
Sistema Agroclimático para Previsão de Safras para Pequenos e Médios Agricultores

Bruno Cau de Brito



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

Uberlândia
2026

Bruno Cau de Brito

**Sistema Agroclimático para Previsão de Safras
para Pequenos e Médios Agricultores**

Trabalho de Conclusão de Curso apresentado
à Faculdade de Computação da Universidade
Federal de Uberlândia, como parte dos requisitos
exigidos para a obtenção do título de Bacharel
em Sistemas de Informação.

Área de Especialização: Sistemas de Informação

Orientador: Prof. Dr. Adriano Mendonça Rocha

Uberlândia

2026

Agradecimentos

Gostaria de agradecer, primeiro a Deus, por me dar saúde e por me capacitar para chegar até aqui. Depois, aos meus pais, por todo o suporte durante essa jornada.

Resumo

Este trabalho apresenta a PredAgro, uma plataforma web voltada ao apoio ao planejamento agrícola de pequenos e médios produtores, com foco em análise de risco climático e estimativa de produtividade. A proposta parte da necessidade de oferecer uma solução acessível, explicável e de baixo custo, capaz de integrar dados agrometeorológicos, cadastro de propriedades rurais e regras agronômicas específicas por cultura.

A solução foi desenvolvida com *front-end* em *React*, *back-end* em *Node.js* e persistência no *Firebase*, utilizando o *Firestore* para armazenamento e o *Firebase Authentication* para autenticação. Para a parte climática, foram integradas consultas à *Open-Meteo*, que é uma plataforma gratuita e *open-source* de previsão meteorológica para curto prazo e séries históricas. Na plataforma, a previsão de curto prazo atende à visualização climática do talhão, enquanto o planejamento agrícola utiliza climatologia histórica como base no ciclo analisado. O sistema implementa cadastro de fazendas e talhões, delimitação geográfica em mapa, planejamento por cultura e período, avaliação de riscos por categoria e geração de uma faixa estimada de produtividade.

Os resultados obtidos mostram que a plataforma consegue produzir análises coerentes de acordo com o cenário climático informado, indicando aumento de risco e redução da produtividade estimada em situações adversas, como seca ou chuvas intensas, e maior estabilidade em condições mais próximas das faixas ideais de cultivo (de acordo com a cultura). Conclui-se que a proposta atende ao objetivo de oferecer uma base funcional para apoio à decisão no contexto agrícola, por meio de um sistema agroclimático, baseado em regras agronômicas, parâmetros por cultura e climatologia histórica para o planejamento. A previsão meteorológica de curto prazo é utilizada apenas para a consulta climática do talhão, enquanto o relatório de planejamento se apoia integralmente na climatologia histórica.

Palavras-chave: Predição de safras. Agricultura digital. Agrometeorologia. Agricultura 5.0. Sistema Agroclimático.

Abstract

This work presents PredAgro, a web platform designed to support the agricultural planning of small and medium-sized producers, with a focus on climate risk analysis and productivity estimation. The proposal stems from the need to offer an accessible, explainable, and low-cost solution capable of integrating agrometeorological data, rural property records, and crop-specific agronomic rules.

The solution was developed with a React front-end, Node.js back-end, and Firebase persistence, utilizing Firestore for storage and Firebase Authentication for user access. For the climate component, queries were integrated with Open-Meteo—a free, open-source platform for short-term weather forecasting and historical series. In the platform, short-term forecasting supports the field weather view, while agricultural planning uses historical climatology as the basis for the analyzed cycle. The system implements farm and plot registration, geographic mapping, planning by crop and period, risk assessment by category, and the generation of an estimated productivity range.

The results demonstrate that the platform produces consistent analyses according to the provided climate scenario, indicating increased risk and reduced estimated productivity in adverse situations, such as drought or intense rainfall, and greater stability in conditions closer to ideal cultivation ranges (according to the specific crop). It is concluded that the proposal fulfills the objective of offering a functional basis for decision support in the agricultural context through an agroclimatic system based on agronomic rules, crop parameters, and historical climatology for planning. Short-term weather forecasting is used only for the field weather view, while the planning report relies entirely on historical climatology.

Keywords: Crop yield prediction. Digital agriculture. Agrometeorology. Agriculture 5.0. Agroclimatic System.

Lista de ilustrações

Figura 1 – Evolução da Agricultura do 1.0 ao 5.0.	24
Figura 2 – O que o produtor faz na PredAgro.	39
Figura 3 – Diagrama Entidade-Relacionamento da plataforma (Parte 1 de 2). . . .	47
Figura 4 – Diagrama Entidade-Relacionamento da plataforma (Continuação). . . .	48
Figura 5 – Diagrama de caso de uso da plataforma.	49
Figura 6 – Diagrama de Classes da plataforma.	50
Figura 7 – Fluxo de processo da plataforma (Parte 1 de 2).	51
Figura 8 – Fluxo de processo da plataforma (Continuação).	52
Figura 9 – Painel principal da plataforma.	57
Figura 10 – Cadastro de fazendas e talhões na plataforma.	57
Figura 11 – Visualização de um talhão.	58
Figura 12 – Tela de planejamento de safra.	59

Lista de tabelas

Tabela 1	–	Comparação entre os trabalhos correlatos e a proposta deste trabalho .	34
Tabela 2	–	Pesos dos fatores de risco no modelo do milho 1 ^a safra.	41
Tabela 3	–	Fontes utilizadas para calibrar o planejamento do milho 1 ^a safra	43
Tabela 4	–	Cenários dos testes funcionais	53
Tabela 5	–	Resultados dos testes funcionais	65
Tabela 6	–	Comparação entre os cenários avaliados para o milho 1 ^a safra	66
Tabela 7	–	Resultados do primeiro relatório do <i>Google Lighthouse</i> (modo de desenvolvimento)	67
Tabela 8	–	Resultados do segundo relatório do <i>Google Lighthouse</i> (<i>build</i> de produção)	68

