficiência e sustentabilidade tem levado ao desenvolvimento de tecnologias capazes de transformar profundamente a maneira como a produção agrícola é conduzida e gerenciada (Gupta; Pal, 2025). Entre essas soluções, a Agricultura Inteligente destaca-se como um paradigma fundamental, uma vez que promove o manejo localizado e baseado em dados, permitindo que insumos, como água e fertilizantes, sejam aplicados de forma racional e no momento adequado. Essa abordagem depende, de forma crescente, da coleta de dados ambientais e agronômicos por meio de sensores distribuídos, estações meteorológicas e dispositivos de *Internet of Things* (IoT). A incorporação da Inteligência Artificial (IA) a esse ecossistema tecnológico amplia substancialmente suas possibilidades, permitindo desde a fusão de dados heterogêneos até a geração de recomendações mais precisas para a tomada de decisão em campo.

Avanços recentes têm mostrado que a integração entre IA e *IoT* está evoluindo para sistemas mais descentralizados e eficientes. O *framework Farm-LightSeek*, por exemplo, ilustra o potencial de arquiteturas *edge-centric* que utilizam *Large Language Models* (LLMs), ou Modelos de Linguagem de Grande Escala, leves, capazes de processar dados multimodais (imagens, condições climáticas e localização geoespacial) diretamente em dispositivos de borda. Essa abordagem não apenas reduz a dependência da conectividade contínua com a nuvem, como também garante maior eficiência energética e menor latência na análise, aspectos cruciais para áreas rurais com infraestrutura limitada (Jiang *et al.*, 2025).

Além da capacidade de análise e previsão, a comunicação eficiente entre agricultores e sistemas digitais representa um fator determinante para a adoção tecnológica. Nesse ponto, os *chatbots* surgem como interfaces acessíveis e inclusivas, capazes de traduzir a complexidade da IA em interações simplificadas em linguagem natural. Nos últimos anos, a evolução dos *chatbots* tradicionais baseados em regras para agentes conversacionais impulsionados por *LLMs* ampliou significativamente seu potencial de uso em contextos agrícolas. O *AgroLLM*, por

exemplo, alcançou 93% de precisão ao integrar modelos de linguagem com mecanismos de recuperação de conhecimento (*Retrieval-Augmented Generation*), permitindo interações multilíngues e altamente contextualizadas para assistência ao agricultor (Samuel *et al.*, 2025). Embora esse trabalho não utilize plataformas de mensagens instantâneas, seus resultados evidenciam o potencial de agentes conversacionais avançados no suporte direto à tomada de decisão em tempo real. Diferentemente dessa abordagem, este estudo propõe a integração desse tipo de tecnologia ao *WhatsApp*, plataforma amplamente difundida no meio rural brasileiro, com o objetivo de tornar o acesso às informações mais inclusivo e prático para pequenos e médios produtores.

No contexto agrícola brasileiro, o *WhatsApp* consolidou-se como a principal ferramenta de comunicação digital entre produtores. Pesquisas nacionais apontam que a ampla penetração de *smartphones* no meio rural, somada à simplicidade de uso do aplicativo, favorece sua adoção para finalidades diversas, que vão desde a troca de informações técnicas até a realização de transações comerciais. De acordo com a 8ª Pesquisa ABMRA, 94% dos produtores possuem *smartphone* e 76% já utilizam o *WhatsApp* como canal para realizar negócios (Salles, 2021). Evidências regionais também confirmam essa tendência, como demonstrado em Minas Gerais, onde o *WhatsApp* desponta como a mídia social mais utilizada semanalmente por agricultores (Oliveira *et al.*, 2024). Esses indicadores revelam que a adoção do *WhatsApp* como interface de interação está alinhada ao cotidiano dos agricultores, o que potencializa a aceitação da solução proposta e amplia sua aplicabilidade prática.

A aplicação de interfaces conversacionais não se limita à disponibilização de informações. Estudos recentes evidenciam que *LLMs* podem ser empregados como tradutores entre comandos em linguagem natural e sistemas robóticos autônomos, ampliando a automação no campo. A pesquisa *Leveraging LLMs for Mission Planning in Precision Agriculture* demonstra como instruções simples fornecidas por agricultores podem ser interpretadas e transformadas em planos de missão executáveis por robôs agrícolas por meio da integração com o *middleware ROS2*. Essa abordagem não apenas ilustra a maturidade crescente da IA aplicada à agricultura, como também aponta para o futuro da interação humano-máquina em cenários agrícolas inteligentes (Zuzuárregui; Carpin, 2025).

Em paralelo, agentes físicos autônomos vêm sendo desenvolvidos como extensões do ecossistema digital agrícola. O *rover* AGRO é um exemplo emblemático: trata-se de uma plataforma autônoma equipada com sensores e visão computacional, capaz de coletar dados agronômicos de forma contínua e independente, integrando-se a sistemas de análise baseados

em IA. Esse tipo de solução evidencia como a robótica agrícola, quando combinada a agentes inteligentes, pode potencializar a coleta de dados, reduzir a dependência de mão de obra e aumentar a precisão das práticas de manejo (Ghumman *et al.*, 2025).

Observa-se que a convergência entre Agricultura Inteligente, *IoT*, Inteligência Artificial e *chatbots* representa não apenas um avanço tecnológico, mas também uma oportunidade de transformação social. O uso de plataformas acessíveis, como aplicativos de mensagens instantâneas, possibilita que pequenos e médios produtores com restrições de infraestrutura ou de conhecimento técnico tenham acesso a informações estratégicas para a gestão de suas propriedades. Dessa forma, essas soluções contribuem para a democratização do acesso às tecnologias digitais no campo, promovendo maior sustentabilidade, resiliência e redução das desigualdades no setor agrícola.

Pesquisas que analisam o comportamento informacional do produtor rural demonstram que a tomada de decisão no campo depende fortemente do acesso a dados climáticos, financeiros, operacionais e estratégicos. Relatórios internacionais apontam que os agricultores têm buscado integrar informações como previsões climáticas, custos de produção e indicadores operacionais para planejar suas atividades com maior precisão, como destacado pela PwC ao evidenciar o papel central dos dados na otimização das práticas agrícolas (PwC Brasil, 2024). De forma complementar, estudos conduzidos pela McKinsey indicam que produtores, especialmente os de pequena e média escala, dependem cada vez mais de informações meteorológicas e operacionais para reduzir riscos, adaptar rotinas e fortalecer a resiliência produtiva frente às mudanças climáticas (McKinsey & Company, 2022). Nesse contexto, a disponibilização integrada desses tipos de dados por meio de um agente conversacional torna-se uma solução alinhada às necessidades reais dos agricultores.

1.1 Motivação

A motivação deste trabalho decorre da ausência, por parte de muitos agricultores, de práticas estruturadas para o registro e análise integrada de informações essenciais à gestão da lavoura. Dados climáticos, financeiros, estratégicos e operacionais costumam permanecer dispersos ou pouco sistematizados, comprometendo o planejamento e a tomada de decisões fundamentadas (PwC Brasil, 2024).

Embora já existam plataformas capazes de fornecer dados climáticos confiáveis em tempo real, elas operam de forma isolada e não oferecem uma visão consolidada do cultivo. O mesmo se observa em relação aos dados financeiros e estratégicos, frequentemente negligenciados em registros organizados, bem como aos dados operacionais do manejo diário, incluindo irrigação, adubação e colheita, que raramente são documentados de forma sistemática (Gupta; Pal, 2025).

Nesse cenário, a agricultura inteligente, em consonância com os princípios da agricultura 5.0, surge como paradigma promissor para integrar múltiplas fontes de informação. O uso de um *chatbot* no *WhatsApp*, aliado a modelos de inteligência artificial, permite centralizar dados heterogêneos, interpretá-los de forma acessível e gerar recomendações personalizadas. Assim, esta pesquisa busca fomentar uma cultura de gestão agrícola orientada por dados, promovendo eficiência produtiva, sustentabilidade e autonomia para pequenos e médios produtores (Jiang *et al.*, 2025).

1.2 Justificativa

A implementação de um sistema de inteligência artificial na agricultura, com foco na coleta e análise integrada de dados climáticos, estratégicos, financeiros e operacionais, torna-se essencial diante dos desafios globais que impactam o setor. O crescimento contínuo da população mundial exige uma produção de alimentos mais eficiente e produtiva, ao mesmo tempo em que a disponibilidade de recursos naturais, como água e energia, torna-se cada vez mais restrita (Food and Agriculture Organization of the United Nations, 2019). Nesse cenário, a agricultura inteligente, em consonância com os princípios da agricultura 5.0, surge como uma abordagem inovadora para otimizar o uso de insumos, reduzir desperdícios e maximizar a produtividade (Gupta; Pal, 2025).

Além do aumento da eficiência produtiva, a sustentabilidade ambiental é um fator crítico na agricultura contemporânea, dado seu impacto sobre os ecossistemas globais. A adoção de sistemas digitais apoiados por *IoT* e inteligência artificial permite um controle mais preciso da aplicação de insumos, minimizando desperdícios e reduzindo a contaminação do solo e da água. Tais tecnologias viabilizam práticas agrícolas mais sustentáveis, promovendo o uso racional de fertilizantes e defensivos, ao mesmo tempo em que reduzem custos operacionais e ampliam a competitividade dos produtores (Jiang *et al.*, 2025).

Outro aspecto fundamental é o suporte à tomada de decisão, possibilitado pelo monitoramento contínuo e em tempo real de variáveis ambientais, financeiras e operacionais. Essas informações permitem antecipar e mitigar os impactos de condições climáticas adversas, pragas e doenças, reduzindo perdas e otimizando as operações no campo. Além disso, a integração de dados históricos possibilita uma gestão mais estratégica da lavoura, permitindo o planejamento de safras futuras com base em análises de desempenho, custos e rentabilidade (PwC Brasil, 2024).

Por fim, a aplicação de inteligência artificial e *IoT* na agricultura representa um campo promissor de inovação tecnológica, impulsionando a modernização do setor e fortalecendo sua competitividade em um mercado global cada vez mais exigente. Assim, este trabalho justifica-se pela necessidade de enfrentar os desafios atuais da agricultura, promovendo soluções tecnológicas que contribuam para práticas mais eficientes, sustentáveis e economicamente viáveis (Samuel *et al.*, 2025).

1.3 Objetivo Geral

Este trabalho tem como objetivo geral conceber, desenvolver e validar um sistema integrado de apoio à gestão agrícola, baseado em um *chatbot* no *WhatsApp*, que funcione como interface acessível e inclusiva para pequenos e médios produtores.

O sistema terá como finalidade organizar, armazenar e interpretar dados climáticos, financeiros, estratégicos e operacionais relacionados à produção agrícola, possibilitando a geração de análises e recomendações personalizadas. Com isso, pretende-se fomentar uma cultura de gestão orientada por dados, promovendo maior eficiência produtiva, sustentabilidade e autonomia no planejamento e execução das atividades no campo.

1.4 Objetivos Específicos

Para alcançar o objetivo geral proposto, este trabalho tem como objetivos específicos:

- a) mapear e estruturar os principais dados relevantes à gestão agrícola, abrangendo informações climáticas, financeiras, estratégicas e operacionais, com ênfase no cultivo do café;

- b) projetar e desenvolver um sistema de apoio à decisão, baseado em um agente conversacional integrado ao *WhatsApp*, capaz de centralizar, organizar e disponibilizar esses dados de forma acessível;
- c) aplicar técnicas de inteligência artificial para interpretar os dados coletados e gerar recomendações que auxiliem o planejamento e a execução de práticas agrícolas mais eficientes e sustentáveis;
- d) validar o sistema desenvolvido por meio de avaliação quantitativa e qualitativa, de modo a aferir sua eficácia e contribuição ao processo de tomada de decisão agrícola;
- e) promover a inclusão tecnológica, disponibilizando aos pequenos e médios produtores rurais uma ferramenta acessível que contribua para a autonomia na gestão da lavoura e para a adoção de práticas mais inteligentes.

1.5 Organização do Trabalho

Este trabalho está estruturado em sete capítulos que apresentam de forma progressiva a motivação, os fundamentos teóricos, a metodologia adotada, o desenvolvimento da solução e sua avaliação. O Capítulo 1 introduz a pesquisa, destacando a motivação, a contextualização do problema, a justificativa e os objetivos. Em seguida, o Capítulo 2 aborda os conceitos centrais relacionados à agricultura inteligente, à agricultura 5.0, às tecnologias de Internet das Coisas (*IoT*) aplicadas ao campo e ao uso de inteligência artificial no suporte à tomada de decisão agrícola. O Capítulo 3 discute trabalhos relacionados, evidenciando iniciativas anteriores que exploram dados climáticos, financeiros, estratégicos e operacionais, situando a contribuição deste estudo em relação ao estado da arte. No Capítulo 4, detalha-se a arquitetura proposta para o sistema, baseada em um *chatbot* integrado ao *WhatsApp*, responsável por centralizar, organizar e interpretar diferentes tipos de dados agrícolas. O Capítulo 5 apresenta a metodologia utilizada para implementação e avaliação do sistema, incluindo a coleta e integração de dados com ênfase no cultivo do café. O Capítulo 6 analisa os resultados obtidos, demonstrando a eficácia da solução na organização das informações e no suporte à tomada de decisão. Por fim, o Capítulo 7 reúne as conclusões e trabalhos futuros, destacando as contribuições da pesquisa, suas limitações e potenciais desdobramentos para aprimoramento e ampliação do sistema.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta os fundamentos teóricos que embasam a pesquisa, abordando conceitos e tecnologias essenciais para a compreensão do tema em estudo. Inicialmente, busca explorar a Agricultura Inteligente, destacando sua evolução, benefícios, desafios e seu papel na modernização do setor agrícola. Em seguida, discutem-se os princípios da Inteligência Artificial (IA), desde seus conceitos fundamentais até suas aplicações práticas, com ênfase nos Large Language Models (LLMs). Por fim, destaca-se os *chatbots*, analisando sua definição, arquiteturas, componentes tecnológicos e aplicações em diversos setores.

2.1 Agricultura Inteligente

A agricultura global enfrenta um desafio sem precedentes: garantir a segurança alimentar para uma população mundial que deve atingir 9 bilhões de pessoas em 2050, em um contexto de crescente escassez de recursos naturais, como terra e água, e de impactos climáticos cada vez mais severos (Massruha, 2023). Projeções indicam que a produção agrícola precisará aumentar em pelo menos 70% para atender a essa demanda. Nesse cenário, a transformação digital emerge como um fator essencial para modernizar toda a cadeia produtiva, promovendo um modelo mais eficiente, sustentável e resiliente (Junior; Henkes, 2023).

A convergência de tecnologias inovadoras, como inteligência artificial (IA), Internet das Coisas (*IoT*) e robótica, vem remodelando a produção de alimentos e o gerenciamento de recursos. Essa abordagem, alinhada aos Objetivos de Desenvolvimento Sustentável (ODS) da ONU, busca otimizar operações, economizar recursos e proteger o meio ambiente (Nascimento; Bálamo, 2023).

Nesse contexto, o presente trabalho contribui para esse ecossistema ao propor um agente conversacional baseado em inteligência artificial, integrado ao *WhatsApp*, capaz de organizar e interpretar dados agrícolas provenientes de fontes como estações meteorológicas e sensores *IoT*. Essa abordagem busca tornar os benefícios da agricultura inteligente mais acessíveis a pequenos e médios produtores.

Este referencial teórico explora a evolução da agricultura até o conceito de Agricultura 5.0, destacando suas tecnologias habilitadoras, benefícios, desafios e perspectivas futuras (Saiz-Rubio; Rovira-Más, 2020).

2.1.1 Evolução da Agricultura: da Tração Animal à Agricultura 5.0

A trajetória da agricultura é marcada por sucessivas revoluções tecnológicas, cada uma promovendo aumentos significativos de produtividade e eficiência. No início do século XX, a produção agrícola era caracterizada pelo trabalho manual intensivo, com auxílio da tração animal, resultando em baixa produtividade e caráter predominantemente de subsistência (Massruha, 2023).

Com a Revolução Industrial e a Revolução Verde, surgiram métodos científicos e novas tecnologias, como mecanização, sementes melhoradas e fertilizantes industrializados, aumentando significativamente a produtividade. No Brasil, a criação da Embrapa em 1973 representou um marco no desenvolvimento de tecnologias adaptadas ao clima tropical (Massruha, 2023).

A Agricultura 3.0, introduziu o uso de dados para gerenciar a variabilidade no campo, aplicando insumos de forma precisa quando e onde eram realmente necessários, com auxílio de *GPS*, sensores e imagens de satélite (Nascimento; Bálsamo, 2023). Em seguida, a Agricultura 4.0, também chamada de Fazenda Inteligente, integrou telemática e análise de dados em larga escala, utilizando sensores, *drones* e *IoT* para fornecer informações estratégicas e operacionais em tempo real. A etapa seguinte da evolução promove operações autônomas e sistemas de suporte à decisão inteligentes, reduzindo a intervenção direta do agricultor (Saiz-Rubio; Rovira-Más, 2020).

2.1.2 Características da Agricultura 5.0

O principal avanço dessa fase é a automação inteligente, que permite que máquinas executem tarefas repetitivas e fisicamente exigentes, aumentando a eficiência do trabalho humano. Atividades como capina, pulverização e colheita podem ser realizadas com mínima supervisão, transferindo ao agricultor o papel de gestor de sistemas e frotas de equipamentos inteligentes que otimizam a produção em tempo real (Saiz-Rubio; Rovira-Más, 2020).

O ciclo de gerenciamento é contínuo e inicia na lavoura, cuja variabilidade natural fundamenta todas as decisões. Em seguida, os dados são coletados por sensores embarcados em veículos terrestres, *drones* e satélites. Esses dados são processados por algoritmos de IA, que geram ordens de ação executadas por equipamentos avançados, como pulverizadores e colheitadeiras com tecnologia de taxa variável (*VRT*) (Saiz-Rubio; Rovira-Más, 2020).

A implementação desse modelo é viabilizada pela combinação de tecnologias como robótica e sistemas autônomos, inteligência artificial e aprendizado profundo, sensoriamento remoto e *IoT*, *Big Data* e sistemas de suporte à decisão. Veículos não tripulados, como o *VineScout*, realizam monitoramento e coleta de dados em vinhedos, enquanto soluções comerciais, como o *Oz* e o pulverizador autônomo *GUSS*, executam tarefas de manejo de campo (Saiz-Rubio; Rovira-Más, 2020).

O assistente agrícola proposto neste trabalho se alinha a essa lógica da Agricultura 5.0, ao empregar IA e integração digital para automatizar a coleta e organização de informações climáticas, financeiras e operacionais, oferecendo suporte à tomada de decisão de forma acessível via interface conversacional.

Algoritmos de aprendizado de máquina e redes neurais profundas processam grandes volumes de dados para reconhecimento de padrões, classificação de doenças e contagem de plantas (Jorge *et al.*, 2023). Sensores conectados transformam cada elemento da fazenda em fonte de dados, abrangendo desde monitoramento remoto por satélite até coleta proximal no solo (Nascimento; Bálamo, 2023). O uso de *Big Data* e computação em nuvem possibilita armazenar e analisar volumes massivos de informações, enquanto sistemas de suporte à decisão fornecem recomendações estratégicas e operacionais.

2.1.3 Benefícios, Desafios e Perspectivas

A adoção da Agricultura 5.0 oferece uma série de benefícios estratégicos e operacionais, resultantes do uso integrado de tecnologias digitais, automação e análise de dados avançada. Entre esses benefícios destacam-se o aumento da produtividade e da rentabilidade, a utilização mais eficiente de recursos naturais, a promoção da sustentabilidade ambiental, maior resiliência a pragas e eventos de estresse hídrico, bem como soluções para mitigar a escassez de mão de obra qualificada (Junior; Henkes, 2023).

Entretanto, a adoção dessas tecnologias ainda enfrenta desafios significativos, incluindo elevados custos iniciais, infraestrutura limitada e conectividade insuficiente em áreas rurais, necessidade de capacitação técnica, falta de padronização de dados e sistemas, além de questões éticas e de governança relacionadas à privacidade e segurança das informações (Jorge *et al.*, 2023).

A consolidação desse modelo depende de políticas que incentivem jovens agricultores familiarizados com tecnologias digitais, bem como da criação de ecossistemas de inovação que promovam a colaboração entre setor público, instituições de pesquisa, *startups* e produtores. A automação e a inteligência artificial já estão na agenda dos principais fabricantes de equipamentos, indicando que representam o próximo passo lógico para um sistema alimentar global produtivo, resiliente e sustentável (Junior; Henkes, 2023).

2.2 Inteligência Artificial

A Inteligência Artificial (IA) é um campo interdisciplinar que visa desenvolver sistemas capazes de executar tarefas que, até recentemente, exigiam inteligência humana. Sua evolução reflete avanços significativos na capacidade de máquinas realizarem inferência, aprendizado e tomada de decisão. Com aplicações que vão da indústria à gestão pública, a IA tem potencial para transformar práticas, automatizar processos e gerar novos paradigmas de interação entre humanos e máquinas (McCarthy *et al.*, 2007).

Com aplicações que vão da indústria à gestão pública, a IA tem potencial para transformar práticas, automatizar processos e gerar novos paradigmas de interação entre humanos e máquinas. No contexto deste estudo, a inteligência artificial é aplicada como núcleo do agente conversacional, responsável por compreender solicitações em linguagem natural e gerar respostas contextualizadas com base em dados agrícolas armazenados, reforçando o papel da IA como mediadora entre dados complexos e decisões práticas no campo (McCarthy *et al.*, 2007).

2.2.1 Definição e Conceitos Fundamentais

A Inteligência Artificial (IA) teve início nos anos 1950, sendo formalmente nomeada em 1956 por John McCarthy na conferência de Dartmouth, marco inaugural da área (McCarthy *et al.*, 2007). Nas décadas seguintes, evoluiu com o desenvolvimento de sistemas baseados em regras, como os primeiros sistemas especialistas, mas enfrentou limitações técnicas que culminaram no chamado “inverno da IA” (Chen; Yuan, 2021). O cenário começou a mudar nos anos 1980, com o surgimento das redes neurais artificiais e o avanço da capacidade computacional.

Nos anos 1990, a IA se consolidou como disciplina aplicada, destacando-se com métodos conexionistas e aprendizados supervisionados, como exemplificado pela vitória do Deep

Blue sobre Garry Kasparov em 1997 (Dhar, 2024). A partir dos anos 2000, impulsionada pelo crescimento do Big Data e pelo uso de *GPUs*, a área passou a desenvolver sistemas de alto desempenho em tarefas específicas (Song; Chen, 2021).

Na última década, a IA expandiu-se amplamente em setores como agricultura, saúde e segurança, com a popularização do *deep learning*, redes convolucionais e modelos generativos. Tais avanços têm gerado debates éticos sobre transparência e impactos sociais (Došilović; Brčić; Hlupić, 2018). Assim, a IA demonstra um ciclo contínuo de inovações, tornando-se elemento central da transformação digital contemporânea (Liu *et al.*, 2021).

A Inteligência Artificial (IA) é um campo multidisciplinar voltado ao desenvolvimento de sistemas computacionais capazes de simular ou ampliar capacidades cognitivas humanas. Embora não exista uma definição única e consensual, a IA pode ser compreendida como a ciência e a engenharia de criar máquinas inteligentes, ou seja, sistemas que realizam tarefas que tradicionalmente requereriam inteligência humana. Segundo (McCarthy *et al.*, 2007), a IA busca desenvolver métodos e técnicas que permitam a computadores realizar tarefas complexas como raciocínio, percepção, tomada de decisões e aprendizagem.

A dificuldade em estabelecer uma definição única está relacionada à complexidade do próprio conceito de inteligência, que se manifesta em múltiplas dimensões. Para (Fetzer, 1990), inteligência pode ser definida como a capacidade de alcançar objetivos em diferentes ambientes, algo observado em humanos, animais e, em certa medida, em máquinas. Outra perspectiva, mencionada por (Haigh, 2025), considera a IA como o estudo das funções mentais por meio de modelos computacionais, buscando replicar processos cognitivos humanos ou animais. Em uma abordagem mais pragmática, a IA também pode ser vista como o estudo de métodos para que computadores realizem tarefas de forma mais eficiente que humanos, evitando discussões filosóficas sobre a natureza da inteligência.

Alguns conceitos fundamentais sustentam o desenvolvimento da inteligência artificial:

- a) raciocínio (*Reasoning*): refere-se à aplicação da lógica para solucionar problemas e tomar decisões com base nas informações disponíveis. Essa habilidade é essencial para sistemas especialistas e algoritmos de tomada de decisão (Harika *et al.*, 2022);
- b) aprendizagem (*Learning*): relaciona-se à capacidade de adaptação a partir da experiência. Por meio de dados, sistemas de IA ajustam seu comportamento e aprimoram seu desempenho em tarefas específicas, empregando técnicas como aprendizado supervisionado, não supervisionado e por reforço (Harika *et al.*, 2022);

- c) representação do conhecimento (*Knowledge Representation*): diz respeito à estruturação formal do conhecimento, permitindo que a máquina compreenda e manipule informações. São utilizadas lógicas formais, ontologias e outras estruturas que viabilizam a inferência automatizada (Harika *et al.*, 2022);
- d) percepção (*Perception*): envolve a aquisição e interpretação de dados sensoriais, como imagens, sons e sinais. Essa capacidade possibilita que sistemas de IA interajam com o ambiente físico, reconhecendo objetos, interpretando estímulos e respondendo de forma contextualizada (Harika *et al.*, 2022);
- e) agentes (*Agents*): um agente é uma entidade autônoma capaz de perceber o ambiente por meio de sensores e atuar sobre ele por meio de atuadores. Agentes inteligentes podem planejar, aprender e tomar decisões com base em seus objetivos e nas informações percebidas (Chen; Yuan, 2021).

2.2.2 Tecnologias da Inteligência Artificial

As tecnologias que sustentam a Inteligência Artificial (IA) evoluíram consideravelmente ao longo das últimas décadas, abrangendo desde métodos simbólicos até técnicas baseadas em aprendizado de máquina. Dentre essas, destaca-se o *machine learning*, que permite a construção de modelos a partir da análise de dados, sem que sejam explicitamente programadas todas as regras (Harika *et al.*, 2022). Essa abordagem inclui técnicas supervisionadas, não supervisionadas e por reforço, cada uma com aplicações específicas em classificação, agrupamento e tomada de decisão sequencial.

Outra tecnologia fundamental é o *deep learning*, um subconjunto do aprendizado de máquina que utiliza redes neurais artificiais com múltiplas camadas para extrair representações hierárquicas dos dados. Esse método tem obtido resultados expressivos em áreas como visão computacional, reconhecimento de fala e processamento de linguagem natural (Chen; Yuan, 2021).

Além disso, o raciocínio automatizado, os sistemas especialistas e a representação do conhecimento continuam relevantes em domínios onde a interpretabilidade e a lógica simbólica são indispensáveis (Yun, 2022). A combinação entre abordagens simbólicas e conexionistas também tem sido explorada, visando unir a robustez estatística com a transparência lógica.

As tecnologias da IA não se limitam aos algoritmos: envolvem também infraestrutura computacional, como uso intensivo de *GPUs*, *frameworks* de desenvolvimento (*TensorFlow*, *PyTorch*) e ambientes de simulação e testes, que viabilizam o treinamento em larga escala e a avaliação de modelos em cenários diversos. Esse ecossistema tecnológico tem permitido a aplicação da IA em setores cada vez mais amplos da sociedade.

2.2.3 Impacto da IA na Gestão Administrativa

A aplicação da Inteligência Artificial (IA) na gestão administrativa tem transformado significativamente a forma como instituições públicas e privadas conduzem seus processos internos. Ferramentas baseadas em IA têm contribuído para a automação de tarefas rotineiras, como triagem de documentos, análise de dados e respostas a demandas repetitivas, permitindo maior agilidade e redução de erros (Harika *et al.*, 2022).

Um dos principais benefícios é o suporte à tomada de decisão, viabilizado por sistemas capazes de identificar padrões em grandes volumes de dados e gerar indicadores gerenciais para gestores. Esses sistemas auxiliam na alocação de recursos, planejamento estratégico e detecção de anomalias, promovendo maior eficiência e transparência administrativa (Yun, 2022).

Além disso, tecnologias como agentes inteligentes e sistemas preditivos vêm sendo empregadas para melhorar o relacionamento com o público, como no atendimento automatizado por meio de *chatbots* e assistentes virtuais (Chen; Yuan, 2021). Tais soluções não apenas otimizam o tempo dos servidores, mas também ampliam o acesso da população a serviços públicos.

A incorporação da IA na gestão requer atenção especial a aspectos éticos, à privacidade e à qualidade dos dados. É fundamental assegurar que os sistemas sejam auditáveis, imparciais e alinhados aos princípios da administração pública, sobretudo em decisões que impactam diretamente cidadãos e servidores (McCarthy *et al.*, 2007).

2.2.4 Limitações Técnicas e Desafios Éticos da Inteligência Artificial

Apesar dos avanços significativos da Inteligência Artificial (IA), sua adoção em larga escala ainda enfrenta diversos desafios. Um dos principais refere-se à qualidade e à disponibilidade dos dados. Sistemas de IA dependem de grandes volumes de dados para treinamento,

e a ausência de dados representativos ou a presença de viés pode comprometer a equidade e a precisão dos resultados (Harika *et al.*, 2022).

Outro desafio está na interpretabilidade dos modelos, especialmente os baseados em técnicas de aprendizado profundo. Muitas vezes, tais modelos são considerados “caixas-pretas”, dificultando a compreensão de como as decisões são tomadas. Isso é particularmente problemático em contextos sensíveis, como saúde, justiça ou administração pública, nos quais a transparência é essencial (Chen; Yuan, 2021).

Além disso, a IA ainda apresenta limitações em tarefas que exigem bom senso, conhecimento de mundo ou julgamento ético. Sistemas inteligentes tendem a ser altamente especializados e apresentam dificuldades na adaptação a contextos fora dos padrões previamente aprendidos (Yun, 2022).

Por fim, aspectos regulatórios e éticos também representam barreiras. A definição de diretrizes que assegurem responsabilidade, proteção de dados pessoais e respeito aos direitos fundamentais é um requisito para que a IA seja adotada de forma segura e confiável (McCarthy *et al.*, 2007). Esses desafios evidenciam que, embora promissora, a IA demanda atenção contínua para garantir seu desenvolvimento e aplicação de forma responsável e sustentável.

2.3 Large Language Model

Os Large Language Models (LLMs) apoiam-se na arquitetura *Transformer*, que processa sequências de texto de modo paralelo e captura relações de longo alcance entre palavras. Esses modelos passam por duas etapas principais: o pré-treinamento em grandes bases de texto não rotuladas e o ajuste fino em tarefas específicas. O que lhes confere a capacidade de gerar e interpretar linguagem com alta precisão. Aplicações como tradução automática, assistentes de diálogo e análise de sentimentos evidenciam seu potencial, embora desafios relacionados ao alto custo computacional, consumo energético e vieses nos dados ainda demandem soluções adequadas (Hrytsyna; Alves, 2024).

2.3.1 Fundamentos e Evolução dos Modelos de Linguagem

Os primeiros Modelos de Linguagem Natural baseavam-se em estatísticas de n-gramas, estimando a probabilidade de ocorrência de sequências de palavras em grandes coleções tex-

tuais (Ciullo, 2024). Embora simples, esses modelos apresentavam desempenho limitado ao lidar com dependências de longo alcance e variações contextuais (Zhuang *et al.*, 2024). Para contornar essas restrições, nas décadas de 1990 e 2000, emergiram redes neurais recorrentes (*RNNs*) e modelos profundos, como as *Long Short-Term Memory (LSTM)* e as *Gated Recurrent Units (GRU)*. Essas arquiteturas introduziram mecanismos capazes de preservar informações relevantes por períodos mais longos nas sequências, o que permitiu aprender representações de maneira mais robusta e reduzir a necessidade de engenharia manual de características (*features*) (Bengio *et al.*, 2003).

O mecanismo de atenção, introduzido para ponderar a relevância de diferentes partes da entrada, abriu caminho para a arquitetura *Transformer*, que processa sequências em paralelo e aprende representações contextuais *multilayer* sem dependência estrita da ordem temporal (Farooq; Aziz; Ullah, 2024). Modelos como BERT e GPT exemplificam esse avanço, combinando pré-treinamento em grandes bases de texto não rotuladas com ajuste fino em tarefas específicas, o que elevou substancialmente o desempenho em múltiplas aplicações de Processamento de Linguagem Natural (PLN) (Zhuang *et al.*, 2024). Em contraponto, os Pequenos Modelos de Linguagem (*SLMs*) oferecem versões mais leves e eficientes, mantendo desempenho competitivo em domínios restritos com menor custo computacional (Örpek; Tural; Destan, 2024).

Essa evolução demonstra uma trajetória de consolidação teórica e prática: de estatísticas simples a arquiteturas profundas e sistemas de pré-treinamento massivo, os Modelos de Linguagem continuam a se aprimorar, equilibrando complexidade, interpretabilidade e eficiência (Vaswani *et al.*, 2017).

2.3.2 Modelos de Linguagem Pequenos (*SLMs*) vs. Grandes (*LLMs*)

Os Large Language Models (*LLMs*), como ChatGPT e GPT-3, distinguem-se pela elevada contagem de parâmetros (da ordem de bilhões) e pelo pré-treinamento em amplas coleções de textos não rotulados, o que lhes confere excelência em tarefas de geração e compreensão de linguagem (Farooq; Aziz; Ullah, 2024). Em contraste, os Pequenos Modelos de Linguagem (*SLMs*) são projetados com um número reduzido de parâmetros, permitindo treinamento e implantação em infraestruturas com recursos computacionais limitados, ainda que apresentem desempenho inferior em cenários de alto volume de dados ou complexidade textual.

Essa distinção reflete um equilíbrio entre qualidade e eficiência: os Large Language Models (LLMs) exigem maior investimento computacional e consumo energético, mas oferecem fluência e versatilidade superiores; por outro lado, os Pequenos Modelos de Linguagem (*SLMs*) favorecem aplicações que demandam agilidade, menores requisitos de hardware e menor exigência de infraestrutura, além de facilitar aspectos relativos à privacidade e à sustentabilidade. A seleção adequada entre *SLMs* e *LLMs* deve considerar os objetivos, as restrições de infraestrutura e as metas de sustentabilidade de cada projeto (Örpek; Tural; Destan, 2024).

A arquitetura desenvolvida neste trabalho integra um modelo de linguagem de grande porte com mecanismos de recuperação de conhecimento (*RAG*), permitindo que o *chatbot* interprete dados agrícolas e forneça respostas contextualizadas, fortalecendo o papel dos *LLMs* como instrumentos de apoio à decisão na agricultura inteligente.

2.3.3 Arquiteturas de Modelos de Linguagem

As primeiras arquiteturas de Modelos de Linguagem (*ML*) baseavam-se em redes recorrentes (*RNNs*) e variantes como *LSTMs* e *GRUs*, que armazenam informações sequenciais em estados ocultos. Apesar de capturar dependências temporais, essas estruturas sofriam com paralelização limitada e alto custo computacional em sequências longas, restringindo sua escalabilidade (Farooq; Aziz; Ullah, 2024).

O mecanismo de atenção (*multi-head attention*), introduzido na arquitetura *Transformer* por (Vaswani *et al.*, 2017), permitiu calcular simultaneamente ponderações entre todos os elementos de entrada, viabilizando processamento paralelo e aprendizagem de contextos de longo alcance em múltiplas camadas. Essa inovação superou as limitações das arquiteturas anteriores.

A arquitetura *Transformer* combina módulos de auto-atenção com camadas *feedforward* posicionais, interligados por normalizações e atalhos residuais, conferindo profundidade e estabilidade ao treinamento (Vaswani *et al.*, 2017). Modelos baseados nessa estrutura, como BERT e GPT, alcançaram ganhos expressivos em tarefas de reconhecimento de entidades nomeadas e extração de relações (Zhuang *et al.*, 2024).

Para lidar com sequências muito longas e otimizar o uso de memória, surgiram variantes que adotam atenção local, mecanismos de janela deslizante dinâmica e esquemas hierárquicos, exemplificados por *Reformer* e *Longformer*. Essas extensões mantêm a eficácia do mecanismo

de atenção, ajustando a carga computacional às necessidades específicas de cada aplicação (Warudkar; Jalit, 2024).

A evolução das arquiteturas de modelos de linguagem reflete um esforço contínuo da comunidade científica e tecnológica para equilibrar a necessidade de escalabilidade, permitindo a manipulação de grandes volumes de dados e tarefas complexas, com a demanda por eficiência computacional, de modo a viabilizar aplicações práticas em diferentes contextos e ambientes de processamento (Liao; Vaughan, 2024).

Desde sua introdução, a arquitetura *Transformer* tem sido amplamente adotada como base para modelos de linguagem de última geração, incluindo BERT, GPT, T5 e RoBERTa, evidenciando sua versatilidade e robustez. No entanto, apesar dos avanços, desafios persistem, como o custo computacional elevado para lidar com sequências extensas, o que motivou a pesquisa em variantes mais eficientes, como *Linformer*, *Performer* e *FlashAttention*. Além do domínio textual, o *Transformer* tem sido aplicado com sucesso em tarefas de visão computacional, bioinformática e processamento de sinais, consolidando-se como um paradigma unificador no aprendizado profundo (Vaswani *et al.*, 2017).

2.3.4 Arquitetura RAG

A arquitetura de Geração Aumentada por Recuperação (*RAG*) representa uma abordagem avançada em Processamento de Linguagem Natural (PLN), ao integrar a capacidade de geração dos Large Language Models (LLMs) com mecanismos eficientes de recuperação de informações externas. Esse modelo híbrido visa superar limitações intrínsecas aos *LLMs*, como a estaticidade do conhecimento, as “alucinações” semânticas e o elevado custo de retreinamento, ao permitir o acesso dinâmico a bases de conhecimento atualizadas (Tural; Örpek; Destan, 2024).

A estrutura RAG é composta por dois componentes principais: o *retriever* e o *generator*. O *retriever* localiza documentos relevantes em bases vetoriais externas com base na semelhança semântica, utilizando técnicas de recuperação densa, esparsa ou híbrida (Yookasame; Pramoun; Thewsuan, 2024). Os textos recuperados são combinados com a consulta do usuário para formar um *prompt* contextualizado, que é então processado por um *LLM*, responsável pela geração da resposta final (Meng *et al.*, 2025).

Essa arquitetura apresenta vantagens significativas, como a redução de inconsistências factuais e a melhoria da adaptabilidade do sistema a domínios específicos (como agricultura, saúde ou educação), sem necessidade de retreinamento completo do modelo (Tural; Örpek; Destan, 2024). Além disso, sua integração com estratégias de *fine-tuning* eficiente (PEFT), como LoRA e *Adapter-tuning*, permite adaptações de baixo custo computacional para tarefas especializadas (Meng *et al.*, 2025).

Apesar dos avanços, a eficácia da RAG depende da qualidade dos dados recuperados, da precisão dos métodos de similaridade e da coerência entre os módulos. Variações como *Self-RAG*, *Corrective-RAG* e *Modular-RAG* têm sido propostas para mitigar essas limitações e ampliar o escopo de aplicações (Tural; Örpek; Destan, 2024).

De acordo com (Yookasame; Pramoun; Thewsuwan, 2024) a arquitetura RAG se estabelece como uma solução robusta e flexível para a geração de respostas mais precisas, atualizadas e alinhadas ao contexto da consulta, contribuindo para o desenvolvimento de sistemas de IA mais confiáveis e sustentáveis.

2.3.5 Protocolos de Comunicação entre Agentes

A interoperabilidade entre agentes baseados em *Large Language Models (LLMs)* é essencial para o desenvolvimento de sistemas distribuídos e colaborativos. Assim, destacam-se os protocolos *Model Context Protocol (MCP)* e *Agent-to-Agent Protocol (A2A)*, que buscam padronizar, respectivamente, a interação de agentes com seu ambiente e a comunicação entre múltiplos agentes (Ehtesham *et al.*, 2025).

O MCP, proposto pela Anthropic, estabelece uma interface padronizada baseada em JSON-RPC para que agentes possam acessar contextos dinâmicos e executar ferramentas externas. Sua arquitetura compreende componentes como ferramentas, recursos, instruções e mecanismos de amostragem, permitindo maior controle e flexibilidade na geração de texto e execução de operações (Li; Xie, 2025). Embora eficiente, o protocolo requer medidas de segurança robustas contra ameaças como injeção de comandos e persistência de privilégios (Ehtesham *et al.*, 2025).

Por sua vez, o A2A, desenvolvido pelo Google, visa estruturar a colaboração entre agentes distribuídos. Baseado em conceitos como *Agent Cards* e *Skills*, o protocolo define um fluxo de delegação de tarefas entre agentes cliente e remoto, utilizando JSON-RPC e eventos assíncro-

nos para troca de mensagens e resultados. Sua padronização permite que agentes interoperem independentemente da plataforma ou provedor (Jeong, 2025).

A integração entre MCP e A2A possibilita a criação de ecossistemas de agentes cooperativos: enquanto o MCP fornece acesso a dados e ferramentas locais, o A2A facilita a delegação de tarefas entre agentes especializados, promovendo escalabilidade e flexibilidade operacional. No entanto, essa combinação introduz novos desafios, como vulnerabilidades de segurança compostas, dificuldade de orquestração e interoperabilidade semântica entre tarefas e ferramentas (Li; Xie, 2025).

Limitações inerentes aos próprios LLMs (como a “tirania do prior”, que dificulta a incorporação de dados contextuais recentes) impõem barreiras à eficácia plena dos protocolos, mesmo quando bem integrados (Ghosh, 2025). Superar tais restrições exigirá avanços não apenas na infraestrutura de protocolos, mas também na arquitetura e treinamento dos modelos subjacentes.

2.3.6 Pré-treinamento e *Fine-tuning*

O avanço dos Modelos de Linguagem (MLs) no campo do Processamento de Linguagem Natural (PLN) foi fortemente impulsionado pela estratégia de pré-treinamento seguida do ajuste fino, ou *fine-tuning*. Essa metodologia consiste em, primeiro, treinar um modelo em grandes volumes de dados genéricos para que ele adquira um conhecimento amplo da linguagem. Posteriormente, realiza-se a adaptação para tarefas específicas a partir de conjuntos de dados menores e rotulados (Volkov; Averkin, 2024).

Durante o pré-treinamento, os modelos aprendem representações contextuais da linguagem por meio de métodos de autoaprendizagem supervisionada. Exemplos incluem o BERT (*Bidirectional Encoder Representations from Transformers*) e o GPT (*Generative Pre-trained Transformer*), cujas arquiteturas visam capturar relações semânticas complexas entre palavras. Enquanto o BERT é treinado para compreender o contexto de maneira bidirecional, o GPT é treinado de forma autoregressiva, prevendo *tokens* subsequentes com base em *tokens* anteriores (Zhuang *et al.*, 2024). O objetivo do pré-treinamento é construir uma base sólida de conhecimento linguístico que possa ser reutilizada em diversas tarefas.

Após essa etapa, o modelo passa pelo *fine-tuning*, onde é ajustado com um volume menor de dados rotulados para uma tarefa específica, como classificação de texto, reconheci-

mento de entidades nomeadas ou extração de relações (Avelino *et al.*, 2024). Esse processo é fundamental para adaptar o conhecimento genérico adquirido durante o pré-treinamento às necessidades particulares de uma aplicação, como no caso do BERTimbau, modelo ajustado para o português brasileiro.

No contexto do Reconhecimento de Entidades Nomeadas (*NER*) e da Extração de Relações (*RE*), destaca-se a abordagem PREAnoTe, proposta por (Avelino *et al.*, 2024), que visa facilitar a criação de conjuntos de textos anotados (*corpora*) para o *fine-tuning* de modelos pré-treinados. Devido à escassez de conjuntos de dados anotados manualmente, técnicas como a Supervisão Distante têm sido utilizadas para reduzir custos e agilizar o processo de anotação (Lin *et al.*, 2024).

Além disso, o estudo de (Farooq; Aziz; Ullah, 2024) exemplifica a aplicação do pré-treinamento e ajuste fino na criação de um agente conversacional especializado em energia solar elétrica, utilizando técnicas como PEFT (*Parameter-Efficient Fine-Tuning*) e LoRA (*Low-Rank Adaptation*) para otimizar recursos computacionais.

Técnicas como LoRA e sua extensão quantizada, QLoRA (*Quantized Low-Rank Adaptation*), têm ampliado significativamente a acessibilidade ao processo de *fine-tuning* de Large Language Models (LLMs). A LoRA atua congelando os pesos do modelo pré-treinado e introduzindo matrizes de atualização de baixa dimensão, reduzindo o consumo de memória e o custo computacional. A QLoRA aprimora essa abordagem por meio da quantização das matrizes adaptativas, utilizando representações como o formato NF4 (*NormalFloat 4-bit*), quantização dupla e otimizadores paginados, o que permite a realização do ajuste fino em GPUs com apenas 48 GB de memória, mantendo desempenho competitivo. Entretanto, conforme demonstrado por (Alahmari *et al.*, 2024), embora essas técnicas sejam eficientes em termos de recursos, elas podem comprometer a estabilidade do modelo. O estudo revelou que múltiplas execuções de *fine-tuning* com QLoRA, mesmo sob as mesmas configurações de hardware e software, resultam em desempenhos diferentes, apontando para um problema de repetibilidade nos experimentos. Esse aspecto é particularmente relevante em cenários onde a consistência e a confiabilidade dos resultados são essenciais.

O estudo de (Hrytsyna; Alves, 2024) também discute a importância do *fine-tuning* ao avaliar o alinhamento de LLMs com padrões de julgamento humano. Embora centrado na avaliação, o trabalho evidencia que a capacidade de adaptação dos modelos a novas tarefas, inclusive

com poucos exemplos (*few-shot learning*), depende diretamente das fases de pré-treinamento e ajuste fino.

O paradigma do pré-treinamento e *fine-tuning* revolucionou o desenvolvimento de modelos de linguagem ao combinar o aproveitamento de grandes volumes de dados com a especialização eficiente para tarefas específicas, consolidando-se como pilar central nas pesquisas atuais em PLN (Bandi; Adapa; Kuchi, 2023).

2.3.7 Aspectos Éticos e Legais

O desenvolvimento e a implementação de *Large Language Models (LLMs)* têm provocado intensos debates acerca das implicações éticas e legais de seu uso. À medida que essas tecnologias se tornam mais integradas à sociedade, surgem preocupações quanto à proteção da privacidade, ao respeito à propriedade intelectual e à transparência dos sistemas (Avelino *et al.*, 2024).

Um dos principais desafios éticos reside no risco de vieses algorítmicos. Como os *LLMs* são treinados a partir de grandes volumes de dados disponíveis publicamente, eles podem reproduzir ou até amplificar preconceitos existentes nas informações utilizadas (Ciullo, 2024). Esses vieses podem impactar negativamente decisões automatizadas, como em processos de seleção de candidatos, avaliação de crédito ou sistemas de justiça, comprometendo princípios de equidade e justiça social.

Outro aspecto relevante refere-se à responsabilidade pela produção de conteúdos. Modelos de linguagem são capazes de gerar textos autonomamente, o que levanta questionamentos sobre a autoria, a veracidade das informações e a possibilidade de disseminação de desinformação (Avelino *et al.*, 2024). Estabelecer mecanismos de rastreabilidade e responsabilidade sobre conteúdos gerados por IA é, portanto, essencial para mitigar danos potenciais.

Em termos legais, a proteção de dados pessoais é uma preocupação central. A utilização de *LLMs* deve observar regulamentações como a Lei Geral de Proteção de Dados (LGPD) no Brasil e o Regulamento Geral de Proteção de Dados (GDPR) na União Europeia, que estabelecem diretrizes sobre coleta, armazenamento e processamento de dados sensíveis (Avelino *et al.*, 2024). O descumprimento dessas normas pode acarretar sanções jurídicas e afetar a confiança dos usuários nos sistemas baseados em IA.

Além disso, a apropriação indevida de material protegido por direitos autorais durante o treinamento de modelos gera controvérsias quanto ao uso ético de conteúdos disponíveis na internet. Debates jurídicos ainda estão em andamento para definir os limites do uso de dados públicos para treinamento de inteligências artificiais (Örpek; Tural; Destan, 2024).

Por fim, destaca-se a necessidade de políticas públicas que orientem o desenvolvimento e a utilização responsável de *LLMs*, equilibrando inovação tecnológica com proteção de direitos fundamentais. A governança ética da IA tornou-se, assim, um tema central para pesquisadores, legisladores e a sociedade em geral (Belle; Papantonis, 2021).

2.4 Chatbot

Este trabalho aplica o conceito de *chatbot* ao contexto agrícola, desenvolvendo um assistente conversacional voltado ao apoio à gestão agrícola. Por meio de mensagens via *WhatsApp*, o agricultor pode acessar informações, registrar dados e obter recomendações personalizadas, aproximando a tecnologia da realidade do campo.

Os *chatbots* configuram-se como uma das tecnologias mais relevantes da era digital, transformando a maneira como humanos e máquinas interagem em diversos setores, como atendimento ao cliente, educação, agricultura, saúde e comércio (Savanur *et al.*, 2021). Para compreender seu potencial e suas limitações, torna-se fundamental analisar não apenas seus conceitos fundamentais e definições, mas também as diferentes arquiteturas, os componentes tecnológicos subjacentes, o funcionamento interno desses sistemas, os métodos empregados para a avaliação de seu desempenho e as implicações socioeconômicas decorrentes de sua adoção em larga escala. Esta seção apresenta uma abordagem estruturada desses aspectos, partindo dos fundamentos teóricos, avançando pelas particularidades técnicas e culminando em uma análise crítica do impacto dos *chatbots* na sociedade contemporânea.

2.4.1 Definição e Conceitos Básicos de Chatbots

Chatbots são sistemas computacionais projetados para interagir com usuários por meio de linguagem natural, simulando uma conversa humana (Deshmukh; Gundewar, 2025). Esses sistemas buscam compreender a intenção das mensagens recebidas e gerar respostas apropria-

das, proporcionando uma experiência de comunicação fluida e eficiente (Venusamy; Rajagopal; Yousoof, 2020).

A literatura apresenta diferentes classificações de *chatbots*, que variam de acordo com sua complexidade e o tipo de interação que oferecem. Em uma abordagem básica, os *chatbots* podem ser categorizados como sistemas baseados em regras, que seguem fluxos predefinidos de diálogo, ou como sistemas baseados em inteligência artificial, capazes de interpretar variáveis contextuais e adaptar suas respostas (Ganesan *et al.*, 2020).

Os primeiros sistemas eram estritamente limitados a sequências lógicas de perguntas e respostas. No entanto, com os avanços no processamento de linguagem natural e no aprendizado de máquina, os *chatbots* passaram a incorporar modelos capazes de aprender com interações anteriores, melhorando continuamente seu desempenho e ampliando a variedade de tarefas que conseguem executar (Savanur *et al.*, 2021).

Assim, os *chatbots* representam uma interface inovadora entre usuários e sistemas computacionais, fundamentada em técnicas de interpretação e geração de linguagem natural, cuja sofisticação varia conforme os métodos tecnológicos empregados.

2.4.2 Tipos e Aplicações de *Chatbots*

Os *chatbots* podem ser classificados conforme o nível de complexidade, a abordagem tecnológica utilizada e o tipo de interação oferecida (Woollaston *et al.*, 2025). Entre os principais tipos, destacam-se:

- a) *chatbots* baseados em regras, ou determinísticos, que operam a partir de fluxos de diálogo predefinidos, geralmente estruturados em árvores de decisão ou *scripts* fixos. São apropriados para tarefas repetitivas e de escopo limitado, como consultas frequentes em serviços de atendimento ao cliente (Balaji; Rao, 2024);
- b) *chatbots* baseados em inteligência artificial, os quais empregam técnicas de processamento de linguagem natural (PLN) e aprendizado de máquina para interpretar intenções e gerar respostas adaptativas (Arsenijevic; Jovic, 2019). Essa flexibilidade os torna adequados a domínios mais dinâmicos, como suporte técnico, educação e saúde;
- c) assistentes virtuais inteligentes, como Siri, Alexa e Google Assistant, que constituem uma evolução dos *chatbots* tradicionais. Esses sistemas integram múltiplos serviços, apresen-

tam compreensão contextual ampliada e executam tarefas específicas, como agendamentos, buscas personalizadas e controle de dispositivos *IoT* (Júnior; Carvalho, 2018);

- d) *chatbots* híbridos, que combinam elementos das abordagens anteriores, mesclando fluxos de decisão predefinidos com técnicas de inteligência artificial, de modo a equilibrar robustez, controle e flexibilidade (Dutt; Sasubilli; Yerrapati, 2020).

Com o avanço das tecnologias de linguagem natural, a adoção de *chatbots* tem se expandido para diversas áreas. Na agricultura, são utilizados para fornecer previsões meteorológicas, orientações sobre manejo e informações técnicas sobre culturas (Kocaballi; Laranjo; Coiera, 2019). No atendimento ao cliente, automatizam respostas a perguntas frequentes e garantem suporte contínuo (Wester *et al.*, 2024). Na educação, funcionam como tutores virtuais, auxiliando no aprendizado personalizado e no monitoramento de desempenho (Sánchez-Adame *et al.*, 2021). Já na área da saúde, apoiam processos de triagem, acompanhamento de tratamentos e suporte emocional, respeitando os protocolos éticos e regulatórios (Cannanure *et al.*, 2024). No comércio eletrônico, oferecem recomendações personalizadas, auxiliam no processo de compra e fomentam o marketing conversacional (Yin *et al.*, 2021). Por fim, no setor público, são empregados para facilitar o acesso da população a serviços governamentais, como emissão de documentos e informações sobre políticas públicas (Rafael *et al.*, 2019).

Cada domínio de aplicação exige ajustes específicos nas funcionalidades e na linguagem dos *chatbots*, de modo a garantir uma experiência mais eficaz, ética e adequada às necessidades dos usuários.

2.4.3 Componentes e Tecnologias de *Chatbots*

Os *chatbots* são programas computacionais concebidos para simular interações humanas, desempenhando papel central na transformação digital de diversos setores. Sua crescente adoção deve-se à capacidade de fornecer respostas automatizadas, suporte ao cliente e serviços personalizados, sustentando-se em um ecossistema tecnológico orientado pela inteligência artificial (IA) (Dutt; Sasubilli; Yerrapati, 2020).

A base funcional dos *chatbots* está na aplicação de técnicas de IA, que permitem o processamento de informações, o aprendizado com interações anteriores e a tomada de decisões a partir de padrões extraídos de dados (Balaji; Rao, 2024). Um dos pilares dessa inteligência é o Processamento de Linguagem Natural (PLN), tecnologia responsável por interpretar a lingua-

gem humana, escrita ou falada, identificar intenções, extrair entidades e analisar o contexto das mensagens. Por meio do PLN, o *chatbot* compreende os comandos do usuário de maneira mais sofisticada, aproximando-se da comunicação humana natural (Savanur *et al.*, 2021).

Complementarmente, o Aprendizado de Máquina (*Machine Learning – ML*) desempenha um papel crucial ao promover a evolução contínua dos sistemas. A partir da análise de grandes volumes de interações, os modelos são ajustados para melhorar a precisão das respostas e a personalização do atendimento (Júnior; Carvalho, 2018). Essa capacidade de adaptação é o que distingue os sistemas mais avançados daqueles baseados apenas em regras estáticas.

Em termos de arquitetura interna, os *chatbots* operam com uma estrutura baseada em três elementos principais: intenções, entidades e respostas. As intenções representam o objetivo do usuário na interação; as entidades correspondem a informações contextuais específicas, como datas, nomes ou localizações; e as respostas são formuladas com base na combinação desses elementos, garantindo relevância e coerência na comunicação (Ganesan *et al.*, 2020).

A classificação dos *chatbots* também pode ser feita de acordo com sua forma de implementação. *Web chatbots* funcionam integrados a sites ou redes sociais, enquanto *chatbots* independentes (em inglês, *standalone chatbots*) operam de forma autônoma, geralmente por meio de aplicações instaladas localmente. Ambos os modelos atendem a diferentes requisitos de acessibilidade e infraestrutura, sendo escolhidos conforme as necessidades do projeto.

As interfaces conversacionais (CUI – *Conversational User Interfaces*) oferecem suporte a múltiplas formas de entrada, como texto, voz e comandos visuais, o que amplia a acessibilidade e a integração com diferentes canais de comunicação, incluindo aplicativos móveis, mensageiros instantâneos e navegadores web (Ganesan *et al.*, 2020).

Além disso, a integração de *chatbots* em plataformas digitais é viabilizada pelas Interfaces de Programação de Aplicações (*APIs*), que conectam os sistemas de diálogo a serviços externos, bancos de dados e módulos de inteligência (Júnior; Carvalho, 2018). Essa conectividade é fundamental para garantir escalabilidade e interoperabilidade em ambientes de produção.

Por fim, destacam-se os ambientes de desenvolvimento, que simplificam a criação e implantação dos *chatbots*. O Dialogflow, da Google, é uma plataforma amplamente utilizada que integra PLN e ML, permitindo que os desenvolvedores projetem interações sofisticadas com menor complexidade técnica. Já o Pandorabots, baseado em AIML (*Artificial Intelligence Markup Language*), permite a criação de *chatbots* com estrutura flexível e respostas predefinidas, sendo ideal para aplicações com fluxos bem definidos (Júnior; Carvalho, 2018).

A articulação entre esses componentes tecnológicos (IA, PLN, ML, arquiteturas dialógicas e ferramentas de desenvolvimento) torna os *chatbots* instrumentos versáteis e eficazes. Seu uso abrange áreas como atendimento ao cliente, comércio eletrônico, educação, recursos humanos e saúde, consolidando-se como uma das soluções mais promissoras na interface entre automação e experiência do usuário.

2.4.4 Funcionamento de um Modelo de *Chatbot*

Os *chatbots*, ou robôs de conversação, são aplicações de software concebidas para simular interações com usuários humanos, utilizando predominantemente texto ou voz como meio de comunicação. Geralmente baseados em técnicas de inteligência artificial (IA), esses sistemas buscam automatizar processos comunicacionais, fornecer informações, auxiliar na execução de tarefas e aprimorar a experiência do usuário em diversos contextos (Balaji; Rao, 2024). Compreender o funcionamento interno desses modelos é fundamental para avaliar suas capacidades e limitações.

O processo de interação típico inicia-se com o recebimento da entrada do usuário, que pode ocorrer por meio de diferentes canais, tais como *websites*, aplicativos móveis, plataformas de mensagens (como Facebook Messenger) ou interfaces de voz (Savanur *et al.*, 2021). Essa entrada textual ou vocal é então submetida a módulos de PLN, que executam tarefas de *tokenização*, análise sintática e semântica, bem como a identificação das intenções e entidades relevantes (Venusamy; Rajagopal; Yousoof, 2020). A partir dessas informações, o sistema de gestão do diálogo determina a ação seguinte, que pode incluir a recuperação de dados em bases de conhecimento, execução de funções específicas ou solicitação de informações adicionais ao usuário (Venusamy; Rajagopal; Yousoof, 2020). Posteriormente, o módulo de Geração de Linguagem Natural formula a resposta adequada, seja na forma de texto, mensagem formatada, imagem ou ação no sistema, enviando-a de volta pelo mesmo canal de comunicação (Júnior; Carvalho, 2018).

É importante notar que modelos mais simples baseiam-se em regras predefinidas, caracterizados por fluxos de conversação estáticos e respostas programadas para comandos específicos. Embora esses sistemas sejam eficazes em tarefas repetitivas e consultas frequentes, apresentam limitações ao lidar com questões complexas ou não previstas. Em contraste, *chatbots*

avançados sustentados por técnicas de IA, PLN e ML oferecem maior robustez, flexibilidade e capacidade de aprendizado contínuo (Venusamy; Rajagopal; Yousoof, 2020).

Assim, o funcionamento de um modelo de *chatbot* resulta da interação sinérgica entre inteligência artificial, processamento de linguagem natural e aprendizado de máquina. Mediante a análise da entrada do usuário, identificação das intenções e entidades, e formulação de respostas adequadas, esses sistemas buscam simular interações humanas com alto grau de sofisticação. A contínua evolução dessas tecnologias amplia o espectro de aplicações dos *chatbots*, tornando-os ferramentas cada vez mais versáteis e relevantes nos diversos contextos digitais contemporâneos.

2.4.5 Avaliação de Chatbots

Ao contrário de softwares tradicionais, a avaliação de *chatbots* apresenta desafios específicos, como compreender a linguagem natural, manter coerência nas respostas e transmitir confiança. Métodos genéricos muitas vezes não capturam essas nuances, exigindo abordagens específicas (Sánchez-Adame *et al.*, 2021).

As avaliações de *chatbots* podem ser classificadas em três categorias principais: técnicas, que se concentram na análise de algoritmos, desempenho e arquitetura do sistema; centradas no usuário, que envolvem métodos como questionários, entrevistas e análise de interações para compreender a experiência do usuário; e híbridas, que combinam elementos de ambas as abordagens para uma avaliação mais abrangente. Além disso, heurísticas específicas têm sido propostas para examinar critérios como clareza da comunicação, facilidade de uso e prevenção de erros durante a interação (Sánchez-Adame *et al.*, 2021).

Dessa forma, a avaliação de *chatbots* demanda métodos específicos e contínuos, que considerem a complexidade das interações e as transformações trazidas pelas tecnologias emergentes.

No contexto deste trabalho, adotou-se uma abordagem híbrida de avaliação, conforme a classificação proposta por (Sánchez-Adame *et al.*, 2021). Essa escolha justifica-se pela necessidade de analisar tanto os aspectos técnicos e objetivos, relacionados ao desempenho e à consistência factual do *chatbot*, quanto os aspectos centrados no usuário, que envolvem a percepção de usabilidade, satisfação e utilidade prática.

A dimensão técnica foi abordada por meio de métricas quantitativas, tais como o Erro Médio Absoluto (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Índice de Concordância de *Willmott*, aplicadas na verificação da acurácia das respostas e na análise da consistência factual das operações sobre o banco de dados. Já a dimensão centrada no usuário foi conduzida por meio de um questionário avaliativo em escala *Likert*, aplicado a produtores e agrônomos, permitindo captar impressões sobre a facilidade de uso, confiabilidade e aceitação tecnológica, com base nos princípios do modelo TAM de Davis (1989).

Assim, a metodologia empregada integra elementos de ambas as categorias, técnica e centrada no usuário, configurando-se como uma avaliação híbrida, capaz de oferecer uma visão mais abrangente e robusta do desempenho e da aceitação do artefato desenvolvido.

2.4.6 Uso do *WhatsApp* por produtores rurais

A escolha do *WhatsApp* como interface não é apenas pragmática, mas sustentada pela literatura sobre adoção de tecnologias no campo. No Brasil, estudos mostram que produtores utilizam intensamente o *WhatsApp* para informação, coordenação e transações: a 8ª Pesquisa ABMRA (levantamento nacional de referência sobre hábitos do produtor) reporta que 94% possuem *smartphone* e que 76% usam o *WhatsApp* para realizar negócios, evidenciando seu papel como canal efetivo de comunicação e negociação na agronomia (Salles, 2021). Uma análise recente com produtores de Minas Gerais indica que o *WhatsApp* é a rede mais usada por agricultores, superando outras mídias sociais (Oliveira *et al.*, 2024). Em paralelo, relatórios e capítulos técnicos sobre agricultura digital no país destacam a difusão de conectividade móvel e o uso de aplicativos de mensagens como suporte à assistência técnica e à extensão rural (Embrapa; Sebrae; INPE, 2020).

Além de sua ampla disponibilidade, o *WhatsApp* se mostra relevante por possibilitar tanto a comunicação horizontal, entre agricultores, quanto a comunicação vertical, com técnicos, cooperativas e instituições de pesquisa (Msimango; Manyevere, 2025). Essa característica contribui para a circulação rápida de informações práticas, como preços de insumos, previsão do tempo, alertas fitossanitários e oportunidades de mercado. Sua interface simples e familiar reduz barreiras de adoção tecnológica, tornando-se um recurso estratégico para a inclusão digital de produtores com diferentes níveis de letramento digital (FAO, 2024).

Esse quadro brasileiro dialoga com evidências internacionais de que agricultores e extensionistas recorrem a aplicativos de *chat*, como o *WhatsApp*, para acessar, compartilhar e validar conhecimento agrônomo, inclusive por meio de grupos e vídeos técnicos, o que reforça sua adequação como *front-end* comunicacional para soluções de apoio à decisão (Bentley; Chowdhury *et al.*, 2024). Nesse contexto, o uso do *WhatsApp* não apenas se justifica pela popularidade da plataforma, mas também pelo seu papel ativo na mediação de processos de gestão agrícola, aprendizagem e inovação no meio rural.

Assim, a escolha do *WhatsApp* como interface principal do sistema proposto neste estudo reflete a busca por acessibilidade ergonômica e de uso, considerando que essa plataforma já faz parte do cotidiano dos produtores rurais brasileiros.

2.4.7 Diferença entre Assistente Agrícola via *WhatsApp* e Sistemas Conversacionais Baseados em LLMs

Assistentes agrícolas via *WhatsApp* e sistemas conversacionais baseados em Large Language Models (LLMs), como o *ChatGPT*, apresentam diferenças conceituais importantes. Os *LLMs* são treinados em extensas bases textuais e podem gerar informações incorretas ou inventadas sem indicação clara de fonte, fenômeno conhecido como “alucinação” (Bender *et al.*, 2021a). Em contrapartida, sistemas de assistência agrícola tendem a restringir suas respostas a dados validados e contextualizados, reduzindo o risco de inconsistências e garantindo maior confiabilidade nas informações fornecidas.

Além disso, a integração de dados e a capacidade de manter registros históricos diferenciam essas abordagens. Enquanto *LLMs* geralmente não possuem armazenamento persistente nativo, permitindo apenas inferência em tempo real, assistentes agrícolas podem centralizar informações relevantes, como dados climáticos, financeiros, estratégicos e operacionais, favorecendo consistência, rastreabilidade e suporte à tomada de decisão (Bender *et al.*, 2021a).

Outro ponto relevante é a utilização de estratégias de recuperação de informações, como o *Retrieval-Augmented Generation*, que permite fornecer respostas contextualizadas a partir de fontes confiáveis, minimizando a geração de conteúdo genérico ou impreciso (Lewis *et al.*, 2020a).

Essa comparação evidencia que, embora os *LLMs* ofereçam versatilidade e fluência na linguagem, assistentes especializados via *WhatsApp* podem garantir maior precisão, consistência e confiabilidade ao lidar com dados críticos para a gestão agrícola.

2.4.8 Segurança e Proteção de Dados

O tratamento de dados pessoais no contexto desta pesquisa demanda atenção especial aos aspectos de segurança e conformidade legal. Isso se justifica pelo fato de que o sistema desenvolvido interage diretamente com o *WhatsApp*, recebendo e processando informações de usuários que, em determinadas situações, podem conter dados pessoais ou sensíveis.

Inicialmente, destaca-se que as mensagens trafegadas no *WhatsApp* são protegidas por criptografia ponta a ponta (E2EE), baseada no *Signal Protocol* (WhatsApp, 2024). Esse mecanismo garante que apenas o remetente e o destinatário possam acessar o conteúdo durante o transporte, de modo que nem mesmo o provedor de serviços tem acesso às mensagens (Signal Foundation, 2025). Contudo, após a descryptografia realizada no cliente conectado por meio da biblioteca *Baileys*, as mensagens passam a estar sob a responsabilidade do sistema proposto. Assim, a segurança em repouso e em processamento torna-se um requisito central (ItsukiChan, 2025).

No armazenamento dos dados, adota-se uma combinação de mecanismos técnicos para assegurar a proteção em repouso. Primeiramente, o banco de dados PostgreSQL utiliza criptografia nativa provida pelo ambiente de hospedagem, garantindo que os volumes de disco permaneçam cifrados mesmo em casos de acesso físico não autorizado. Além disso, são aplicadas políticas de segurança em nível de linha (*Row-Level Security* - RLS), que restringem o acesso a registros de acordo com o contexto de autenticação de cada usuário, promovendo isolamento lógico entre diferentes entidades (Supabase, 2025).

Complementarmente, segredos de autenticação, como chaves de *API* e *tokens* de sessão do *WhatsApp*, são armazenados em cofres de variáveis de ambiente, evitando exposição em código-fonte ou repositórios versionados. Esses segredos são submetidos a processos de rotatividade periódica, mitigando riscos em caso de comprometimento (Alucard0x1, 2024). Políticas de controle de acesso seguem o princípio do menor privilégio, limitando permissões de leitura e escrita apenas a componentes estritamente necessários. Os acessos administrativos são moni-

torados e auditados por meio de registros de *log*, permitindo rastreabilidade em incidentes de segurança.

Outro aspecto fundamental é a conformidade com a Lei Geral de Proteção de Dados (LGPD). Nesse sentido, são adotados princípios de minimização, armazenando apenas o estritamente necessário, e políticas de retenção com janelas temporais definidas. Sempre que o tratamento envolver dados de maior risco, é prevista a elaboração de Relatórios de Impacto à Proteção de Dados Pessoais (RIPD), conforme orientações da Autoridade Nacional de Proteção de Dados (ANPD) (ANPD, 2024).

A arquitetura de segurança do sistema baseia-se em dois eixos principais: proteção em trânsito, assegurada pela criptografia ponta a ponta do *WhatsApp*; e proteção em repouso, viabilizada por criptografia de volumes, políticas RLS, gestão segura de segredos, controle de acesso com privilégio mínimo e auditoria de operações. Dessa forma, busca-se atender simultaneamente aos requisitos técnicos e normativos de proteção de dados.

2.4.9 Ferramentas e Tecnologias de Suporte

A arquitetura desenvolvida neste trabalho apoia-se em um conjunto de ferramentas e tecnologias que viabilizam a integração entre os módulos do sistema, a automação de fluxos de dados e a comunicação com o usuário final. Entre os principais componentes utilizados, destacam-se o *Docker*, a plataforma *N8N* e a biblioteca *Baileys*, cada um desempenhando um papel essencial na operacionalização do assistente agrícola.

O *Docker* é uma tecnologia de contêinerização que permite empacotar aplicações e suas dependências em ambientes isolados, garantindo portabilidade, escalabilidade e reprodutibilidade da execução (Merkel, 2014). No contexto deste trabalho, o uso de contêineres facilita a implantação modular dos serviços como o banco de dados, o orquestrador de fluxos e o modelo de linguagem, promovendo maior consistência entre ambientes de desenvolvimento e produção.

A plataforma *N8N* é um sistema de automação de fluxos de trabalho (*workflow automation*) que possibilita a criação de pipelines de integração entre *APIs*, bancos de dados e sistemas externos, sem necessidade de codificação extensa (N8N GmbH, 2025). No sistema proposto, o *N8N* atua como camada intermediária entre o *chatbot* e as fontes de dados, permitindo a execução automatizada de tarefas como leitura, atualização e verificação de informações agrícolas.

Por fim, a biblioteca *Baileys* oferece uma interface de programação que permite a integração de aplicações com o *WhatsApp Web* (WhiskeySockets, 2025). Sua adoção neste trabalho possibilita a comunicação direta do agente conversacional com os produtores rurais por meio do aplicativo, garantindo o envio e recebimento de mensagens em tempo real. Essa integração é fundamental para operacionalizar o canal de interação central do assistente agrícola, viabilizando o uso prático do sistema em ambiente de produção.

Assim, a combinação dessas três tecnologias (*Docker*, *N8N* e *Baileys*) fornece a infraestrutura necessária para a implementação eficiente, modular e escalável do assistente agrícola proposto.

3 ESTADO DA ARTE EM *CHATBOTS* AGRÍCOLAS

Em um contexto em que a agricultura desempenha um papel vital na economia de muitos países, especialmente na Índia, onde 58% da população depende desse setor, o acesso a informações precisas e especializadas ainda é um desafio significativo. Diante desse cenário, os autores Chandolikor *et al.* (2022) propuseram o *AgroBot*, um *chatbot* inteligente desenvolvido para auxiliar agricultores com dúvidas relacionadas a práticas agrícolas, como irrigação, seleção de pesticidas, previsão de preços e condições ideais de cultivo.

O *AgroBot* possui a capacidade de processar linguagem natural, permitindo que os usuários interajam de forma intuitiva, mesmo com consultas mal estruturadas ou contendo erros gramaticais. O sistema é baseado em redes neurais artificiais (RNA) e emprega técnicas de Processamento de Linguagem Natural (*NLP*) para compreender e responder às perguntas dos agricultores.

Os resultados apresentados pelos autores demonstram a eficácia do sistema em responder a perguntas complexas. Por exemplo, quando questionado sobre "Qual condição é adequada para o cultivo de arroz?", o *chatbot* identificou corretamente a intenção "*riceCondition*" e respondeu: "O arroz requer um clima quente e úmido." Além disso, o *AgroBot* pode ser acessado via aplicativo móvel ou plataforma web, funcionando 24 horas por dia, sem a necessidade de intervenção humana, o que o torna uma solução escalável e economicamente viável.

Uma das principais contribuições desse trabalho é a demonstração de como inteligência artificial e *NLP* podem ser aplicados para resolver problemas reais no setor agrícola, especialmente em regiões com limitações de infraestrutura e alfabetização digital. Os autores também destacam que futuras melhorias podem incluir suporte multilíngue e integração com dados locais, como previsões meteorológicas e cotações de mercado, ampliando ainda mais o impacto do sistema.

O trabalho de Balpande *et al.* (2024) apresenta o *Agridenius*, um *chatbot* que combina técnicas de *Retrieval-Augmented Generation* (RAG) com modelos generativos de linguagem, configurando-se como uma ferramenta potencialmente transformadora para o apoio à decisão no campo.

O sistema adota uma arquitetura que, por um lado, incorpora um módulo de recuperação de informação capaz de acessar um extenso conjunto de textos (*corpus*) composto por pesquisas científicas, manuais técnicos e dados agronômicos atualizados. Por outro, emprega

modelos generativos baseados em arquiteturas *Transformer*, responsáveis por processar e sintetizar as informações recuperadas em respostas contextualizadas. Essa abordagem híbrida foi especificamente desenvolvida para superar limitações comumente encontradas em sistemas convencionais, particularmente no que diz respeito à precisão factual e ao tratamento adequado da terminologia técnica característica do domínio agrícola.

Os resultados obtidos pelos pesquisadores demonstram a eficácia da proposta. Os testes de validação revelaram uma acurácia de 98,5% nas respostas geradas, com variações de desempenho conforme a cultura agrícola em questão, atingindo 90,9% de F1-Score para o algodão e 87,0% para o trigo. A análise temática das consultas evidenciou que 38,8% das interações concentravam-se em questões relacionadas a fertilizantes, indicando uma boa aderência às necessidades práticas dos usuários.

Deve-se atentar à limitação do estudo quanto à qualidade e atualização do corpus documental que se mostrou um fator crítico para o desempenho do sistema. Adicionalmente, os autores destacam desafios significativos na adaptação do modelo para diferentes contextos linguísticos e regionais, bem como na integração com fontes de dados dinâmicas, como informações de mercado em tempo real.

Na Tailândia, onde parte significativa dos agricultores apresenta dificuldades com tecnologias modernas, os pesquisadores Suebsombut *et al.* (2022) desenvolveram uma solução inovadora: um *chatbot* integrado ao aplicativo *LINE*, amplamente utilizado no país, para auxiliar no manejo agrícola.

O estudo dos autores Suebsombut *et al.* (2022) partiu de uma constatação: embora a Internet das Coisas (*IoT*) e sensores inteligentes venham sendo adotados na agricultura inteligente, muitos agricultores, especialmente os mais idosos, encontram barreiras no uso dessas tecnologias. O *chatbot* surge então como uma ponte entre o conhecimento técnico e o usuário final, traduzindo dados complexos em orientações simples e acessíveis.

A arquitetura do sistema combina três elementos principais. Primeiro, uma base de conhecimento sobre cultivos, com informações sobre irrigação, controle de pragas e outras práticas agrícolas. Segundo, a integração com sensores de campo que monitoram condições do solo e do ambiente. Por fim, uma interface conversacional simples, onde o agricultor pode tanto receber alertas automáticos quanto fazer perguntas específicas sobre seu cultivo.

Os resultados da implementação piloto, focada no cultivo de alface na região de Chiang Mai, indicaram alto nível de satisfação entre os agricultores. A taxa de satisfação atingiu

impressionantes 96%, demonstrando a eficácia da solução. Um dos aspectos mais valorizados foi a possibilidade de controlar sistemas de irrigação diretamente pelo *chat*, simplificando significativamente o manejo diário da plantação.

Apesar dos resultados positivos, os pesquisadores identificaram limitações importantes. O sistema atual exige que os agricultores digitem comandos muito específicos, o que pode ser desafiador para quem não está familiarizado com termos técnicos. Além disso, a base de conhecimento ainda é restrita a poucas culturas, limitando sua aplicabilidade.

Os desenvolvedores planejam incorporar processamento de linguagem natural para entender perguntas mais coloquiais, expandir a base de conhecimento para outras culturas e adaptar o sistema aos diversos dialetos regionais da Tailândia.

Esta experiência tailandesa oferece lições para outros países em desenvolvimento. Demonstra que é possível modernizar a agricultura sem excluir os pequenos produtores, desde que as soluções tecnológicas sejam pensadas a partir das reais necessidades e limitações dos usuários finais. O ponto principal do projeto reside justamente em sua capacidade de traduzir dados técnicos em orientações práticas, usando uma plataforma que já faz parte do cotidiano dos agricultores.

Na era da transformação digital, a agricultura enfrenta um paradoxo: enquanto a demanda por alimentos orgânicos e sustentáveis cresce globalmente, muitos agricultores ainda lutam para obter preços justos por seus produtos. Este cenário inspirou o desenvolvimento de uma solução inovadora apresentada no artigo de Kiruthika *et al.* (2020), que propõe uma ponte digital entre produtores e consumidores finais.

A proposta de Kiruthika *et al.* (2020) reside na criação de um sistema de *chatbot* integrado a plataformas de mensagens populares, como *Facebook Messenger*. Esta ferramenta não é meramente um canal de comunicação, mas sim uma plataforma inteligente que armazena perfis de agricultores, incluindo seus cultivos, capacidades produtivas e expectativas de preço. Quando um consumidor busca um produto específico, o *chatbot* analisa seu banco de dados e sugere os agricultores mais adequados, fornecendo informações de contato para negociação direta.

A implementação prática deste sistema revelou impactos significativos. Para os agricultores, representou a possibilidade de escapar da dependência de intermediários, que frequentemente absorvem grande parte dos lucros. Os dados apresentados mostram que essa abordagem pode aumentar substancialmente a renda dos pequenos produtores. Para os consumidores, sur-

giu como uma janela de acesso a alimentos orgânicos a preços mais acessíveis, com a vantagem adicional de conhecer a origem do que consomem.

Um aspecto também apontado pelos autores é a abordagem do problema do endividamento agrícola. O artigo apresenta como a falta de acesso direto ao mercado e os baixos preços pagos pelos intermediários contribuem para a crise financeira que assola muitos agricultores. O *chatbot* surge então não apenas como ferramenta comercial, mas como mecanismo de inclusão econômica e social.

Os autores reconhecem, entretanto, que o sistema ainda enfrenta desafios. A necessidade de infraestrutura digital em áreas rurais e a familiarização dos agricultores com tecnologias de comunicação emergem como barreiras a serem superadas. Como direção futura, o artigo sugere a integração com sistemas de monitoramento agrícola em tempo real, que poderiam oferecer aos consumidores informações sobre o estágio de crescimento de seus alimentos encomendados.

O *chatbot* de Maduri *et al.* (2021), construído sobre a plataforma *Xampp* e utilizando técnicas de Processamento de Linguagem Natural (PLN, do inglês *Natural Language Processing – NLP*), funciona como uma ponte entre o conhecimento técnico armazenado em bancos de dados especializados e os agricultores que necessitam dessas informações. Seu diferencial reside na capacidade de traduzir termos agrônômicos complexos em orientações práticas e acessíveis, disponibilizadas em dispositivos móveis dos produtores rurais.

Um agricultor que precisa saber a dosagem correta de nitrogênio para sua plantação de arroz, por exemplo, recebe a resposta precisa em segundos. O sistema vai além, oferecendo desde diagnósticos de deficiências nutricionais até recomendações de quais culturas são mais adequadas para determinado tipo de solo. Tudo isso através de uma interface que lembra uma conversa comum, sem jargões técnicos excessivos.

Na Índia, onde muitos agricultores ainda recorrem a práticas tradicionais transmitidas entre gerações, os *chatbots* têm potencial para reduzir lacunas de conhecimento técnico e favorecer maior eficiência produtiva. Ao ampliar o acesso a informações baseadas em evidências científicas, esses sistemas possibilitam que pequenos produtores tomem decisões mais fundamentadas sobre o manejo de seus cultivos.

Além disso, os autores reconhecem desafios. A dependência de conexão à internet em áreas rurais, a necessidade de atualização constante do banco de dados e as variações linguísticas regionais são obstáculos que precisam ser superados. Como caminho futuro, os pesqui-

sadores sugerem desde a implementação de reconhecimento de imagens para identificar pragas até o desenvolvimento de versões offline do sistema.

O Quadro 3.1 apresenta uma análise comparativa das principais abordagens de *chatbots* aplicadas ao setor agrícola, evidenciando a evolução tecnológica e o amadurecimento das funcionalidades oferecidas ao longo do tempo. Nota-se uma transição de sistemas baseados em regras fixas e capacidades limitadas para soluções mais avançadas, que incorporam inteligência artificial, automação e integração com tecnologias complementares, como sensores e plataformas de mensagens. A linha dedicada à Solução Proposta sintetiza as características do sistema desenvolvido neste trabalho, o qual visa oferecer uma abordagem integrada para a gestão da produção agrícola, contemplando suporte multilíngue e recursos automatizados mais amplos. A tabela também destaca contribuições relevantes de estudos anteriores, como a introdução de um sistema pioneiro de recomendações agrícolas (Chandolikor *et al.*, 2022), a mediação direta entre produtores e compradores (Balpande *et al.*, 2024), o controle remoto da irrigação com uso de *IoT* (Suebsombut *et al.*, 2022), o emprego de redes neurais no diagnóstico de doenças em plantas (Kiruthika *et al.*, 2020), e a integração de conhecimento técnico com IA generativa para respostas especializadas (Maduri *et al.*, 2021). Assim, o comparativo permite situar a proposta atual no contexto das tendências emergentes, ressaltando seus diferenciais frente às abordagens analisadas.

Quadro 3.1 – Comparativo de Abordagens em *Chatbots* Agrícolas

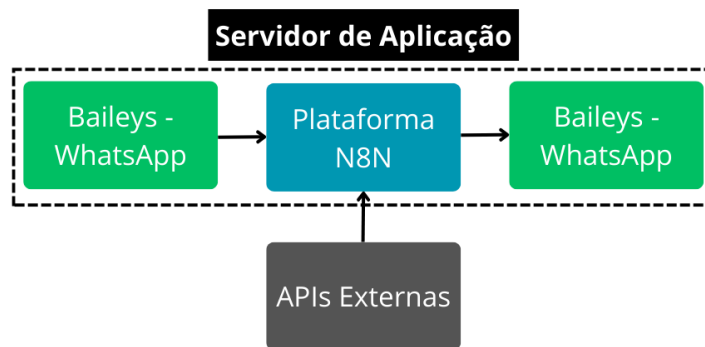
Estudo	Abordagem	Principais Funções	Inovações Principais
(Chandollikar <i>et al.</i> , 2022)	<i>chatbots</i> baseados em regras	Dá orientações sobre fertilizantes e práticas agrícolas	Introdução pioneira de recomendações automatizadas para agricultores
(Balpande <i>et al.</i> , 2024)	<i>chatbots</i> híbridos (regras + IA)	Facilita o contato direto entre produtores e compradores	Elimina intermediários, promovendo negociação direta entre produtores e compradores
(Suebsombut <i>et al.</i> , 2022)	<i>chatbots</i> baseados em regras com <i>IoT</i>	Controla irrigação automaticamente usando sensores	Integra sensores <i>IoT</i> a um <i>chatbot</i> em ambiente amplamente acessível (LINE)
(Kiruthika <i>et al.</i> , 2020)	<i>chatbots</i> baseados em IA	Diagnostica doenças em plantas por imagem ou texto	Emprego pioneiro de redes neurais para diagnóstico automatizado de doenças em lavouras
(Maduri <i>et al.</i> , 2021)	<i>chatbots</i> baseados em IA generativa	Responde perguntas complexas sobre manejo agrícola	Combina conhecimento agrônomo com IA de linguagem para respostas personalizadas
Solução proposta	Assistente virtual inteligente	Abordagem holística. Fornece dados climáticos, financeiros, estratégicos e operacionais via <i>WhatsApp</i>	Automatiza coleta e análise de dados para gestão agrícola completa

Fonte: elaboração própria.

4 ARQUITETURA TECNOLÓGICA DO ASSISTENTE INTELIGENTE AGRÍCOLA

Este capítulo apresenta a arquitetura proposta para o assistente inteligente agrícola, descrevendo seus componentes físicos e lógicos, bem como o modo de integração entre eles. A metodologia adotada é de natureza aplicada, orientada à implementação e validação do sistema em ambiente agrícola real, o que garante aderência às necessidades práticas do campo. A arquitetura, representada esquematicamente na Figura 4.1, foi concebida para assegurar precisão, confiabilidade e consistência no processamento das informações. Inicialmente, é discutida a infraestrutura de suporte, com foco no servidor de aplicação, seguido pela descrição das *APIs* externas utilizadas. Na sequência, detalham-se a biblioteca *Baileys*, responsável pela comunicação com o *WhatsApp*, e a plataforma N8N, que constitui o núcleo de automação do sistema. São então apresentados os nós e *workflows* configurados no N8N, que incluem módulos de manipulação de dados financeiros, estratégicos, operacionais e meteorológicos, além da integração com modelos de linguagem e mecanismos de memória. Por fim, aborda-se o processo de geração e disponibilização de links para consulta de dados e o nó de saída responsável pelo envio de mensagens ao usuário.

Figura 4.1 – Arquitetura geral do assistente inteligente agrícola



Fonte: elaboração própria.

4.1 Servidor de Aplicação

A instalação do servidor de aplicação constituiu a base da infraestrutura responsável por hospedar o sistema desenvolvido, sendo implantado na Diretoria de Gestão de Tecnologia da Informação (DGTI) da Universidade Federal de Lavras (UFLA), o que assegurou maior con-

trole institucional, disponibilidade e suporte técnico. O servidor foi configurado com o sistema operacional *Ubuntu Server*, em sua versão *LTS (Long Term Support)*, escolhido por oferecer estabilidade e suporte prolongado, garantindo a continuidade operacional e a confiabilidade do ambiente. Sobre esse sistema, instalaram-se as ferramentas *Docker* e *Docker Compose*, que permitiram a criação e execução de contêineres isolados e leves, além de possibilitar a orquestração padronizada dos serviços por meio de arquivos, favorecendo a reprodutibilidade, manutenção e escalabilidade do sistema. A plataforma N8N foi utilizada para automatizar fluxos de trabalho, coordenando tarefas de coleta, transformação e encaminhamento de dados, promovendo eficiência e integração entre diferentes serviços e fontes de informação. Adicionalmente, a biblioteca *Baileys* foi instalada no servidor para viabilizar a comunicação com a plataforma *WhatsApp*, permitindo o envio e recebimento automatizado de mensagens dentro do ambiente controlado, garantindo segurança e confiabilidade no processamento de dados sensíveis. Para proteger o servidor e os dados processados, adotaram-se medidas de segurança que englobaram autenticação e autorização de usuários, controle rigoroso de portas, configuração de políticas de *firewall* e, quando necessário, acesso remoto seguro por meio de *VPN*. Dessa forma, a configuração do servidor de aplicação estabeleceu um componente estratégico da arquitetura do sistema, oferecendo um ambiente robusto, escalável e seguro, capaz de suportar de maneira eficiente os módulos de coleta, processamento e armazenamento de dados ambientais, bem como a integração com serviços externos e automações essenciais ao projeto.

A integração com *APIs* externas foi essencial para ampliar as funcionalidades do sistema, permitindo a comunicação com serviços de terceiros que forneceram dados ou executaram operações complementares às funcionalidades locais. Para esse fim, utilizou-se a biblioteca *requests*, amplamente empregada em aplicações *Python*, por facilitar o envio de requisições *HTTP*, como *GET* e *POST*, e o tratamento das respostas, especialmente em comunicações com *APIs RESTful*.

Durante a configuração das integrações, definiram-se os *endpoints (URLs)*, parâmetros de requisição, cabeçalhos *HTTP* e, quando necessário, mecanismos de autenticação, como *tokens* ou chaves de *API*. Também foram implementados procedimentos para o tratamento de erros, garantindo robustez e confiabilidade na comunicação com os serviços externos.

O sistema integrou as seguintes *APIs* externas:

- a) *OpenWeatherMap API*: forneceu previsões meteorológicas detalhadas, incluindo temperatura, precipitação, umidade, velocidade do vento e outros parâmetros climáticos. Essas

informações permitiram ao sistema antecipar condições ambientais e apoiar decisões estratégicas no manejo da lavoura de café;

- b) *Supabase API*: possibilitou a integração com o banco de dados da fazenda, permitindo consultas e modificações em tabelas financeiras, estratégicas e operacionais. Essa integração garantiu acesso seguro e controlado aos dados, permitindo que o *AI Agent* realizasse operações automatizadas;
- c) *Groq API*: foi utilizada para consultas e processamento de dados vetorizados armazenados, possibilitando buscas semânticas sobre informações operacionais do cultivo de café, melhorando a precisão na recuperação de dados relevantes;
- d) *Google Gemini API*: forneceu capacidades de compreensão e geração de linguagem natural. Por meio do modelo *Gemini-2.5-Flash*, possibilitou a interpretação de mensagens do usuário, a geração de respostas coerentes e o suporte à lógica de decisão do *AI Agent*;
- e) *Google Drive API*: permitiu o acesso e o download de documentos relevantes, como arquivos PDF sobre práticas de cultivo. Esses documentos foram posteriormente processados para gerar representações vetoriais (*embeddings*) utilizadas no fluxo de automação;
- f) *HTML/CSS to Image API* (<https://hcti.io/>): foi utilizada para converter tabelas HTML, geradas a partir dos dados financeiros ou estratégicos, em imagens que puderam ser compartilhadas de forma segura, preservando a apresentação padronizada das informações.

A integração com essas *APIs* proporcionou ao sistema uma visão consolidada das condições ambientais, operacionais e estratégicas da lavoura, enriquecendo a base de dados utilizada pelo *AI Agent* e favorecendo a tomada de decisões fundamentadas e precisas no manejo da produção de café.

4.2 Biblioteca *Baileys*

A biblioteca *Baileys* foi utilizada como ferramenta *open-source* desenvolvida em *JavaScript/TypeScript* que permite a integração de aplicações com o *WhatsApp* por meio do protocolo *Web WhatsApp* (WhiskeySockets, 2025). No contexto deste projeto, ela foi empregada para estabelecer comunicação entre os usuários e o fluxo de automação implementado no N8N. A cada mensagem enviada pelo usuário via *WhatsApp*, a biblioteca capturou o conteúdo da comunicação, incluindo texto, anexos e identificadores de remetentes, e repassou essas informações para

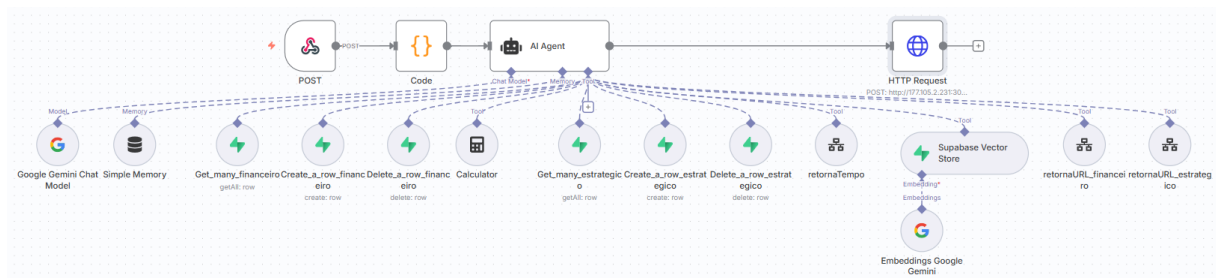
os *webhooks* configurados no fluxo. Da mesma forma, permitiu que respostas geradas pelo *AI Agent* fossem enviadas de volta ao usuário de forma segura e estruturada.

A biblioteca também possibilitou o monitoramento de eventos em tempo real, como entrega de mensagens, leitura pelo destinatário e status de conexão, garantindo um acompanhamento preciso das interações. Além disso, realizou autenticação segura por meio de *QR Code* e *tokens*, assegurando que o acesso ao *WhatsApp* fosse restrito à aplicação e protegido contra acessos não autorizados (WhiskeySockets, 2025). Dessa forma, a utilização da biblioteca *Baileys* mostrou-se essencial para automatizar as interações no *WhatsApp*, integrando de maneira confiável a comunicação dos usuários ao fluxo de automação que processa informações financeiras, estratégicas, operacionais e meteorológicas da fazenda.

4.3 Plataforma N8N

A plataforma N8N constituiu o núcleo da automação de fluxos de trabalho do sistema, permitindo a orquestração de tarefas e a integração entre múltiplas fontes de dados e serviços externos. Por meio de sua arquitetura baseada em nós, foi possível configurar entradas, transformações e saídas de informações de forma modular e flexível, garantindo que cada etapa do processamento ocorresse de maneira controlada e eficiente (N8N GmbH, 2025). Essa abordagem facilitou a implementação de automações complexas, como o recebimento de mensagens via *WhatsApp*, a comunicação com *APIs* externas e o armazenamento ou encaminhamento de dados para outros sistemas. A Figura 4.2 ilustra o *workflow* principal implementado no N8N, evidenciando a sequência de nós e a interconexão entre as diferentes etapas do fluxo de automação.

Figura 4.2 – *Workflow* N8N



Fonte: elaboração própria a partir da plataforma n8n.

A escolha do N8N foi motivada por sua arquitetura de automação visual baseada em nós, a qual favorece a integração entre sistemas heterogêneos por meio de mecanismos estruturados de orquestração. Embora existam alternativas consolidadas, como *Node-RED*, *LangChain* ou plataformas especializadas em *RAG*, como o *RagFlow*, o N8N distinguiu-se por oferecer suporte nativo a fluxos acionados por *webhooks*, integração direta com bancos de dados e ferramentas de IA, além da possibilidade de incorporar rotinas personalizadas em *JavaScript*. Esses atributos o tornaram particularmente adequado às necessidades deste projeto, que demandavam orquestração modular, representação visual clara do fluxo e agilidade na prototipação das interações entre o agente conversacional, *APIs* externas e o banco de dados.

4.3.1 Nó *POST*

O nó *POST* correspondeu a um *Webhook* configurado no *N8N* e funcionou como ponto de entrada do fluxo. Sua função foi receber requisições *HTTP* externas provenientes do servidor que possuía a biblioteca *Baileys* instalada, a qual realizava a integração com o *WhatsApp*. Nesse cenário, toda mensagem enviada pelo usuário ao *WhatsApp* foi repassada ao *Webhook* por meio de uma requisição do tipo *POST*, cujo corpo continha tanto o texto da mensagem quanto o identificador do remetente. O caminho definido para esse *Webhook* foi configurado como `webhook-path`, determinando o endereço específico de acesso ao recurso dentro do *N8N*. Assim, esse nó desempenhou o papel fundamental de porta de entrada do sistema, permitindo que o conteúdo bruto da comunicação estabelecida via *WhatsApp* chegasse ao fluxo de automação e fosse, posteriormente, processado pelos nós seguintes.

4.3.2 Nó *Code*

O nó *Code* no *N8N* foi utilizado para processamento personalizado de dados por meio de *JavaScript*. No fluxo implementado, ele desempenhou a função de extrair e estruturar informações da mensagem recebida pelo *Webhook* (nó *POST*). Inicialmente, o nó acessou o corpo da requisição *HTTP* recebida e capturou a *string JSON* que continha a mensagem enviada pelo usuário. Em seguida, realizou o *parse* dessa *string*, convertendo-a em um objeto *JavaScript* (*parsedMessage*), o que possibilitou a manipulação estruturada dos campos da mensagem, como texto e metadados.

Posteriormente, o nó extraiu o campo *from*, que identificou o remetente da mensagem, garantindo que o sistema reconhecesse a origem da comunicação. Por fim, retornou um novo item contendo o objeto *parsedMessage* e o identificador *from*, que foram utilizados pelos nós subsequentes do fluxo, permitindo que outras ferramentas do *N8N* processassem a mensagem e interagissem com bancos de dados ou com o agente de inteligência artificial.

Dessa forma, o nó *Code* atuou como um pré-processador das mensagens recebidas, convertendo dados brutos em um formato estruturado e consistente, essencial para o correto funcionamento do fluxo automatizado de mensagens e da integração com a inteligência artificial.

4.3.3 Nó *AI Agent*

O nó *AI Agent* no *N8N* atuou como o núcleo de processamento inteligente do fluxo, sendo responsável por interpretar as mensagens recebidas e executar ações conforme definido pelas ferramentas conectadas. Esse nó foi configurado com um *prompt* que descreveu detalhadamente o escopo de atuação do agente, determinando que ele funcionasse exclusivamente como assistente agrícola para a Fazenda da UFLA, com funções específicas relacionadas a dados financeiros, estratégicos, operacionais e meteorológicos.

Ao receber uma entrada, o nó *AI Agent* decidiu, com base no conteúdo da mensagem e nas regras definidas no *prompt*, qual ferramenta ou ação deveria ser acionada. Entre as funcionalidades implementadas, destacaram-se: a consulta e modificação de dados financeiros na tabela do *Supabase*, a consulta e modificação de dados estratégicos também armazenados no *Supabase*, o cálculo de informações financeiras, a consulta de dados operacionais relacionados ao cultivo de café, que estavam armazenados em forma vetorizada no banco de dados, permitindo buscas inteligentes, bem como a geração de *links URL* para acesso aos dados financeiros e estratégicos.

Além disso, o agente foi responsável por formatar a resposta final de maneira clara, profissional e objetiva, respeitando as regras de comunicação previamente definidas, como escrita em português formal, uso de texto corrido ou listas numeradas simples, e sem inventar informações que não estivessem presentes na base de dados.

Dessa forma, o nó *AI Agent* centralizou a lógica de decisão do fluxo, garantindo que todas as solicitações recebidas fossem processadas de maneira consistente, confiável e em conformidade com o escopo específico definido para o assistente agrícola.

4.3.4 Nó *Google Gemini Chat Model*

O nó *Google Gemini Chat Model* representou a integração do fluxo com o modelo de linguagem avançado da *Google*, denominado *Gemini-2.5-Flash*, acessado por meio da *API PaLM*. Sua função foi fornecer capacidades de compreensão e geração de linguagem natural, permitindo que o fluxo interpretasse corretamente as mensagens recebidas e produzisse respostas adequadas ao contexto operacional do sistema.

Esse nó recebeu o conteúdo textual processado pelos nós anteriores, como o *Code*, e encaminhou essas informações ao modelo *Gemini-2.5-Flash*, responsável pela análise semântica e pela produção da resposta textual. O resultado gerado pelo modelo foi então utilizado pelo *AI Agent* para orientar decisões internas do fluxo, como acionar ferramentas, consultar bancos de dados ou formatar a saída final enviada ao usuário no *WhatsApp*.

A escolha do *Gemini-2.5-Flash* deveu-se à sua combinação entre baixo custo computacional, alta velocidade de inferência e capacidade de lidar com instruções complexas em língua portuguesa, características essenciais para um sistema que depende de respostas em tempo real e opera integrado a fluxos automatizados. Embora existam modelos alternativos, como GPT, Claude ou LLaMA, optou-se pelo *Gemini-2.5-Flash* devido à sua integração nativa com o ecossistema do N8N e com a infraestrutura da *API PaLM*, o que simplificou o processo de autenticação, reduziu latências e garantiu estabilidade operacional no ambiente de produção. Dessa forma, o nó acrescentou ao fluxo uma camada robusta de interpretação linguística, sustentando a lógica de decisão implementada pelo agente inteligente.

4.3.5 Nó *Simple Memory*

O nó *Simple Memory* no fluxo do *N8N* funcionou como um mecanismo de memória de curto prazo para o *AI Agent*. Ele armazenou temporariamente o contexto das conversas, permitindo que o agente mantivesse coerência e acompanhasse o histórico das interações com cada usuário.

A configuração desse nó utilizou uma chave de sessão personalizada, definida pelo identificador do remetente (*from*) da mensagem recebida. Isso garantiu que cada usuário possuísse um contexto isolado, evitando que informações de diferentes conversas se misturassem. O com-

primento da janela de contexto foi ajustado para 1000, controlando a quantidade de informações recentes que foram mantidas na memória.

Dessa forma, o *Simple Memory* permitiu que o *AI Agent* considerasse interações anteriores ao gerar respostas, melhorando a consistência e a relevância das informações fornecidas, sem a necessidade de armazenamento permanente em banco de dados.

4.3.6 Nó *Get_many_financeiro*

O nó *Get_many_financeiro* é um nó de integração com o *Supabase* que tem a função de consultar todos os registros da tabela *Fazenda_Financeiro*. Ele utiliza a operação *getAll*, configurada para retornar todos os itens disponíveis na tabela, garantindo que o *AI Agent* tenha acesso completo aos dados financeiros armazenados.

Este nó permite que o agente leia informações como entradas, tipos, descrições, valores e datas registradas no banco de dados, fornecendo a base necessária para consultas, relatórios e cálculos financeiros. A conexão é realizada por meio das credenciais do *Supabase*, garantindo autenticação segura e acesso controlado à tabela específica da fazenda.

Assim, o *Get_many_financeiro* atua como ferramenta de leitura, essencial para operações que envolvem análise ou apresentação de dados financeiros ao usuário, sendo frequentemente chamado pelo *AI Agent* quando há solicitações relacionadas a essas informações.

4.3.7 Nó *Create_a_row_financeiro*

O nó *Create_a_row_financeiro* foi responsável por inserir novos registros na tabela *Fazenda_Financeiro* do *Supabase*. Ele recebeu valores para os campos entrada, tipo, descrição, valor e data, que foram preenchidos automaticamente a partir das instruções geradas pelo *AI Agent*.

A operação desse nó foi essencial para permitir que o fluxo adicionasse novas informações financeiras, mantendo o banco de dados atualizado com entradas recentes da fazenda. A conexão com o *Supabase* foi realizada por meio de credenciais seguras, garantindo autenticação e acesso controlado à tabela.

Ao ser acionado pelo *AI Agent*, o nó permitiu que novas transações financeiras ou registros de entradas fossem adicionados de forma automatizada, com dados provenientes de interações via *WhatsApp* ou outros pontos de entrada do sistema.

4.3.8 Nó Delete_a_row_financeiro

O nó *Delete_a_row_financeiro* foi responsável por remover registros específicos da tabela *Fazenda_Financeiro* no *Supabase*. Ele operou a partir de um critério de filtro definido, que, neste caso, verificava o valor do campo ‘entrada’ para identificar a linha que deveria ser deletada.

Esse nó permitiu que o fluxo eliminasse entradas financeiras de maneira controlada e automatizada, garantindo que apenas os registros que atendiam à condição especificada fossem removidos. A operação foi acionada pelo *AI Agent*, que definiu o valor de referência para a exclusão, assegurando a integração entre a inteligência do agente e o banco de dados. A conexão com o *Supabase* utilizou credenciais seguras, garantindo autenticação e acesso autorizado à tabela.

4.3.9 Nó Calculator

O nó *Calculator* atuou como uma ferramenta de cálculo dentro do fluxo do *N8N*. Ele foi utilizado pelo *AI Agent* para realizar operações matemáticas ou financeiras sobre os dados obtidos das tabelas do *Supabase*.

Sua função principal permitiu que cálculos necessários, como somas, médias ou outras operações aritméticas, fossem executados automaticamente durante o processamento das informações financeiras. O nó recebeu instruções do *AI Agent* e retornou os resultados, integrando o processamento de dados com as demais funcionalidades do sistema, garantindo respostas precisas e rápidas sem necessidade de intervenção manual.

4.3.10 Nó *Get_many_estratégico*

O nó *Get_many_estratégico* foi responsável por consultar todos os registros da tabela *Fazenda_Estrategico* no *Supabase*. Ele operou com a função *getAll*, garantindo que todos os dados estratégicos armazenados no banco de dados fossem recuperados de forma completa.

Esses dados incluíram informações de planejamento, indicadores de desempenho e outros registros relevantes para decisões estratégicas da fazenda. O nó funcionou como uma interface de leitura entre o banco de dados e o *AI Agent*, permitindo que o agente utilizasse essas informações para análises, recomendações ou geração de relatórios automatizados, integrando a camada de dados estratégicos ao fluxo de automação.

4.3.11 Nó *Create_a_row_estratégico*

O nó *Create_a_row_estratégico* foi responsável por inserir novos registros na tabela *Fazenda_Estrategico* do *Supabase*. Ele recebeu valores para os campos *entrada*, *descrição*, *local*, *data_inicio* e *data_fim* a partir das instruções geradas pelo *AI Agent*, que processou os dados fornecidos pelos usuários ou por outras fontes de informação.

Esse nó atuou como interface de escrita no banco de dados, garantindo que novas informações estratégicas fossem registradas de forma estruturada, permitindo que o fluxo de automação mantivesse atualizados os dados utilizados para análises, planejamento e geração de relatórios estratégicos da fazenda.

4.3.12 Nó *Delete_a_row_estratégico*

O nó *Delete_a_row_estratégico* foi responsável por remover registros da tabela *Fazenda_Estrategico* do *Supabase*. A exclusão ocorreu com base em condições específicas, neste caso, utilizando o valor do campo *entrada* fornecido pelo *AI Agent*.

Esse nó garantiu que informações estratégicas que não eram mais relevantes ou que precisavam ser atualizadas fossem removidas do banco de dados de forma controlada, mantendo a integridade e a consistência dos dados utilizados pelo fluxo de automação.

4.3.13 Nó `retornaTempo`

O nó `retornaTempo` foi configurado para fornecer informações meteorológicas atuais, atuando como uma ferramenta de consulta automatizada dentro do fluxo de automação do *N8N*. Ele se integrou a um *workflow* específico (`retornaTempo`), que realizou a coleta, o processamento e a disponibilização dos dados climáticos de interesse para o sistema. Para obter essas informações, o *workflow* estabeleceu comunicação com a *API OpenWeatherMap*, garantindo acesso a dados confiáveis sobre temperatura, umidade, precipitação, velocidade do vento e outros parâmetros meteorológicos relevantes. Esse nó não exigiu parâmetros de entrada fornecidos diretamente pelo usuário, sendo acionado pelo fluxo sempre que se tornou necessário obter informações sobre as condições meteorológicas atuais. A utilização do nó permitiu que o *AI Agent* e outros componentes do fluxo acessassem dados consistentes e atualizados, apoiando decisões estratégicas relacionadas ao manejo agrícola.

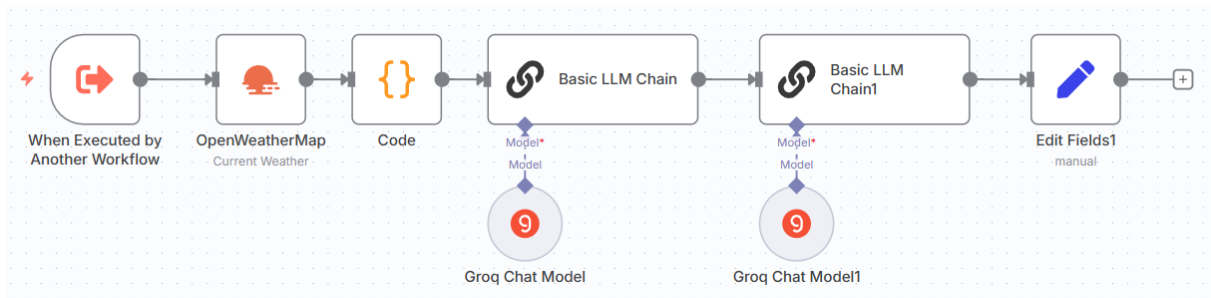
4.3.14 Workflow `retornaTempo`

O *workflow* `retornaTempo`, acionado pelo nó homônimo, organizou de forma estruturada o processo de aquisição e entrega dos dados meteorológicos (Figura 4.3). Inicialmente, realizou a requisição à *API OpenWeatherMap*, coletando parâmetros como temperatura, umidade, pressão atmosférica, precipitação, velocidade e direção do vento, além de informações temporais e geográficas associadas à Fazenda da UFLA. Em seguida, o *workflow* processou e padronizou essas informações, garantindo que fossem consistentes e facilmente interpretáveis pelos demais módulos do sistema. Todo o procedimento foi automatizado, permitindo que os dados fossem disponibilizados de forma rápida e confiável. Dessa maneira, o *workflow* `retornaTempo` complementou o nó principal, assegurando que o fluxo de automação contasse com informações meteorológicas detalhadas e atualizadas, essenciais para a execução de tarefas agrícolas, análise de risco climático e planejamento estratégico das atividades no campo.

4.3.15 Nó *Supabase Vector Store e Embeddings Google Gemini*

O nó *Supabase Vector Store* foi utilizado para recuperar informações específicas sobre o cultivo de café armazenadas na tabela `Fazenda_Operacional` do banco de dados *Supabase*.

Figura 4.3 – Workflow do nó retornaTempo para obtenção de dados meteorológicos



Fonte: elaboração própria a partir da plataforma n8n.

Ele operou no modo *retrieve-as-tool*, permitindo que o conteúdo embutido em formato vetorial fosse consultado pelo fluxo de automação como uma ferramenta de busca de documentos.

A principal função deste nó foi possibilitar que o *AI Agent* ou outras partes do sistema acessassem rapidamente dados operacionais relevantes, utilizando consultas baseadas em similaridade (*match_documents*). Dessa forma, informações detalhadas sobre o cultivo de café foram integradas e processadas dentro do fluxo de automação, enriquecendo respostas e análises realizadas pelo agente.

O nó *Embeddings Google Gemini* foi responsável por gerar representações vetoriais (*embeddings*) de textos utilizando o modelo *gemini-2.5-flash* da *API Google PaLM*. Essas representações permitiram que conteúdos textuais fossem transformados em vetores numéricos, os quais puderam ser armazenados e consultados posteriormente em uma *vector store*.

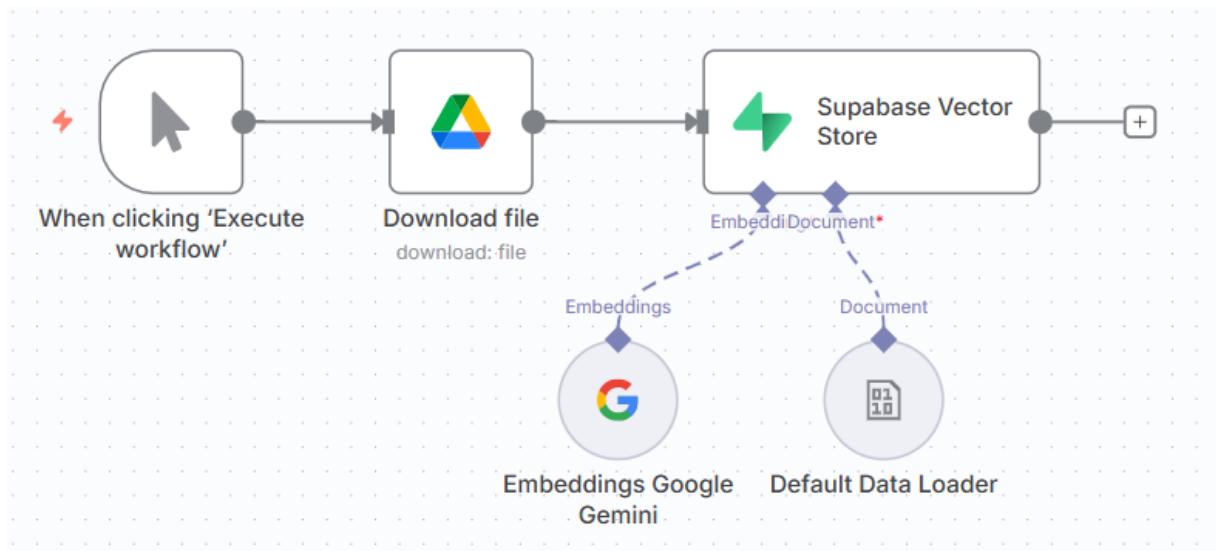
No contexto do fluxo de automação, este nó foi utilizado para processar os dados operacionais sobre o cultivo de café, convertendo-os em *embeddings* que possibilitaram buscas semânticas e análises baseadas em similaridade. Dessa forma, o agente de IA conseguiu acessar informações relevantes de maneira eficiente e precisa, integrando os dados à lógica do sistema.

4.3.16 Workflow de integração do Supabase Vector Store Embeddings Google Gemini

O *workflow* associado aos nós *Supabase Vector Store* e *Embeddings Google Gemini* organizou o processo de ingestão, conversão e armazenamento de documentos operacionais relacionados ao cultivo de café na tabela *Fazenda_Operacional* do *Supabase*. A execução do fluxo iniciou-se com o nó *Download file*, responsável por obter arquivos do *Google Drive*,

neste caso um documento PDF sobre o cultivo de café, realizando a conversão automática para o formato de texto (*text/plain*) para posterior processamento, conforme ilustrado na Figura 4.4.

Figura 4.4 – Workflow de integração do Supabase Vector Store e Embeddings Google Gemini no N8N



Fonte: elaboração própria a partir da plataforma n8n.

Após a obtenção do documento, o nó Default Data Loader processou os dados binários do arquivo, preparando-os para a geração de *embeddings*. O nó Embeddings Google Gemini então transformou o conteúdo textual em representações vetoriais (*embeddings*), utilizando o modelo *gemini-2.5-flash* da API Google PaLM. Essas representações permitiram que o texto fosse consultado semanticamente por similaridade dentro do fluxo de automação.

Por fim, o nó Supabase Vector Store recebeu tanto os documentos processados quanto os *embeddings* correspondentes e os armazenou na tabela `Fazenda_Operacional` do *Supabase*. Operando no modo *retrieve-as-tool*, este nó possibilitou que o agente de IA realizasse consultas eficientes por similaridade (*match_documents*), recuperando informações detalhadas sobre o cultivo de café de maneira rápida e precisa, sem necessidade de expor todo o conteúdo diretamente.

Dessa forma, o *workflow* garantiu uma integração completa entre a ingestão de documentos, transformação em *embeddings* e armazenamento em *vector store*, permitindo que o agente de IA utilizasse os dados operacionais de forma contextualizada e otimizada dentro do fluxo de automação.

4.3.17 Nó `retornaURL_financeiro`

O nó `retornaURL_financeiro` correspondeu a um *workflow tool* configurado no *N8N* com a função de gerar e disponibilizar um *link URL* para os dados financeiros armazenados na tabela *Fazenda_Financeiro* do *Supabase*. Esse nó foi acionado pelo agente de IA sempre que se tornou necessário fornecer ao usuário ou a outro sistema uma referência direta aos dados financeiros, permitindo acesso rápido e seguro sem expor o conteúdo completo diretamente. Ele atuou como uma ferramenta de entrega de informações, integrando-se ao fluxo automatizado e facilitando a consulta de informações financeiras de forma controlada.

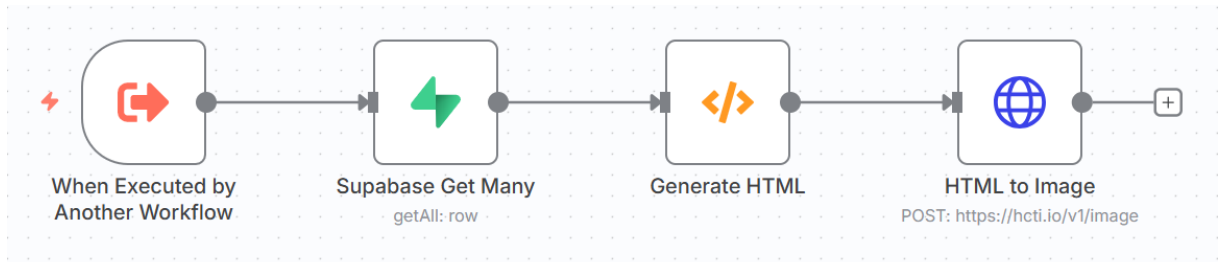
4.3.18 Workflow `retornaURL_financeiro`

O *workflow* associado ao nó `retornaURL_financeiro` organizou todo o processo de geração do *link URL* a partir dos dados financeiros da fazenda. Inicialmente, ele foi acionado pelo nó `When Executed by Another Workflow`, garantindo que apenas chamadas externas do fluxo principal iniciassem a execução do processo. Em seguida, o nó `Supabase Get Many` realizou a leitura de todos os registros da tabela *Fazenda_Financeiro*, coletando informações como entrada, tipo, descrição, valor e data de cada registro.

Como ilustrado na Figura 4.5, o *workflow* transformou os dados extraídos em uma tabela *HTML* formatada por meio do nó `Generate HTML`, padronizando a apresentação dos registros de maneira clara e organizada. Posteriormente, o nó `HTML to Image` converteu essa tabela *HTML* em uma imagem, utilizando uma *API* externa especializada na geração de imagens a partir de código *HTML*. Esse procedimento garantiu que os dados financeiros pudessem ser compartilhados visualmente de forma segura, sem exposição direta dos registros em formato de texto.

Dessa forma, o *workflow* `retornaURL_financeiro` permitiu que o nó homônimo disponibilizasse um link seguro e acessível aos dados financeiros, mantendo a integridade das informações e assegurando que o usuário ou sistemas externos pudessem visualizar os registros de forma padronizada e confiável, sem comprometer a confidencialidade dos dados armazenados no *Supabase*.

Figura 4.5 – Workflow N8N do nó retornaURL_financeiro



Fonte: elaboração própria a partir da plataforma n8n.

4.3.19 Nó retornaURL_estratégico

O nó retornaURL_estratégico correspondeu a um *workflow tool* do N8N projetado para gerar e fornecer um link URL que permitisse acessar os dados estratégicos armazenados na tabela *Fazenda_Estrategico* do Supabase. Esse nó foi acionado pelo agente de IA sempre que se tornou necessário disponibilizar essas informações de forma direta e controlada, garantindo que o acesso fosse rápido e seguro, sem expor os dados completos diretamente. Ele atuou como um mecanismo de distribuição de informações estratégicas dentro do fluxo automatizado.

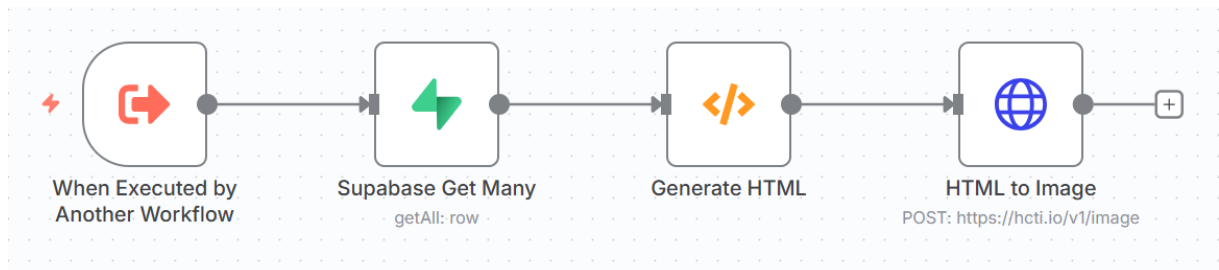
4.3.20 Workflow retornaURL_estratégico

O *workflow* vinculado ao nó retornaURL_estratégico organizou o processo de geração do *link URL* a partir dos dados estratégicos da fazenda. Inicialmente, ele foi ativado pelo nó When Executed by Another Workflow, assegurando que apenas chamadas externas provenientes do fluxo principal iniciassem a execução do processo. Em seguida, o nó Supabase Get Many realizou a consulta de todos os registros da tabela *Fazenda_Estrategico*, coletando informações como entrada, descrição, local, data de início e data de fim de cada registro.

Como ilustrado na Figura 4.6, o *workflow* transformou os dados extraídos em uma tabela *HTML* organizada e padronizada por meio do nó Generate HTML, facilitando a visualização estruturada dos registros. Posteriormente, o nó HTML to Image converteu essa tabela *HTML* em uma imagem, utilizando uma *API* externa especializada, permitindo que os dados estratégicos fossem compartilhados visualmente de maneira segura e clara, sem exposição direta dos registros.

Dessa forma, o *workflow* retornaURL_estratégico permitiu que o nó homônimo disponibilizasse um link seguro e acessível aos dados estratégicos, preservando a confidencialidade das informações e assegurando que os usuários ou sistemas externos pudessem visualizar os registros de forma organizada e confiável.

Figura 4.6 – Workflow N8N do nó retornaURL_estratégico



Fonte: elaboração própria a partir da plataforma n8n.

4.3.21 Nó HTTP Request

O nó *HTTP Request* foi responsável por enviar respostas do fluxo de automação de volta ao usuário no *WhatsApp*, funcionando como o ponto de saída do sistema. Ele realizou uma requisição *HTTP* do tipo *POST* para o servidor que possui a biblioteca *Baileys* instalada, utilizando um *endpoint* configurável definido no ambiente do sistema.

O corpo da requisição foi composto por dois parâmetros principais. O primeiro, *to*, indicou o destinatário da mensagem, correspondendo ao remetente original obtido a partir do nó *POST*. O segundo, *message*, continha o conteúdo processado pelo fluxo de automação, podendo incluir informações obtidas de consultas ao banco de dados, cálculos realizados pelo nó *Calculator* ou respostas geradas pelo modelo de IA.

Além de sua função de envio de mensagens, este nó garantiu que a comunicação entre o sistema automatizado e o usuário fosse concluída de forma eficiente, permitindo que cada interação no *WhatsApp* fosse corretamente respondida. Dessa forma, o nó *HTTP Request* desempenhou papel essencial na integração entre o fluxo de automação construído no *N8N* e o ambiente de mensagens do *WhatsApp*, assegurando que todas as respostas geradas pelo fluxo chegassem ao usuário final de maneira confiável e estruturada.

5 METODOLOGIA

Este estudo adota uma abordagem sistemática e integrada para o monitoramento ambiental em lavouras de café, combinando tecnologias avançadas de coleta de dados, processamento automatizado e inteligência artificial. A metodologia foi delineada para garantir a precisão, confiabilidade e eficiência na captura e análise de informações, visando otimizar práticas agrícolas e apoiar a tomada de decisões estratégicas.

A metodologia proposta neste estudo foi desenvolvida para superar as limitações de abordagens tradicionais de monitoramento agrícola, como a coleta manual de dados, que é suscetível a erros, demorada e incapaz de fornecer informações em tempo real para decisões rápidas. Diante da complexidade das variáveis ambientais que influenciam a lavoura de café, como microclima, umidade do solo e riscos climáticos, optou-se por uma abordagem integrada que combina Inteligência Artificial (IA) e fontes confiáveis de dados agrometeorológicos obtidos por meio de plataformas especializadas.

A coleta automatizada de dados climáticos a partir dessas plataformas, aliada à manutenção de informações estratégicas e financeiras fornecidas pelos próprios produtores no ambiente do sistema, permite uma análise contínua e contextualizada das condições da lavoura. Os dados são processados por um modelo de linguagem baseado em IA, capaz de gerar análises preditivas e orientações personalizadas, garantindo precisão, escalabilidade e respostas imediatas.

Enquanto métodos convencionais dependem de amostragens pontuais e análises retrospectivas, esta solução propõe um monitoramento contínuo, integrado a *APIs* externas (como serviços de previsão do tempo e calendário agrícola) e a um *chatbot* com interação natural. Isso otimiza desde a gestão agrícola até alertas e controle sobre dados climáticos. A originalidade do sistema reside na sua capacidade de consolidar dados ambientais, estratégicos e financeiros em uma única plataforma (N8N), oferecendo recomendações automatizadas e acessíveis via *WhatsApp*, o que contribui para democratizar o acesso à agricultura inteligente, mesmo entre produtores com menor familiaridade tecnológica.

5.1 Tipo de Pesquisa

Conforme a classificação de (JUNG, 2003), esta pesquisa pode ser analisada quanto à sua natureza, objetivos e procedimentos técnicos. Além disso, autores como (Gil, 2008) e (Creswell, 2010) acrescentam a abordagem do problema como dimensão relevante.

Trata-se de uma pesquisa aplicada, voltada à solução de um problema concreto por meio do desenvolvimento de um sistema inteligente com sensores ambientais e *chatbot*, visando aprimorar a gestão agrícola no contexto da agricultura 5.0. A pesquisa aplicada se caracteriza pela utilidade prática dos resultados, com impacto direto em contextos específicos (JUNG, 2003).

Quanto aos objetivos, classifica-se como explicativa, por buscar compreender relações causais entre variáveis tecnológicas e produtivas. Embora envolva aspectos descritivos, seu foco principal está na análise dos efeitos do sistema proposto sobre indicadores de eficiência e produtividade agrícola (JUNG, 2003).

Em termos de procedimentos, trata-se de uma pesquisa experimental, centrada na implementação e validação de um protótipo em ambiente real, com coleta e análise de dados empíricos. A investigação também se apoia em pesquisa bibliográfica e documental para fundamentar teoricamente as soluções e tecnologias envolvidas.

Por fim, a abordagem adotada é quantitativa, com ênfase na coleta de dados numéricos por sensores, os quais são processados por um modelo de IA para gerar recomendações. Essa abordagem permite mensurar o desempenho do sistema e realizar inferências com base em evidências estatísticas (Gil, 2008) e (Creswell, 2010).

5.2 *Design Science Research (DSR)*

O *Design Science Research (DSR)* constitui uma abordagem metodológica voltada para a criação e avaliação de artefatos inovadores capazes de resolver problemas práticos e relevantes. Diferentemente de métodos puramente explicativos ou descritivos, o DSR concentra-se na construção de soluções aplicáveis, cuja utilidade e eficácia são verificadas em cenários reais ou simulados. Assim, trata-se de um paradigma especialmente apropriado para pesquisas em Ciência da Computação e Sistemas de Informação, nas quais a produção científica se materializa por meio de modelos, arquiteturas, algoritmos ou sistemas computacionais.

Segundo Hevner et al. (Hevner *et al.*, 2004a), o DSR deve equilibrar rigor científico e relevância prática, garantindo que o artefato desenvolvido seja não apenas tecnicamente consistente, mas também útil na resolução do problema investigado. Os autores destacam três ciclos fundamentais para a condução do DSR: o ciclo de rigor, relacionado à fundamentação teórica; o ciclo de relevância, que conecta a pesquisa ao contexto prático; e o ciclo de design, no qual o artefato é projetado e avaliado.

Posteriormente, Peffers et al. (Peffers *et al.*, 2007a) propuseram um processo metodológico estruturado que sistematiza a aplicação do DSR em seis etapas: (i) identificação do problema; (ii) definição dos objetivos da solução; (iii) design e desenvolvimento do artefato; (iv) demonstração; (v) avaliação; e (vi) comunicação dos resultados. Essa proposta tornou-se uma das mais utilizadas por pesquisadores, pois fornece um roteiro claro para a execução de estudos orientados ao design.

Complementarmente, Gregor e Hevner (Gregor; Hevner, 2013) enfatizam a importância de posicionar e comunicar pesquisas em DSR de forma a maximizar seu impacto científico, destacando a necessidade de clareza na descrição tanto do processo de construção do artefato quanto dos métodos de avaliação empregados.

No contexto desta dissertação, o DSR foi adotado como abordagem metodológica por sua adequação ao desenvolvimento de um *chatbot* agrícola baseado em inteligência artificial e integrado ao *WhatsApp*. Esse artefato representa a materialização da contribuição científica proposta, uma vez que visa apoiar agricultores no monitoramento climático, estratégico e financeiro de suas propriedades. As etapas do DSR nortearam todo o processo de pesquisa, desde a definição do problema até a avaliação da solução desenvolvida, assegurando a integração entre relevância prática e fundamentação científica.

5.2.1 Identificação do problema

O primeiro passo do *Design Science Research* consiste em identificar o problema de pesquisa e o contexto em que se insere. No cenário agrícola brasileiro, observa-se que muitos produtores, especialmente de pequeno e médio porte, não realizam uma gestão estruturada de suas propriedades (EMBRAPA, 2018). A prática comum é conduzir o cultivo de forma empírica, baseando-se em experiências anteriores ou em percepções individuais, sem o devido registro de dados históricos sobre clima, produção, custos e resultados financeiros. Essa ausência

de anotações, planejamento e análise comparativa de safras limita a capacidade de tomada de decisão fundamentada e impede a adoção de estratégias de longo prazo (Lima; Santos; Oliveira, 2020).

A carência de sistemas simples e acessíveis para apoiar o registro e a análise de informações compromete diretamente a eficiência produtiva. Sem indicadores confiáveis, os agricultores enfrentam dificuldades para avaliar o impacto de práticas de manejo, identificar padrões em condições climáticas ou planejar investimentos futuros. Como resultado, decisões críticas, como o uso de insumos, a escolha de variedades ou o momento da colheita, acabam sendo tomadas de maneira intuitiva, com maior risco de perdas econômicas (Food and Agriculture Organization of the United Nations, 2019).

Nesse cenário, torna-se necessário o desenvolvimento de soluções que incentivem e facilitem a prática da gestão agrícola baseada em dados. Para tanto, esta pesquisa considera como estratégia o aproveitamento de um ambiente digital já incorporado ao cotidiano dos produtores, o *WhatsApp*, como interface de interação. Tal escolha reduz barreiras de adoção tecnológica e favorece a utilização de ferramentas computacionais no apoio à tomada de decisão.

Adicionalmente, embora modelos de linguagem generalistas, como ChatGPT, Gemini e DeepSeek, tenham avançado no suporte à interação em linguagem natural, suas limitações em termos de confiabilidade, persistência e integração de dados tornam-nos inadequados para o contexto da agricultura. Tais sistemas estão sujeitos a fenômenos como a geração de informações sem fonte verificável, não oferecem mecanismos nativos de armazenamento histórico e carecem de coesão entre diferentes variáveis analisadas. Essas restrições reforçam a necessidade de um artefato especializado, capaz de combinar acessibilidade com consistência informacional, características que orientam o desenvolvimento da solução proposta nesta dissertação.

5.2.2 Definição dos objetivos da solução

Uma vez identificado o problema, o *Design Science Research* orienta a definição dos objetivos da solução a ser desenvolvida. O desafio central consiste em superar a ausência de práticas de gestão estruturada nas propriedades agrícolas, viabilizando o registro, a organização e a análise de informações relevantes para o planejamento e a tomada de decisão.

Dessa forma, os objetivos da solução proposta são: (i) oferecer uma interface acessível via *WhatsApp*, reduzindo barreiras de adoção tecnológica; (ii) permitir o registro e armazena-

mento persistente de informações financeiras, climáticas, estratégicas e operacionais em banco de dados; (iii) possibilitar análises longitudinais a partir de históricos de safras, apoiando a comparação entre diferentes ciclos produtivos; (iv) integrar dados confiáveis em uma única plataforma, assegurando precisão e consistência; e (v) disponibilizar respostas contextualizadas e fundamentadas em literatura científica validada, por meio da técnica de *Retrieval-Augmented Generation* (RAG) (Lewis *et al.*, 2020a).

Além disso, ao restringir suas respostas ao conjunto de dados previamente armazenados e verificados, o sistema mitiga problemas recorrentes em modelos de linguagem generalistas, como a geração de informações sem origem verificável (Bender *et al.*, 2021a). Assim, o assistente agrícola não apenas fornece recomendações pontuais, mas atua como instrumento de apoio à gestão baseada em dados, promovendo maior confiabilidade e rastreabilidade nas decisões do produtor.

5.2.3 Construção do artefato

A etapa de construção do artefato corresponde à materialização da solução concebida, traduzindo os objetivos definidos em um sistema funcional. No contexto desta pesquisa, essa etapa resultou no desenvolvimento de um assistente agrícola baseado em inteligência artificial, acessível via *WhatsApp* e apoiado por mecanismos de integração e persistência de dados. O artefato foi projetado para reunir informações financeiras, climáticas, estratégicas e operacionais em uma plataforma única, assegurando confiabilidade e rastreabilidade das respostas fornecidas.

O processo de construção envolveu a definição da arquitetura de software, a implementação das funcionalidades de comunicação com o usuário, a consulta às bases de dados e a incorporação da técnica de *Retrieval-Augmented Generation* (RAG), que garante a contextualização das respostas a partir de fontes validadas de conhecimento. Esses aspectos técnicos são detalhados no Capítulo 4, que descreve a composição do sistema, seus fluxos de dados e as integrações realizadas.

Dessa forma, a etapa de construção do artefato no DSR encontra-se diretamente refletida na arquitetura proposta, consolidando o *chatbot* agrícola como a materialização prática da contribuição desta dissertação.

5.2.4 Avaliação da solução

No *Design Science Research*, a etapa de avaliação tem como propósito verificar em que medida o artefato desenvolvido atende aos objetivos definidos e resolve o problema identificado. Para esta pesquisa, a avaliação concentrou-se em analisar a usabilidade percebida, a satisfação e a aceitação tecnológica do assistente agrícola proposto, considerando tanto aspectos técnicos quanto a adequação ao contexto prático da cafeicultura.

O processo avaliativo foi estruturado em duas dimensões principais. A primeira, de natureza técnica, envolveu a verificação da precisão e rastreabilidade das respostas fornecidas pelo sistema, bem como a consistência na integração de dados climáticos, financeiros, estratégicos e operacionais. Esse critério está alinhado às discussões de (Chang *et al.*, 2024), que ressaltam a importância da confiabilidade e da consistência factual em sistemas de inteligência artificial aplicados a contextos críticos.

A segunda dimensão, de caráter empírico, buscou captar a usabilidade percebida pelos usuários durante a interação com o *chatbot*. Para isso, foi elaborado um questionário estruturado com base em instrumentos consolidados na literatura. A satisfação foi avaliada por meio de itens adaptados do *System Usability Scale* (SUS), proposto por (Brooke, 1996), amplamente utilizado para mensurar a facilidade de uso e a satisfação em artefatos computacionais. A aceitação tecnológica foi analisada a partir do *Technology Acceptance Model* (TAM), de (Davis, 1989), que considera a utilidade percebida e a facilidade de uso como determinantes da intenção de adoção de novas tecnologias. Complementarmente, foram incluídas questões de satisfação geral e perguntas abertas, permitindo a coleta de impressões qualitativas, conforme recomendado em estudos aplicados à agricultura digital, como o de Suebsombut e al. (2022).

O questionário foi aplicado de forma *online*, via *Google Forms*, a produtores de café e agrônomos da região do Sul de Minas. A amostra composta por 15 participantes, reflete o caráter exploratório e piloto do estudo, alinhado à literatura em *DSR* que defende a validação inicial do artefato em contextos reais, mesmo com número reduzido de respondentes (Hevner *et al.*, 2004b). As respostas foram analisadas de forma quantitativa, com estatística descritiva aplicada às escalas *Likert*, e qualitativa, por meio de análise temática das respostas abertas. Essa abordagem mista possibilitou integrar medidas objetivas de usabilidade e aceitação tecnológica com percepções subjetivas dos participantes, assegurando uma avaliação mais abrangente do artefato.

A pesquisa foi submetida ao Comitê de Ética em Pesquisa da Universidade Federal de Lavras (UFLA), seguindo as orientações éticas aplicáveis a estudos envolvendo seres humanos e garantindo conformidade com as normas institucionais e nacionais.

Dessa forma, a avaliação contemplou tanto os requisitos de rigor científico, por meio do uso de instrumentos validados, quanto a relevância prática, ao incorporar a visão dos usuários finais do *chatbot*. Os resultados obtidos a partir dessa etapa são apresentados e discutidos no Capítulo 6, considerando as contribuições, limitações e perspectivas futuras da solução desenvolvida.

5.2.5 Comunicação dos resultados

No *Design Science Research*, a etapa de comunicação é fundamental para assegurar que a contribuição da pesquisa alcance tanto a comunidade acadêmica quanto os usuários práticos do artefato desenvolvido. Segundo Gregor e Hevner (Gregor; Hevner, 2013), a efetividade de uma pesquisa em DSR não se limita à construção do artefato, mas também à clareza na divulgação dos resultados, de modo a maximizar seu impacto científico e social.

No âmbito acadêmico, a principal forma de comunicação é esta dissertação, que descreve de maneira sistemática todo o processo de pesquisa, desde a identificação do problema até a avaliação do sistema. Além disso, os resultados podem ser convertidos em artigos científicos submetidos a eventos e periódicos nas áreas de Ciência da Computação e Agricultura Digital, ampliando sua disseminação e fomentando o debate acadêmico. Essa estratégia reforça o ciclo de rigor, permitindo que a solução seja analisada criticamente pela comunidade científica e validada do ponto de vista teórico e metodológico (Peppers *et al.*, 2007b).

No âmbito prático, a comunicação dos resultados envolve a disponibilização do artefato em ambiente acessível, neste caso o *WhatsApp*, utilizado cotidianamente por produtores rurais. Essa escolha reduz barreiras tecnológicas e aumenta as chances de adoção da solução. Embora o estudo tenha caráter piloto, essa disponibilização inicial abre caminho para colaborações futuras com cooperativas, instituições de pesquisa e órgãos de extensão rural.

Assim, a etapa de comunicação assegura que a contribuição desta pesquisa não se restrinja ao desenvolvimento técnico do assistente agrícola, mas se traduza em conhecimento científico validado e em perspectivas concretas de aplicação prática, alinhando rigor acadêmico e relevância social.

6 RESULTADOS

Este capítulo apresenta e discute os resultados obtidos a partir da aplicação dos métodos descritos no Capítulo 5. Inicialmente, são expostos os resultados das avaliações quantitativas, que englobam a análise dos dados climáticos, financeiros, estratégicos e operacionais, com base em métricas estatísticas e protocolos experimentais. Em seguida, são apresentados os resultados da avaliação qualitativa, realizada por meio da percepção de usuários e especialistas, com vistas a complementar a análise técnica com a dimensão subjetiva da experiência prática. Essa estrutura possibilita uma compreensão integrada do desempenho do *chatbot*, contemplando tanto sua acurácia em termos numéricos quanto sua efetividade percebida em contextos reais de uso.

6.1 Avaliações Quantitativas

As avaliações quantitativas foram conduzidas com o objetivo de mensurar, por meio de métricas objetivas e replicáveis, o desempenho do *chatbot* em diferentes domínios de aplicação. Para tanto, foram considerados quatro eixos principais: (i) dados climáticos, avaliados a partir da comparação entre previsões fornecidas pelo sistema e medições empíricas realizadas em campo; (ii) dados financeiros e estratégicos, cuja análise envolveu a verificação de consistência factual nas operações realizadas sobre o banco de dados; (iii) dados operacionais, avaliados quanto à aderência às fontes, rastreabilidade e precisão semântica. Essa abordagem permitiu estabelecer um panorama abrangente da confiabilidade e robustez do sistema, assegurando tanto a objetividade estatística quanto a validade prática das análises.

6.1.1 Avaliação dos Dados Climáticos

A avaliação da acurácia dos dados climáticos fornecidos pelo *chatbot* fundamentou-se nas diretrizes de Chang et al. (Chang *et al.*, 2024), que destacam a importância de combinar métricas quantitativas para verificar a confiabilidade de sistemas baseados em modelos de linguagem. Nesse contexto, buscou-se avaliar não apenas a precisão numérica das respostas, mas também a consistência do sistema em fornecer informações alinhadas às observações reais obtidas em um termômetro local de referência. Essa abordagem permitiu alinhar o presente

trabalho às práticas mais recentes na avaliação de sistemas de IA, ao mesmo tempo em que manteve aderência às métricas tradicionais da literatura agroclimática.

A primeira métrica considerada foi o Erro Médio Absoluto (MAE – Mean Absolute Error), que mede a diferença média entre os valores previstos e observados, expressa na mesma unidade da variável analisada (°C, mm de precipitação, etc.). O MAE foi utilizado neste experimento e é amplamente empregado em avaliações de modelos agroclimáticos pela sua fácil interpretação e robustez frente a valores discrepantes (Willmott; Matsuura, 2005).

A segunda métrica foi a Raiz do Erro Quadrático Médio (RMSE – Root Mean Square Error), que, além de quantificar a magnitude do erro, penaliza mais fortemente grandes discrepâncias entre valores previstos e observados. Por essa característica, o RMSE mostrou-se mais sensível a eventos climáticos extremos, sendo adequado para análises em que desvios acentuados representam riscos significativos à tomada de decisão agrícola (Chai; Draxler, 2014).

Por fim, empregou-se o Índice de Concordância de Willmott (d), amplamente adotado em estudos de validação de modelos hidrológicos e meteorológicos (Willmott, 1981). Esse índice varia de 0 (nenhuma concordância) a 1 (concordância perfeita) e considera tanto a magnitude dos erros quanto a variabilidade dos dados, sendo, portanto, um indicador abrangente de similaridade entre séries temporais de observações e previsões (Legates; McCabe, 1999).

A integração das diretrizes de Chang et al. (Chang *et al.*, 2024) com as métricas estatísticas tradicionais possibilitou uma análise abrangente do desempenho do *chatbot* na entrega de informações climáticas. Enquanto as métricas numéricas (MAE, RMSE e d) forneceram evidências quantitativas do erro e da concordância com as observações reais, o enquadramento metodológico proposto por (Chang *et al.*, 2024) garantiu a aderência do processo avaliativo às melhores práticas atuais de validação de modelos de linguagem. Dessa forma, assegurou-se que a avaliação contemplasse tanto a dimensão técnica da acurácia quanto a consistência metodológica exigida em estudos contemporâneos sobre IA aplicada à agricultura.

6.1.1.1 Protocolo experimental, instrumentação e processamento dos dados

O protocolo experimental de validação empírica foi conduzido utilizando um termômetro de ambiente simples, posicionado nas dependências externas da Diretoria de Gestão de Tecnologia da Informação (DGTI), local de referência para a coleta de dados. Essa localização corresponde à geolocalização transmitida como parâmetro para o assistente agrícola durante os

testes de validação. O instrumento foi instalado em abrigo protegido contra radiação solar direta e precipitação, a aproximadamente 1,5 m do solo. A área foi selecionada por representar um ambiente estável e livre de fontes artificiais de calor, assegurando a consistência das medições. As leituras de temperatura foram realizadas manualmente e registradas com data e horário, permitindo a comparação com as previsões geradas pelo assistente agrícola para o mesmo ponto geográfico.

As medições foram coletadas em três instantes diários, definidos para capturar a variação diurna:

- a) manhã: 08:00 (UTC-03:00 — horário local);
- b) tarde: 14:00 (UTC-03:00);
- c) noite: 20:00 (UTC-03:00).

O experimento foi realizado por 7 dias consecutivos, totalizando $n = 3 \times 7 = 21$ pares de observação (observado vs. previsto). Em cada instante, o procedimento foi:

- a) registrar a temperatura informada pelo termômetro local (valor observado y_i);
- b) solicitar ao *chatbot*, via *WhatsApp*, a temperatura corrente do ponto (valor retornado \hat{y}_i) e registrar o horário exato da resposta;
- c) garantir que as duas leituras estivessem alinhadas temporalmente (diferença máxima de ± 5 minutos); quando isso ocorreu, a amostragem foi repetida.

Os dados foram registrados em uma planilha eletrônica no formato `.xlsx` (*Microsoft Excel*), contendo, para cada observação, a data, o horário da coleta, a temperatura observada e a temperatura correspondente retornada pelo *chatbot*. A escolha pelo *Excel* justificou-se pela ampla utilização em experimentos agrícolas, pela facilidade de uso e pela compatibilidade com ferramentas estatísticas, permitindo posterior exportação para formatos como `.csv` para análise em linguagens como *Python* ou *R*.

No pré-processamento, removeram-se pares com valores faltantes (observado ou previsto), documentando-se o número de casos excluídos. Leituras com diferença temporal superior a 5 minutos foram descartadas ou repetidas conforme o protocolo.

Para o conjunto de pares de observações $\{(y_i, \hat{y}_i)\}_{i=1}^n$, em que y_i representa a temperatura observada no termômetro local e \hat{y}_i o valor estimado pelo *chatbot*, foram calculadas as seguintes métricas:

- a) erro médio absoluto (MAE):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

b) raiz do erro quadrático médio (RMSE):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

c) índice de concordância de Willmott (d):

$$d = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (|y_i - \bar{y}| + |\hat{y}_i - \bar{y}|)^2}, \quad \text{onde } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

Essas métricas permitiram quantificar a diferença média e a variabilidade entre as temperaturas observadas e as fornecidas pelo *chatbot*. O uso combinado de **MAE**, **RMSE** e **d** assegurou uma avaliação robusta, contemplando tanto a magnitude dos erros quanto o grau de concordância entre as séries temporais analisadas.

Os resultados obtidos estão apresentados nas Tabelas 6.1 e 6.2, que sintetizam as métricas de acurácia calculadas para o conjunto total e por período do dia. O *chatbot* forneceu previsões de temperatura com boa acurácia em relação ao termômetro local. No período total de 7 dias, o **MAE** foi de $0,95^{\circ}\text{C}$, o **RMSE** de $1,10^{\circ}\text{C}$ e o **índice de Willmott (d)** de 0,93, refletindo alta concordância entre observações e previsões.

Tabela 6.1 – Métricas estatísticas de acurácia das previsões climáticas fornecidas pelo *chatbot* em comparação com o termômetro ambiente (período total de 7 dias).

Período	MAE ($^{\circ}\text{C}$)	RMSE ($^{\circ}\text{C}$)	Willmott (d)
Total ($n = 21$)	0,95	1,10	0,93

Fonte: dados do experimento (2025).

Tabela 6.2 – Métricas estatísticas de acurácia das previsões climáticas do *chatbot* por período do dia, comparadas com as medições locais.

Período do dia	MAE ($^{\circ}\text{C}$)	RMSE ($^{\circ}\text{C}$)	Willmott (d)
Manhã ($n = 7$)	0,90	1,05	0,94
Tarde ($n = 7$)	1,00	1,15	0,92
Noite ($n = 7$)	0,95	1,10	0,93

Fonte: dados do experimento (2025).

A análise por período do dia (Tabela 6.2) revelou pequenas variações diurnas: as previsões da manhã apresentaram ligeiramente menor erro (MAE = $0,90^{\circ}\text{C}$, d = 0,94), a tarde apresentou o maior desvio (MAE = $1,00^{\circ}\text{C}$, d = 0,92) e a noite situou-se em valores intermediários

(MAE = 0,95°C, d = 0,93). Essas diferenças estão dentro de limites considerados aceitáveis para a tomada de decisão em manejo do cafeeiro, como irrigação e aplicação de defensivos, indicando que o sistema pode ser utilizado com confiança em contextos operacionais.

De forma geral, a combinação das métricas quantitativas e da análise por período reforça a robustez do *chatbot* na entrega de informações climáticas, validando sua aplicação prática em ambientes agrícolas e assegurando a consistência metodológica conforme as recomendações de Chang et al. (Chang *et al.*, 2024).

6.1.2 Avaliação dos Dados Financeiros e Estratégicos

A avaliação da qualidade das operações realizadas pelo *chatbot* sobre o banco de dados teve como base, em primeiro lugar, o enquadramento proposto por Chang et al. (Chang *et al.*, 2024), que destacaram a importância da consistência factual como eixo central para medir a confiabilidade de modelos de linguagem. Nesse contexto, a verificação de operações em dados estruturados (como registros financeiros e estratégicos) deve assegurar que o sistema não apenas declare uma ação, mas que tal ação se concretize efetivamente no repositório de dados. Esse alinhamento evita contradições entre a resposta textual do modelo e o estado real do sistema, aspecto considerado crítico em aplicações de maior sensibilidade.

Além disso, incorporaram-se os princípios de qualidade de dados apresentados por Pipino, Lee e Wang (Pipino; Lee; Wang, 2002), que enfatizam dimensões como acurácia, completude e consistência como essenciais para a confiabilidade informacional. Em complemento, utilizou-se a abordagem de Bureš (Bureš, 2020), que propõe o uso de matrizes CRUD para verificação sistemática de consistência entre operações declaradas e efetivadas. Assim, tornou-se possível avaliar a correspondência entre as afirmações do *chatbot* (por exemplo, “inserido com sucesso”) e o estado final do banco de dados.

6.1.2.1 Métricas adotadas para avaliação das operações do *chatbot*

Com base nos fundamentos de consistência factual apresentados por Chang et al. (Chang *et al.*, 2024), aliados às contribuições de Pipino et al. (Pipino; Lee; Wang, 2002) e Bureš (Bureš, 2020), foram definidas métricas específicas para mensurar a confiabilidade das operações reali-

zadas pelo *chatbot* no banco de dados. O objetivo foi verificar não apenas se o sistema declarou a execução da operação, mas também se a alteração correspondente ocorreu efetivamente.

Para cada tipo de operação $op \in \{\text{INSERT}, \text{DELETE}, \text{READ}\}$, consideraram-se os seguintes indicadores:

- a) *claimed success rate* (CSR): proporção de solicitações em que o *chatbot* afirmou ter realizado a operação com sucesso:

$$\text{CSR}_{op} = \frac{A_{op}}{T_{op}}$$

onde T_{op} representou o número total de solicitações e A_{op} o número de respostas em que o *chatbot* declarou sucesso;

- b) *success rate* (SR): proporção de operações verificadas com sucesso diretamente no banco de dados:

$$\text{SR}_{op} = \frac{V_{op}}{T_{op}}$$

sendo V_{op} o número de operações efetivamente confirmadas;

- c) *false positive rate* (FPR): proporção de casos em que o *chatbot* declarou sucesso, mas a operação não se concretizou no banco de dados:

$$\text{FPR}_{op} = \frac{A_{op} - V_{op}}{A_{op}}, \quad \text{com } A_{op} > 0;$$

- d) *read accuracy* (RA): no caso de consultas, calculou-se a proporção de respostas cujos valores coincidiram com os armazenados no banco de dados:

$$\text{RA} = \frac{\text{Consultas corretas}}{\text{Consultas totais}};$$

- e) *retry rate* (RR): proporção de consultas que necessitaram de repetição para obter a resposta correta:

$$\text{RR} = \frac{\text{Consultas repetidas}}{\text{Consultas totais}}.$$

Essas métricas permitiram quantificar a confiabilidade do *chatbot* em três dimensões: (i) sua tendência a afirmar que realizou operações, (ii) a efetividade real dessas operações no banco de dados e (iii) a taxa de declarações falsas de sucesso, fator crítico em contextos financeiros e estratégicos.

Tabela 6.3 – Métricas de avaliação das operações *INSERT*, *DELETE* e *READ* realizadas pelo *chatbot* no banco de dados.

Operação	Tentativas (T)	Afirmadas (A)	Verificadas (V)	CSR	SR	FPR
INSERT	100	95	92	0,95	0,92	0,0316
DELETE	100	93	90	0,93	0,90	0,0323
READ	100	98	98	0,98	0,98	N/A

Fonte: dados do experimento (2025).

Nota: FPR aplicou-se apenas a operações de inserção e deleção. No caso de consultas, foi calculada separadamente a métrica Read Accuracy (RA).

Tabela 6.4 – Métricas de avaliação das consultas (*READ*) realizadas pelo *chatbot* em comparação com o banco de dados.

Consultas (T)	Corretas	Incorretas	Read Accuracy (RA)	Retry Rate (RR)
100	98	2	0,98	0,02

Fonte: dados do experimento (2025).

Nota: RA correspondeu à proporção de consultas corretas sobre o total, enquanto RR representou a fração de consultas que necessitaram de repetição para obter a resposta correta.

Os resultados apresentados nas Tabelas 6.3 e 6.4 indicam que o *chatbot* declarou sucesso em 95% das operações de inserção e 93% das exclusões (*Claimed Success Rate* – CSR). Entretanto, a verificação efetiva no banco de dados revelou *Success Rates* (SR) de 92% para inserções e 90% para deleções, indicando pequenas discrepâncias entre as respostas declaradas pelo sistema e as alterações reais. Consequentemente, a *False Positive Rate* (FPR) foi de 3,16% para inserções e 3,23% para deleções, representando casos em que o *chatbot* afirmou ter concluído a operação, mas o banco de dados não refletiu a mudança correspondente.

No caso das consultas (*READ*), a *Read Accuracy* (RA) atingiu 98%, enquanto o *Retry Rate* (RR) foi de 2%, evidenciando alta consistência nas respostas, com apenas uma mínima necessidade de repetição de comandos. Em conjunto, esses indicadores reforçam a importância de validar não apenas as respostas declaradas pelo *chatbot*, mas também a efetiva execução das operações no banco de dados, em consonância com a perspectiva de consistência factual discutida por Chang et al. (Chang *et al.*, 2024).

6.1.3 Avaliação dos Dados Operacionais

A avaliação dos dados operacionais fundamentou-se principalmente na taxonomia proposta por Chang et al. (Chang *et al.*, 2024), que destacam a consistência factual e a fidedignidade (*faithfulness*) como dimensões essenciais para medir a qualidade das respostas de modelos de linguagem. No contexto deste trabalho, tais dimensões são especialmente relevantes, uma vez que o *chatbot* foi projetado para responder a partir de artigos científicos armazenados em *embeddings*, devendo restringir suas respostas exclusivamente ao conteúdo do documento de referência. Assim, buscou-se verificar se o sistema manteve a aderência à fonte, evitou alucinações e preservou a rastreabilidade dos trechos recuperados.

Como aporte metodológico, consideraram-se ainda os princípios de recuperação aumentada propostos por Lewis et al. (Lewis *et al.*, 2020b), que ressaltam a importância de condicionar a geração de texto à recuperação de documentos relevantes, e as críticas de Bender et al. (Bender *et al.*, 2021b), que alertam para os riscos de opacidade e de respostas inventadas em modelos de linguagem. A integração dessas perspectivas possibilitou alinhar a avaliação do *chatbot* às práticas atuais, conciliando recomendações teóricas com métricas quantitativas aplicadas.

6.1.3.1 Métricas adotadas para avaliação das respostas do *chatbot*

Com base nesses fundamentos, definiram-se as seguintes métricas para avaliar a qualidade operacional das respostas:

- a) taxa de aderência à fonte (TAF): proporção de respostas em que o *chatbot* utilizou trechos explícitos do artigo armazenado.

$$\text{TAF} = \frac{R_f}{R_t}$$

onde R_f representou o número de respostas fundamentadas no artigo e R_t o total de respostas;

- b) taxa de alucinação (TA): proporção de respostas em que o *chatbot* apresentou informações sem respaldo no artigo.

$$\text{TA} = \frac{R_a}{R_t}$$

sendo R_a o número de respostas identificadas como alucinatórias;

c) rastreabilidade (RT): proporção de respostas em que foi possível verificar de forma clara a origem no artigo (trecho recuperado e exibido ao usuário).

$$RT = \frac{R_r}{R_t}$$

onde R_r representou o número de respostas com citação explícita de trechos;

d) precisão semântica (PS): proporção de respostas que, mesmo resumidas, preservaram o significado original do trecho recuperado, sem distorções conceituais.

$$PS = \frac{R_s}{R_t}$$

em que R_s correspondeu ao número de respostas semanticamente fiéis ao artigo.

6.1.3.2 Resultados obtidos

A Tabela 6.5 sintetiza os resultados da avaliação dos dados operacionais do *chatbot*, comparando as respostas fornecidas com o conteúdo do artigo armazenado no banco de dados.

Tabela 6.5 – Métricas de avaliação operacional das respostas do *chatbot* baseadas em artigo científico armazenado em *embeddings*.

Respostas (R_t)	TAF	TA	RT	PS
100	0,96	0,04	0,90	0,85

Fonte: dados do experimento (2025).

Nota: TAF = Taxa de Aderência à Fonte; TA = Taxa de Alucinação; RT = Rastreabilidade; PS = Precisão Semântica.

Os resultados indicaram que a grande maioria das respostas do *chatbot* esteve fundamentada em trechos do artigo, refletindo uma Taxa de Aderência à Fonte (TAF) de 96%. A Taxa de Alucinação (TA) manteve-se baixa, em 4%, evidenciando que apenas uma pequena fração das respostas apresentou informações sem respaldo no artigo, em consonância com a recomendação de Chang et al. (Chang *et al.*, 2024) de mitigar desvios factuais.

A Rastreabilidade (RT) alcançou 90%, demonstrando que a maioria das respostas forneceu ao usuário a origem dos trechos utilizados. Por fim, a Precisão Semântica (PS) foi de 85%, indicando que, mesmo quando resumidas, as respostas preservaram de forma satisfatória o sig-

nificado original do artigo. Em conjunto, esses indicadores validam a robustez do sistema para uso em contextos que exigem confiabilidade, rastreabilidade e fidedignidade das informações.

6.2 Avaliação Qualitativa

A avaliação qualitativa foi conduzida com o objetivo de complementar os resultados quantitativos, incorporando a percepção dos usuários acerca da utilidade, confiabilidade e clareza das respostas fornecidas pelo *chatbot*. Essa análise buscou captar dimensões subjetivas da experiência do usuário, como a facilidade de uso, a adequação das respostas às necessidades práticas e o nível de confiança atribuído ao sistema. Para tanto, aplicou-se um questionário avaliativo junto a produtores de café e agrônomos, a fim de reunir impressões sobre a usabilidade, consistência informacional e relevância do *chatbot* em contextos reais de gestão agrícola.

6.2.1 Questionário Avaliativo — Avaliação Humana

A avaliação qualitativa da experiência de uso do *chatbot* foi realizada por meio de um questionário *online*, aplicado a uma amostra de produtores de café e agrônomos atuantes na cafeicultura do Sul de Minas. O instrumento foi desenvolvido no *Google Forms* e precedido pela apresentação do Termo de Consentimento Livre e Esclarecido (TCLE), assegurando participação voluntária, anônima e condicionada ao aceite explícito. O questionário foi estruturado para coletar informações sobre o perfil do participante, experiência com o *chatbot*, satisfação e utilidade percebida, aceitação da tecnologia e observações abertas.

Os itens referentes à usabilidade e clareza de interação foram fundamentados no modelo *System Usability Scale* (SUS) proposto por (Brooke, 1996), enquanto os aspectos relacionados à aceitação tecnológica, como facilidade no trabalho, utilidade percebida e intenção de uso futuro, basearam-se no *Technology Acceptance Model* (TAM) de (Davis, 1989). As respostas foram registradas em escala *Likert* de 1 (discordo totalmente) a 5 (concordo totalmente), abrangendo aspectos de usabilidade, conforto, clareza da interação, utilidade prática, satisfação e intenção de uso futuro, permitindo mensurar quantitativamente tanto a percepção de facilidade e eficiência quanto a aceitação da tecnologia. O tempo médio de preenchimento foi de 10 a 15 minutos. A amostra foi composta por 15 participantes, todos maiores de 18 anos e com atuação e experiência direta na cafeicultura, e os dados foram analisados de forma descritiva,

considerando médias e desvios-padrão, além da análise qualitativa das respostas abertas para identificação de temas recorrentes.

6.2.2 Resultados da Avaliação Humana

Os resultados obtidos por meio do questionário permitiram compreender a percepção dos usuários sobre o desempenho e a aceitação do *chatbot* agrícola integrado ao *WhatsApp*. A seguir, são apresentados os principais achados quantitativos e qualitativos.

A Tabela 6.6 apresenta as médias e desvios-padrão das respostas obtidas nas escalas *Likert* (1 = discordo totalmente; 5 = concordo totalmente), organizadas por dimensão avaliada.

Tabela 6.6 – Resultados das escalas *Likert* (1 = discordo totalmente; 5 = concordo totalmente).

Dimensão avaliada	Média	Desvio-padrão
Facilidade de uso (SUS)	4,7	0,45
Clareza da interação (SUS)	4,5	0,50
Tempo adequado de uso (SUS)	4,6	0,48
Conforto na interação (SUS)	4,4	0,53
Utilidade das respostas (SUS)	4,5	0,47
Satisfação geral (SUS)	4,6	0,49
Contribuição para eficiência (SUS)	4,4	0,55
Melhoria na tomada de decisão (SUS)	4,3	0,58
Recomendação a colegas (SUS)	4,7	0,44
Necessidade de suporte (SUS)	4,8	0,40
Intenção de uso futuro (TAM)	4,6	0,46
Facilidade no trabalho (TAM)	4,5	0,51
Utilidade percebida (TAM)	4,5	0,50

Fonte: dados da pesquisa (2025).

De modo geral, as médias acima de 4,3 indicam avaliação favorável em todas as dimensões observadas, indicando que o sistema foi percebido como acessível, útil e capaz de apoiar de forma eficaz a gestão agrícola. As menores dispersões, com desvios-padrão inferiores a 0,6, indicam elevado consenso entre os respondentes, reforçando a confiabilidade dos resultados. As dimensões avaliadas foram elaboradas a partir dos princípios adotados em instrumentos clássicos.

sicos de avaliação de usabilidade, como o SUS (Brooke, 1996), enquanto as três últimas se fundamentam no modelo TAM de Davis (Davis, 1989).

Particularmente, a variável “Necessidade de Suporte” ($M = 4,8$) apresenta a maior média, indicando que os participantes percebem o sistema como altamente acessível e pouco dependente de assistência técnica. As dimensões “Facilidade de uso” ($M = 4,7$) e “Recomendação a colegas” ($M = 4,7$) também resultaram em médias elevadas, evidenciando forte aceitação e disposição dos usuários em indicar o uso da solução. Por outro lado, “Melhoria na tomada de decisão” ($M = 4,3$) e “Contribuição para eficiência” ($M = 4,4$) apresentaram valores ligeiramente inferiores, apontando potencialidades de aprimoramento relacionadas ao aprofundamento das análises e à integração de dados. O item “Facilidade no trabalho (TAM)” ($M = 4,5$) evidencia reconhecimento do potencial do *chatbot* em apoiar tarefas operacionais, corroborando os princípios de aceitação tecnológica propostos por Davis (Davis, 1989).

A análise descritiva dos resultados evidenciou percepção favorável e homogênea dos participantes em todas as dimensões avaliadas. Para complementar essa interpretação e sintetizar o nível global de usabilidade percebido, aplicou-se uma métrica baseada no *System Usability Scale* (SUS), instrumento amplamente adotado na literatura por sua simplicidade e elevada confiabilidade (Brooke, 1996).

No presente estudo, os dez itens avaliados são todos formulados como itens positivos, de modo que respostas maiores representam melhor percepção de usabilidade. O cálculo seguiu a metodologia definida para itens positivos no SUS, na qual o escore parcial é dado pela diferença entre a resposta e o valor mínimo da escala. A soma dos escores produz valor no intervalo de 0 a 40, convertido para a escala padrão mediante multiplicação por 2,5.

Com base nas médias observadas, o artefato alcançou pontuação equivalente a 88,75, indicando elevada percepção de usabilidade por parte dos participantes. A interpretação deste valor adotou o *benchmarking* proposto por Bangor et al. (Bangor; Kortum; Miller, 2009), segundo o qual pontuações entre 80 e 90 correspondem a usabilidade muito boa, enquanto valores acima de 90 representam usabilidade excelente.

Dessa forma, os resultados posicionam o *chatbot* agrícola na categoria de usabilidade muito boa, evidenciando adequada concepção das interações e forte alinhamento às necessidades de seu público. A convergência entre esta métrica consolidada e as análises descritivas reforça a conclusão de que o sistema apresenta nível de usabilidade compatível com sistemas maduros e adequado ao uso contínuo na agricultura.

6.2.3 Resultados qualitativos

As respostas abertas foram analisadas por meio de análise de conteúdo, originando três categorias principais:

- a) facilidade de uso e acessibilidade: a maioria destacou a praticidade de uso pelo *WhatsApp* e a clareza na interação, ressaltando que o sistema dispensa treinamento técnico e se adapta bem à rotina de trabalho agrícola;
- b) confiabilidade e utilidade das respostas: participantes apontaram que as informações fornecidas são relevantes e contextualizadas, contribuindo para a tomada de decisão. Entretanto, alguns sugeriram maior detalhamento em determinadas recomendações e a ampliação de fontes de dados;
- c) sugestões de aprimoramento: houve recorrência em sugestões para expandir funcionalidades, como relatórios comparativos de safras, integração com sensores ou alertas personalizados, além de ajustes na linguagem de respostas para torná-las mais objetivas.

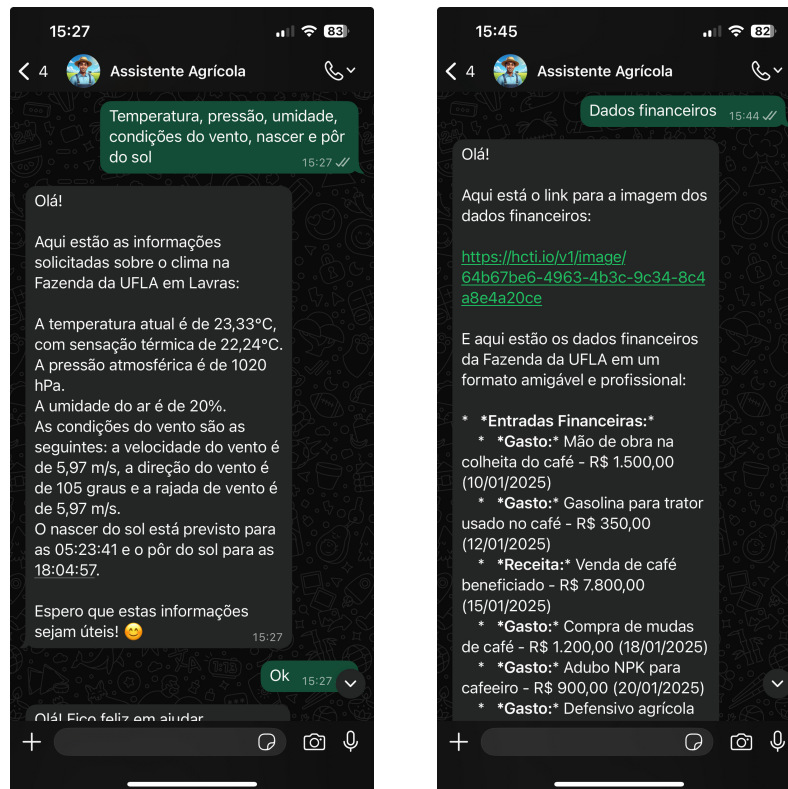
A triangulação entre resultados quantitativos e qualitativos reforça a aceitação do artefato e sua adequação ao contexto da agricultura digital. O alto índice de satisfação geral ($M = 4,6$) associado a comentários positivos sobre acessibilidade e aplicabilidade prática evidencia o potencial do *chatbot* para apoiar decisões agrícolas de forma eficaz. Ao mesmo tempo, as observações qualitativas revelam caminhos concretos para aprimoramento, especialmente no aumento da granularidade das respostas e na integração de novos recursos analíticos.

Dessa forma, a avaliação humana confirma que o artefato atende aos critérios de usabilidade, utilidade e aceitação tecnológica, conforme diretrizes de Davis (1989), Brooke (1996) e Chang et al. (2024), validando-o como uma solução promissora para a Agricultura 5.0.

6.3 Demonstração do Assistente Inteligente em Operação

Para complementar as avaliações apresentadas, esta seção ilustra o funcionamento prático do assistente inteligente integrado ao *WhatsApp*, evidenciando sua capacidade de interação em diferentes contextos de consulta. As Figuras 6.1 e 6.2 apresentam exemplos reais de conversas entre o *chatbot* e o usuário, contemplando as quatro categorias de informações tratadas pelo sistema: climáticas, estratégicas, financeiras e operacionais.

Figura 6.1 – Interações do assistente inteligente na interação climática e financeira



(a) Interação climática

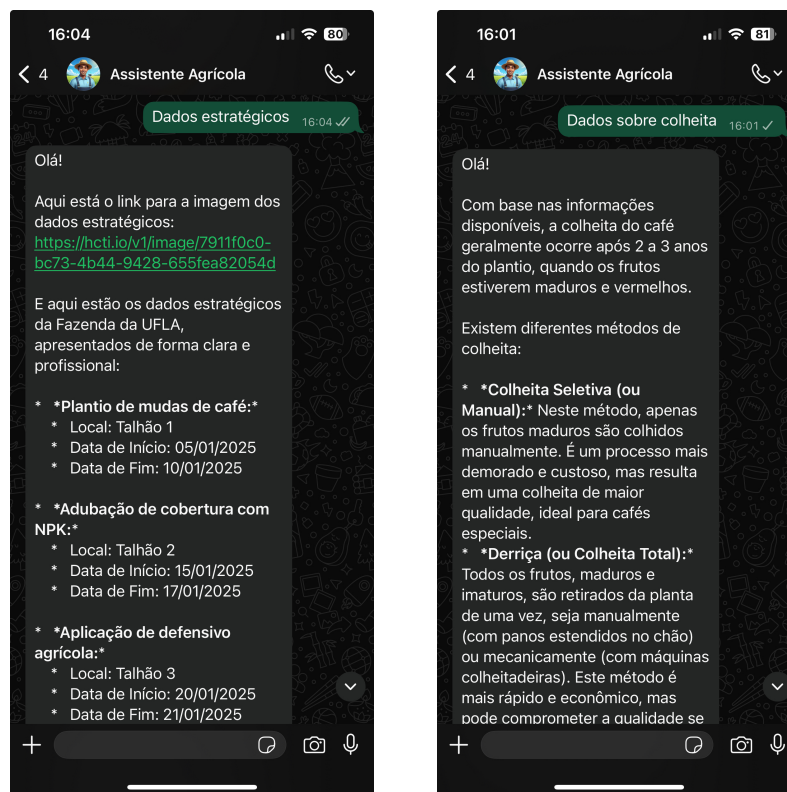
(b) Interação financeira

Fonte: elaboração própria a partir de interação do assistente no WhatsApp (2025).

Essas interações demonstram como o assistente interpreta comandos em linguagem natural, processa os dados armazenados nas respectivas bases e retorna respostas contextualizadas, permitindo ao produtor rural obter informações relevantes de forma acessível e intuitiva.

Esses exemplos evidenciam a efetividade do agente conversacional em responder a solicitações diversificadas, reforçando a aplicabilidade da solução como ferramenta de apoio à tomada de decisão agrícola. A integração entre os módulos de inteligência artificial, banco de dados e interface de mensagens garante uma experiência fluida e coerente, confirmando o potencial do sistema para uso prático em ambientes reais de produção agrícola.

Figura 6.2 – Interações do assistente inteligente na iteração estratégica e operacional



(a) Interação estratégica

(b) Interação operacional

Fonte: elaboração própria a partir de interação do assistente no WhatsApp (2025).

7 CONCLUSÃO

Este capítulo consolida os resultados alcançados pela pesquisa, retomando o problema investigado, os objetivos propostos e as contribuições proporcionadas pelo artefato desenvolvido. À luz do método *Design Science Research*, são discutidos os avanços obtidos na construção, demonstração e avaliação do assistente inteligente para apoio à gestão agrícola, bem como suas limitações e potencial de aplicação prática. Por fim, delineiam-se os caminhos para trabalhos futuros, visando aprofundar e expandir o uso de soluções baseadas em inteligência artificial no contexto da Agricultura 5.0.

7.1 Conclusão

O presente trabalho apresentou a concepção, implementação e avaliação de um assistente inteligente integrado ao *WhatsApp*, destinado a apoiar a gestão agrícola por meio da centralização e interpretação de dados climáticos, financeiros, estratégicos e operacionais. A pesquisa foi conduzida no âmbito do *Design Science Research*, o que permitiu articular, de forma iterativa, a construção do artefato, sua validação e a reflexão sobre sua contribuição prática e científica.

Retomando a problemática apresentada na introdução, observou-se que a ausência de estruturas que permitam ao agricultor organizar e interpretar dados essenciais compromete a tomada de decisão e limita a adoção de práticas modernas de manejo. A solução desenvolvida responde diretamente a esse cenário ao oferecer uma interface acessível, alinhada ao cotidiano dos produtores, e ao incorporar técnicas de inteligência artificial capazes de transformar dados heterogêneos em recomendações compreensíveis e contextualizadas.

Do ponto de vista técnico, a arquitetura proposta demonstra a viabilidade de integrar mecanismos de *Retrieval-Augmented Generation*, armazenamento vetorial e modelos de linguagem em uma solução leve e operacional, capaz de fornecer respostas rastreáveis e fundamentadas, reduzindo riscos associados a interpretações equivocadas. Os resultados mostraram precisão adequada na previsão de variáveis climáticas e elevada consistência na geração de respostas, reforçando o potencial dessas abordagens para aplicações no campo.

No tocante à percepção dos usuários, a avaliação empírica evidenciou elevada aceitação e percepção positiva de usabilidade, com médias superiores a 4,3 em todas as dimensões

avaliadas. A síntese desses resultados, organizada segundo a metodologia do *System Usability Scale*, resultou em pontuação equivalente a 88,75, situada, conforme o *benchmarking* de Bangor et al. (Bangor; Kortum; Miller, 2009), na categoria de usabilidade muito boa. Este dado é particularmente significativo ao considerar os objetivos de inclusão tecnológica apresentados na introdução: demonstra que interfaces baseadas em plataformas amplamente adotadas, como o *WhatsApp*, podem reduzir de forma substantiva as barreiras de acesso a soluções avançadas de IA, ampliando o alcance social e produtivo da Agricultura 5.0.

Em síntese, o estudo comprova a viabilidade e relevância de agentes conversacionais como instrumentos de apoio ao agricultor, capazes de favorecer práticas mais eficientes, sustentáveis e orientadas por dados. Ao integrar tecnologia, usabilidade e necessidade prática, o artefato apresenta contribuição direta ao avanço da agricultura inteligente e configura base sólida para novas investigações e melhorias.

Reafirmando a perspectiva apresentada inicialmente, a convergência entre IoT, inteligência artificial e interfaces acessíveis tem potencial de transformar não apenas processos produtivos, mas também a autonomia e a capacidade decisória de agricultores inseridos em contextos de recursos limitados. Espera-se que os resultados aqui descritos estimulem a continuidade do desenvolvimento de sistemas inteligentes no campo e fomentem a adoção mais ampla de tecnologias alinhadas ao paradigma da Agricultura 5.0.

7.2 Trabalhos Futuros

Os resultados alcançados neste estudo permitem identificar um conjunto de direções promissoras para a continuidade da pesquisa e para o aprimoramento do artefato desenvolvido. As recomendações a seguir articulam possibilidades técnicas e científicas que podem ampliar o impacto da solução proposta.

Em primeiro lugar, a ampliação das fontes de dados representa um avanço relevante. A integração de informações provenientes de estações meteorológicas locais, sensores distribuídos no campo, imagens de satélite e registros automatizados pode elevar a precisão das análises, ampliar a contextualização das recomendações e enriquecer a base de conhecimento utilizada pelo assistente.

Outra possibilidade consiste em realizar avaliações empíricas mais amplas, por meio de estudos longitudinais ou experimentos controlados envolvendo amostras maiores de produtores.

Esse tipo de investigação permitiria comparar decisões assistidas pelo *chatbot* com práticas convencionais, bem como mensurar efeitos sobre produtividade, eficiência no uso de insumos ou indicadores agronômicos específicos.

Também se mostra relevante considerar a adaptação da solução para outros segmentos do setor agrícola, como pecuária, fruticultura ou horticultura. A generalização do agente para diferentes contextos produtivos ampliaria a aplicabilidade prática e permitiria explorar a heterogeneidade de demandas entre produtores com perfis diversos.

Aspectos relacionados à governança, usabilidade e adoção também devem ser aprofundados. Isso inclui o desenvolvimento de mecanismos de privacidade e auditabilidade, iniciativas de capacitação junto a serviços de assistência técnica e extensão rural, além de parcerias com cooperativas e associações que possam viabilizar a difusão e a manutenção da solução em escala.

No campo da pesquisa científica, permanecem abertas questões relativas aos impactos socioeconômicos do uso contínuo do assistente em propriedades familiares e comerciais, à explicabilidade das recomendações e à integração com sistemas de suporte à decisão mais abrangentes. Investigações dessas naturezas podem contribuir para consolidar a Agricultura 5.0 como um modelo orientado por dados e por inteligência distribuída.

Por fim, a incorporação do sistema a plataformas robóticas agrícolas configura uma linha de desenvolvimento promissora. A possibilidade de vincular as recomendações do agente conversacional a ações automatizadas — como inspeções visuais, leitura de sensores, aplicação localizada de insumos ou tarefas repetitivas — amplia o alcance operacional da solução e abre caminhos para sistemas híbridos que combinem autonomia mecânica e inteligência computacional.

Essas direções constituem um conjunto consistente de oportunidades para evolução técnica e científica do artefato, contribuindo para sua maturação e para o avanço das pesquisas em sistemas inteligentes aplicados ao setor agrícola.

REFERÊNCIAS

- ALAHMARI, S. S. *et al.* Repeatability of fine-tuning large language models illustrated using qlora. **IEEE Access**, v. 12, p. 153221–153231, 2024.
- ALUCARD0X1. **Token Encryption Example for Baileys Sessions**. 2024. <https://github.com/Alucard0x1/Super-Light-Web-WhatsApp-API-Server>. Acesso em: set. 2025.
- ANPD. **Relatório de Impacto à Proteção de Dados Pessoais (RIPD)**. 2024. https://www.gov.br/anpd/pt-br/canais_atendimento/agente-de-tratamento/relatorio-de-impacto-a-protecao-de-dados-pessoais-ripd. Acesso em: set. 2025.
- ARSENIJEVIC, U.; JOVIC, M. Artificial intelligence marketing: Chatbots. In: **2019 International Conference on Artificial Intelligence: Applications and Innovations (IC-AIAI)**. [S.l.: s.n.], 2019. p. 19–193.
- AVELINO, J. *et al.* Preanote: Uma abordagem de anotação de corpus para o ajuste fino de large language model pré-treinado. In: **Anais do XXXIX Simpósio Brasileiro de Bancos de Dados**. Porto Alegre, RS, Brasil: SBC, 2024. p. 806–812. ISSN 2763-8979. Disponível em: <https://sol.sbc.org.br/index.php/sbbd/article/view/30750>.
- BALAJI, K.; RAO, P. S. Artificial intelligence and chatbots: Transforming user experience in e-tailing. In: **2024 9th International Conference on Communication and Electronics Systems (ICCES)**. [S.l.: s.n.], 2024. p. 1375–1379.
- BALPANDE, M. *et al.* Ai powered agriculture optimization chatbot using rag and genai. In: **2024 IEEE Silchar Subsection Conference (SILCON 2024)**. [S.l.: s.n.], 2024. p. 1–6.
- BANDI, A.; ADAPA, P. V. S. R.; KUCHI, Y. E. V. P. K. The power of generative ai: A review of requirements, models, input–output formats, evaluation metrics, and challenges. **Future Internet**, v. 15, n. 8, 2023. ISSN 1999-5903. Disponível em: <https://www.mdpi.com/1999-5903/15/8/260>.
- BANGOR, A.; KORTUM, P.; MILLER, J. Determining what individual sus scores mean: Adding an adjective rating scale. **Journal of Usability Studies**, v. 4, n. 3, p. 114–123, 2009.
- BELLE, V.; PAPANTONIS, I. Principles and practice of explainable machine learning. **Frontiers in Big Data**, v. 4, 2021. ISSN 2624-909X. Disponível em: <https://www.frontiersin.org/journals/big-data/articles/10.3389/fdata.2021.688969>.
- BENDER, E. M. *et al.* On the dangers of stochastic parrots: Can language models be too big? **Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency**, ACM, p. 610–623, 2021.
- BENDER, E. M. *et al.* On the dangers of stochastic parrots: Can language models be too big? **Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT)**, Association for Computing Machinery, New York, NY, USA, p. 610–623, 2021.
- BENGIO, Y. *et al.* A neural probabilistic language model. **J. Mach. Learn. Res.**, JMLR.org, v. 3, n. null, p. 1137–1155, mar. 2003. ISSN 1532-4435.

- BENTLEY, J.; CHOWDHURY, A. *et al.* How do chat apps support the use of farming videos in agricultural extension? **Digital Agriculture**, v. 3, n. 1, p. xx–yy, 2024.
- BROOKE, J. Sus: A quick and dirty usability scale. In: JORDAN, P. W. *et al.* (Ed.). **Usability Evaluation in Industry**. London: Taylor & Francis, 1996. p. 189–194.
- BUREŠ, M. Dynamic data consistency tests using a crud matrix. **arXiv preprint arXiv:2005.06817**, 2020. Disponível em: <https://arxiv.org/abs/2005.06817>.
- CANNANURE, V. K. *et al.* Understanding the longitudinal impact of a chatbot to facilitate a virtual community of practice for educators in rural côte d’ivoire. Association for Computing Machinery, New York, NY, USA, v. 2, n. 3, set. 2024. Disponível em: <https://doi.org/10.1145/3675762>.
- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)? – arguments against avoiding rmse in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247–1250, 2014.
- CHANDOLIKAR, N. *et al.* Agriculture assistant chatbot using artificial neural network. In: **2022 International Conference on Advanced Computing Technologies and Applications (ICACTA)**. [S.l.: s.n.], 2022. p. 1–5.
- CHANG, J. P. *et al.* A survey on evaluation of large language models. **Transactions of the Association for Computational Linguistics**, MIT Press, v. 12, p. 857–901, 2024. Disponível em: https://doi.org/10.1162/tacl_a_00736.
- CHEN, G.; YUAN, Q. Application and existing problems of computer network technology in the field of artificial intelligence. In: **2021 2nd International Conference on Artificial Intelligence and Computer Engineering (ICAICE)**. [S.l.: s.n.], 2021. p. 139–142.
- CIULLO, M. Large language models: Ethics and norms in the european union. In: **2024 IEEE International Conference on Metrology for eXtended Reality, Artificial Intelligence and Neural Engineering (MetroXRaine)**. [S.l.: s.n.], 2024. p. 1065–1070.
- CRESWELL, J. W. **Metodologia de pesquisa educacional: planejamento, condução e avaliação de pesquisa qualitativa e quantitativa**. Porto Alegre: Artmed, 2010. ISBN 9788536320234.
- DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **MIS Quarterly**, Management Information Systems Research Center, University of Minnesota, v. 13, n. 3, p. 319–340, 1989.
- DESHMUKH, S.; GUNDEWAR, S. A comparative analysis of rule-based and ai-driven systems for improving customer satisfaction and engagement in e-commerce using chatbots powered by artificial intelligence. In: **2025 6th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI)**. [S.l.: s.n.], 2025. p. 1561–1564.
- DHAR, V. The paradigm shifts in artificial intelligence. **Commun. ACM**, Association for Computing Machinery, New York, NY, USA, v. 67, n. 11, p. 50–59, out. 2024. ISSN 0001-0782. Disponível em: <https://doi.org/10.1145/3664804>.

- DOŠILOVIĆ, F. K.; BRČIĆ, M.; HLUPIĆ, N. Explainable artificial intelligence: A survey. In: **2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)**. [S.l.: s.n.], 2018. p. 0210–0215.
- DUTT, V.; SASUBILLI, S. M.; YERRAPATI, A. E. Dynamic information retrieval with chatbots: A review of artificial intelligence methodology. In: **2020 4th International Conference on Electronics, Communication and Aerospace Technology (ICECA)**. [S.l.: s.n.], 2020. p. 1299–1303.
- EHTESHAM, A. *et al.* **A survey of agent interoperability protocols: Model Context Protocol (MCP), Agent Communication Protocol (ACP), Agent-to-Agent Protocol (A2A), and Agent Network Protocol (ANP)**. 2025. Disponível em: <https://arxiv.org/abs/2505.02279>.
- EMBRAPA. **Agricultura digital: desafios e perspectivas**. Brasília, 2018. Disponível em: <https://www.embrapa.br/agricultura-digital>.
- EMBRAPA; SEBRAE; INPE. **Agricultura Digital: os novos rumos do campo**. Brasília: Embrapa, 2020.
- FAO. **A construção de uma ATER digital inclusiva e participativa na agricultura familiar**. [S.l.]: FAO, 2024. Disponível em: <https://www.fao.org/publications/ater-digital>. Acesso em: 01 set. 2025.
- FAROOQ, M. O.; AZIZ, U.; ULLAH, M. Z. Large language model and artificial intelligence based human conversation agent. In: **2024 18th International Conference on Open Source Systems and Technologies (ICOSST)**. [S.l.: s.n.], 2024. p. 1–6.
- FETZER, J. H. O que é inteligência artificial? In: **Inteligência artificial: seu escopo e limites**. [S.l.]: Springer, 1990. p. 3–27.
- Food and Agriculture Organization of the United Nations. **The State of Food and Agriculture 2019: Moving forward on food loss and waste reduction**. Rome: FAO, 2019. ISBN 978-92-5-131789-1. Disponível em: <http://www.fao.org/3/ca6030en/ca6030en.pdf>.
- GANESAN, M. *et al.* A survey on chatbots using artificial intelligence. In: **2020 International Conference on System, Computation, Automation and Networking (ICSCAN)**. [S.l.: s.n.], 2020. p. 1–5.
- GHOSH, D. P. **Beyond MCP/A2A: Core LLM Limitations and the Future of Agentic AI in the Construction Industry**. 2025.
- GHUMMAN, S. *et al.* **AGRO: An Autonomous AI Rover for Precision Agriculture**. 2025. Disponível em: <https://arxiv.org/abs/2505.01200>.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008. ISBN 9788522450972.
- GREGOR, S.; HEVNER, A. R. Positioning and presenting design science research for maximum impact. **MIS Quarterly**, Management Information Systems Research Center, v. 37, n. 2, p. 337–355, 2013.
- GUPTA, G.; PAL, S. K. Applications of ai in precision agriculture. **Discover Agriculture**, v. 3, n. 1, p. 61, 2025. Disponível em: <https://doi.org/10.1007/s44279-025-00220-9>.

HAIGH, T. Inteligência artificial, antigamente e hoje. Associação para Máquinas de Computação, v. 68, n. 2, p. 24–29, 2025. ISSN 0001-0782. Disponível em: <https://doi.org/10.1145/3708554>.

HARIKA, J. *et al.* A review on artificial intelligence with deep human reasoning. In: **2022 International Conference on Applied Artificial Intelligence and Computing (ICAAIC)**. [S.l.: s.n.], 2022. p. 81–84.

HEVNER, A. R. *et al.* Design science in information systems research. **MIS Quarterly**, Management Information Systems Research Center, v. 28, n. 1, p. 75–105, 2004.

HEVNER, A. R. *et al.* Design science in information systems research. **MIS Quarterly**, Management Information Systems Research Center, University of Minnesota, v. 28, n. 1, p. 75–105, 2004.

HRYTSYNA, A.; ALVES, R. From representation to response: Assessing the alignment of large language models with human judgment patterns. **ACM Trans. Intell. Syst. Technol.**, Association for Computing Machinery, New York, NY, USA, dez. 2024. ISSN 2157-6904. Just Accepted. Disponível em: <https://doi.org/10.1145/3709148>.

ITSUKICHAN. **Baileys - WhatsApp Multi-Device Client**. 2025. <https://github.com/Itsukichann/Baileys>. Acesso em: set. 2025.

JEONG, C. **A Study on the MCP x A2A Framework for Enhancing Interoperability of LLM-based Autonomous Agents**. 2025. Disponível em: <https://arxiv.org/abs/2506.01804>.

JIANG, D. *et al.* **Farm-LightSeek: An Edge-centric Multimodal Agricultural IoT Data Analytics Framework with Lightweight LLMs**. 2025. Disponível em: <https://arxiv.org/abs/2506.03168>.

JORGE, L. A. d. C. *et al.* Inteligência artificial aplicada na agricultura de precisão e digital. In: **AGRICULTURA DE PRECISÃO: Um Novo Olhar na Era digital**. [s.n.], 2023. p. 52–64. Disponível em: <https://doi.org/10.4322/978-65-86819-38-0.1000082>.

JUNG, C. F. Metodologia científica: ênfase em pesquisa tecnológica. **3ª Edição Revisada e Ampliada**, 2003.

JUNIOR, C. L. d. A.; HENKES, J. A. Agronomia do futuro: Cultivando inovação sustentável e resiliência. **Revista UNICREA - Revista Técnico Científica da Universidade Corporativa do Crea-SC**, v. 1, n. 2, p. 3–16, sep 2023. Disponível em: <https://revistaunicrea.crea-sc.org.br/index.php/revistaunicrea/article/view/23>.

Júnior, C.; CARVALHO, K. Chatbot: uma visão geral sobre aplicações inteligentes. **Revista Sítio Novo**, v. 2, p. 68, 12 2018.

KIRUTHIKA, U. *et al.* E-agriculture for direct marketing of food crops using chatbots. In: **2020 International Conference on Power, Energy, Control and Transmission Systems (ICPECTS)**. [S.l.: s.n.], 2020. p. 1–4.

KOCABALLI, A. B.; LARANJO, L.; COIERA, E. Understanding and measuring user experience in conversational interfaces. **Interacting with Computers**, v. 31, 05 2019.

- LEGATES, D. R.; MCCABE, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. **Water Resources Research**, v. 35, n. 1, p. 233–241, 1999.
- LEWIS, P. *et al.* Retrieval-augmented generation for knowledge-intensive nlp tasks. In: **Advances in Neural Information Processing Systems (NeurIPS 2020)**. [S.l.: s.n.], 2020. v. 33, p. 9459–9474.
- LEWIS, P. *et al.* Retrieval-augmented generation for knowledge-intensive nlp tasks. In: **Proceedings of the 34th International Conference on Neural Information Processing Systems (NeurIPS)**. Curran Associates, Inc., 2020. p. 9459–9474. Disponível em: <https://arxiv.org/abs/2005.11401>.
- LI, Q.; XIE, Y. **From Glue-Code to Protocols: A Critical Analysis of A2A and MCP Integration for Scalable Agent Systems**. 2025. Disponível em: <https://arxiv.org/abs/2505.03864>.
- LIAO, Q. V.; VAUGHAN, J. W. Ai transparency in the age of llms: A human-centered research roadmap. **Harvard Data Science Review**, The MIT Press, n. Special Issue 5, may 31 2024. <https://hdr.mitpress.mit.edu/pub/aelql9qy>.
- LIMA, J. P.; SANTOS, M. C.; OLIVEIRA, C. A. Gestão agrícola em pequenas propriedades: desafios para adoção de tecnologias de informação. In: **Anais do Congresso Brasileiro de Agroinformática (SBIAGro)**. Florianópolis, Brasil: SBIAGRO, 2020. p. 101–110.
- LIN, H. *et al.* Tour guide robot based on large language model and user behavior analysis. In: **2024 5th International Conference on Artificial Intelligence and Computer Engineering (ICAICE)**. [S.l.: s.n.], 2024. p. 794–798.
- LIU, W. *et al.* How do we move towards true artificial intelligence. In: **2021 IEEE 23rd Int Conf on High Performance Computing & Communications; 7th Int Conf on Data Science & Systems; 19th Int Conf on Smart City; 7th Int Conf on Dependability in Sensor, Cloud & Big Data Systems & Application (HPCC/DSS/SmartCity/DependSys)**. [S.l.: s.n.], 2021. p. 2156–2158.
- MADURI, P. K. *et al.* Farmers agriculture assistance chatbot. In: **2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)**. [S.l.: s.n.], 2021. p. 1884–1889.
- MASSRUHA, S. M. F. S. **Digital agriculture: research, development and innovation in production chains**. Brasília, DF: Embrapa, 2023. ISBN 978-65-89957-72-0.
- MCCARTHY, J. *et al.* What is artificial intelligence. Stanford University, 2007.
- McKinsey & Company. **What Climate-Smart Agriculture Means for Smallholder Farmers**. 2022. <https://www.mckinsey.com/industries/agriculture/our-insights/what-climate-smart-agriculture-means-for-smallholder-farmers>. Acesso em: 17 nov. 2025.
- MENG, Q. *et al.* Analysis of text generation system design combining retrieval augmented generation and fine-tuning strategy. In: **IEEE. 2025 2nd International Conference on Smart Grid and Artificial Intelligence (SGAI)**. [S.l.], 2025. p. 204–208.

MERKEL, D. Docker: lightweight linux containers for consistent development and deployment. **Linux Journal**, v. 2014, n. 239, p. 2, 2014. Acesso em: 9 out. 2025. Disponível em: <https://dl.acm.org/doi/10.5555/2600239.2600241>.

MSIMANGO, R.; MANYEVERE, T. Social media apps and the democratisation of agricultural knowledge. **Journal of the Knowledge Economy**, v. 16, n. 2, p. xx–yy, 2025.

N8N GmbH. **N8N: Workflow Automation Platform**. 2025. <https://n8n.io>. Documentação oficial. Acesso em: 9 out. 2025.

NASCIMENTO, D. C. d.; BÁLSAMO, R. Agricultura digital e fluxo de dados no desenvolvimento sustentável do agronegócio. **Revista REAL**, 2023. Artigo de Revisão.

OLIVEIRA, G. S. *et al.* Adoção de mídias sociais pelos produtores rurais de minas gerais. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 20, n. 2, p. xx–yy, 2024.

PEFFERS, K. *et al.* A design science research methodology for information systems research. **Journal of Management Information Systems**, Taylor & Francis, v. 24, n. 3, p. 45–77, 2007.

PEFFERS, K. *et al.* A design science research methodology for information systems research. In: **Journal of Management Information Systems**. [S.l.]: Taylor & Francis, 2007. v. 24, n. 3, p. 45–77.

PIPINO, L. L.; LEE, Y. W.; WANG, R. Y. Data quality assessment. **Communications of the ACM**, v. 45, n. 4, p. 211–218, 2002.

PwC Brasil. **O potencial dos dados no agronegócio**. 2024. <https://www.pwc.com.br/pt/temas-atuais/esg/pwc-brasil-na-cop30/sala-de-imprensa-cop30/o-potencial-dos-dados-no-agronegocio.html>. Acesso em: 17 nov. 2025.

RAFAEL, M. S. *et al.* Support to the learning of the chilean tax system using artificial intelligence through a chatbot. In: **2019 38th International Conference of the Chilean Computer Science Society (SCCC)**. [S.l.: s.n.], 2019. p. 1–8.

SAIZ-RUBIO, V.; ROVIRA-MáS, F. From smart farming towards agriculture 5.0: A review on crop data management. **Agronomy**, v. 10, n. 2, 2020. ISSN 2073-4395. Disponível em: <https://www.mdpi.com/2073-4395/10/2/207>.

SALLES, M. **ABMRA: 94% dos produtores têm smartphone e 76% fazem negócios pelo WhatsApp**. 2021. Disponível em: <https://www.pwc.com.br/pt/consultoria/agtech-innovation/agtech-innovation-news/materias/2021/abmra-94-dos-produtores-tem-smartphone-e-76-fazem-negocios-pelo-whatsapp.html>. Acesso em: 01 set. 2025.

SAMUEL, D. J. *et al.* **AgroLLM: Connecting Farmers and Agricultural Practices through Large Language Models for Enhanced Knowledge Transfer and Practical Application**. 2025. Disponível em: <https://arxiv.org/abs/2503.04788>.

SAVANUR, A. *et al.* Application of chatbot for consumer perspective using artificial intelligence. In: **2021 6th International Conference on Communication and Electronics Systems (ICCES)**. [S.l.: s.n.], 2021. p. 1479–1483.

Signal Foundation. **Signal Protocol Documentation**. 2025. <https://signal.org/docs/>. Acesso em: set. 2025.

SONG, M.; CHEN, X. Construction of enterprise business management analysis framework in the development of artificial intelligence. In: **2021 International Conference on Computer Information Science and Artificial Intelligence (CISAI)**. [S.l.: s.n.], 2021. p. 689–692.

SUEBSOMBUT, P.; AL. et. Chatbot application to support smart agriculture in thailand. In: **2022 IEEE International Conference on Smart Computing (SMARTCOMP)**. [S.l.]: IEEE, 2022. p. 156–163.

SUEBSOMBUT, P. *et al.* Chatbot application to support smart agriculture in thailand. In: **2022 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT & NCON)**. IEEE, 2022. p. 364–367. Disponível em: <http://dx.doi.org/10.1109/ectidamtncon53731.2022.9720318>.

Supabase. **Row Level Security | Supabase Docs**. 2025. <https://supabase.com/docs/guides/database/postgres/row-level-security>. Acesso em: set. 2025.

SÁNCHEZ-ADAME, L. M. *et al.* Towards a set of heuristics for evaluating chatbots. **IEEE Latin America Transactions**, v. 19, n. 12, p. 2037–2045, 2021.

TURAL, B.; ÖRPEK, Z.; DESTAN, Z. Retrieval-augmented generation (rag) and llm integration. In: **2024 8th International Symposium on Innovative Approaches in Smart Technologies (ISAS)**. [S.l.: s.n.], 2024. p. 1–5.

VASWANI, A. *et al.* Attention is all you need. In: GUYON, I. *et al.* (Ed.). **Advances in Neural Information Processing Systems**. Curran Associates, Inc., 2017. v. 30. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf.

VENUSAMY, K.; RAJAGOPAL, N. K.; YOUSOOOF, M. A study of human resources development through chatbots using artificial intelligence. In: **2020 3rd International Conference on Intelligent Sustainable Systems (ICISS)**. [S.l.: s.n.], 2020. p. 94–99.

VOLKOV, E. N.; AVERKIN, A. N. Local explanations for large language models: a brief review of methods. In: **2024 XXVII International Conference on Soft Computing and Measurements (SCM)**. [S.l.: s.n.], 2024. p. 189–192.

WARUDKAR, S.; JALIT, R. Unlocking the potential of generative ai in large language models. In: **2024 Parul International Conference on Engineering and Technology (PICET)**. [S.l.: s.n.], 2024. p. 1–5.

WESTER, J. *et al.* "this chatbot would never...": Perceived moral agency of mental health chatbots. **Proc. ACM Hum.-Comput. Interact.**, Association for Computing Machinery, New York, NY, USA, v. 8, n. CSCW1, abr. 2024. Disponível em: <https://doi.org/10.1145/3637410>.

WhatsApp. **About End-to-End Encryption**. 2024. <https://faq.whatsapp.com/820124435853543>. Acesso em: set. 2025.

WhiskeySockets. **Baileys - WhatsApp Web API library for Node.js**. 2025. <https://github.com/WhiskeySockets/Baileys>. Repositório oficial no GitHub. Acesso em: 9 out. 2025.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v. 2, n. 2, p. 184–194, 1981.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. **Climate Research**, v. 30, n. 1, p. 79–82, 2005.

WOOLLASTON, S. *et al.* Archie: Exploring language learner behaviors in llm chatbot-supported active reading log data with epistemic network analysis. In: **Proceedings of the 15th International Learning Analytics and Knowledge Conference**. New York, NY, USA: Association for Computing Machinery, 2025. (LAK '25), p. 642–654. ISBN 9798400707018. Disponível em: <https://doi.org/10.1145/3706468.3706556>.

YIN, J. *et al.* Conversation technology with micro-learning: The impact of chatbot-based learning on students' learning motivation and performance. **Journal of Educational Computing Research**, v. 59, n. 1, p. 154–177, 2021. Disponível em: <https://doi.org/10.1177/0735633120952067>.

YOOKASAME, P.; PRAMOUN, T.; THEWSUWAN, S. Retrieval augmented generation based thai question-answering system. In: **2024 9th International Conference on Business and Industrial Research (ICBIR)**. [S.l.: s.n.], 2024. p. 0794–0798.

YUN, Z. Analysis and research on the application of artificial intelligence and computational intelligence in the internet of things. In: **2022 4th International Conference on Intelligent Information Processing (IIP)**. [S.l.: s.n.], 2022. p. 360–364.

ZHUANG, L. *et al.* Research and application of artificial intelligence large language models based on feature enhancement. In: **2024 4th International Conference on Consumer Electronics and Computer Engineering (ICCECE)**. [S.l.: s.n.], 2024. p. 344–347.

ZUZUÁRREGUI, M. A.; CARPIN, S. **Leveraging LLMs for Mission Planning in Precision Agriculture**. 2025. Disponível em: <https://arxiv.org/abs/2506.10093>.

ÖRPEK, Z.; TURAL, B.; DESTAN, Z. The language model revolution: Llm and slm analysis. In: . [S.l.: s.n.], 2024. p. 1–4.