Lista de Abreviações e Siglas

API Application Programming Interfaces

ANN Artificial Neural Network

CLS Cumulative Layout Shift

CONAB Companhia Nacional de Abastecimento

DER Diagrama Entidade-Relacionamento

Embrapa Empresa Brasileira de Pesquisa Agropecuária

FCP First Contentful Paint

FPGA Field-Programmable Gate Array

IA Inteligência Artificial

IBGE Instituto Brasileiro de Geografia e Estatística

IoT Internet das Coisas

INMET Instituto Nacional de Meteorologia

INPE Instituto Nacional de Pesquisas Espaciais

KNN K-Nearest Neighbor

LCP Largest Contentful Paint

MAPA Ministério da Agricultura, Pecuária e Abastecimento

PIB Produto Interno Bruto

REST Transferência de Estado Representacional

SPS Serviço de Previsão de Safras

SPA Single Page Application

SVM Support Vector Machines

SI Speed Index

TBT Total Blocking Time

TCC Trabalho de Conclusão de Curso

TTI Time to Interactive

VHDL VHSIC Hardware Description Language

ZARC Zoneamento Agrícola de Risco Climático

Sumário

1	INTRODUÇÃO	19
1.1	Justificativa	20
1.2	Objetivos	21
1.3	Organização da Monografia	22
2	FUNDAMENTAÇÃO TEÓRICA	23
2.1	Conceitos Fundamentais	23
2.1.1	Agricultura Digital	23
2.1.2	Análise de dados agrometeorológicos	25
2.1.3	Técnicas de previsão de safras	26
2.1.4	Zoneamento Agrícola de Risco Climático (ZARC)	26
2.1.5	Aplicações digitais e mobilidade no agronegócio	27
2.2	Tecnologias	28
2.2.1	<i>React</i>	28
2.2.2	<i>Node.js</i>	28
2.2.3	<i>Firebase</i>	29
2.2.4	<i>Open-Meteo</i>	29
2.2.5	Mapas digitais	29
2.3	Trabalhos Correlatos	30
2.3.1	Síntese dos trabalhos correlatos e posicionamento da proposta	33
3	MÉTODO	35
3.1	Arquitetura da solução	35
3.2	Abordagem de desenvolvimento	35
3.2.1	Organização do desenvolvimento em etapas	36
3.3	Especificações técnicas da implementação	36
3.3.1	Persistência e organização dos dados	36
3.3.2	Mapas, localização e georreferenciamento	37

3.3.3	Consulta climática e cache	38
3.3.4	Climatologia histórica	38
3.3.5	Visão geral da plataforma	38
3.3.6	Estimativa da data final do ciclo	39
3.3.7	Motor de análise de risco	40
3.3.8	Estimativa de produtividade	41
3.3.9	Fontes de calibração do planejamento	42
3.4	Requisitos da solução	43
3.4.1	Requisitos funcionais do usuário	43
3.4.2	Requisitos não funcionais do usuário	44
3.4.3	Requisitos funcionais do sistema	44
3.4.4	Requisitos não funcionais do sistema	45
3.5	Diagramas do sistema	45
3.5.1	Diagrama Entidade-Relacionamento	46
3.5.2	Diagrama de Caso de Uso	49
3.5.3	Diagrama de Classes	49
3.5.4	Fluxo do processo	51
3.6	Avaliação da solução	53
3.6.1	Testes funcionais	53
3.6.2	Avaliação de Desempenho	53
4	PROPOSTA E DESENVOLVIMENTO DO SISTEMA	55
4.1	Contribuição principal	55
4.2	Componentes do sistema	56
4.3	Protótipo implementado	56
4.4	Saídas esperadas	59
4.5	Implementação do núcleo agroclimático	60
4.5.1	Estimativa do ciclo por soma térmica	60
4.5.2	Construção da climatologia histórica	61
4.5.3	Avaliação do risco hídrico com ajuste térmico	61
4.5.4	Estimativa de produtividade a partir dos riscos	62
5	RESULTADOS	65
5.1	Avaliação dos Testes Funcionais	65
5.2	Avaliação do Comportamento do Modelo em Diferentes Cenários	66
5.3	Resultados do <i>Google Lighthouse</i>	67
5.4	Considerações sobre os Resultados	69
6	CONCLUSÃO	71
6.1	Principais Contribuições	71

6.2	Dificuldades e Limitações	72
6.3	Trabalhos Futuros	73
REFERÊNCIAS		75
APÊNDICE A	RELATÓRIO <i>GOOGLE LIGHTHOUSE</i> – PRI- MEIRA ANÁLISE	81
APÊNDICE B	RELATÓRIO <i>GOOGLE LIGHTHOUSE</i> – SE- GUNDA ANÁLISE	89

Introdução

Ao falar sobre o tema “Agronegócio Brasileiro”, os números são inquestionáveis. Segundo (FIESC, 2023), o Ministério da Agricultura, Pecuária e Abastecimento (MAPA) prevê que a produção de grãos no Brasil chegará a 390 milhões de toneladas nos próximos 10 anos, o que representa um aumento de mais de 24%. Além disso, o mesmo Ministério diz que a área de grãos deve aumentar mais de 15% entre 2023/24 e 2033/34, passando de quase 80 milhões de hectares em 2023/24 para mais de 92 milhões em 2033/34 (MAPA, 2024). Esses resultados mostram a tendência de crescimento da produção com ganhos de produtividade. Ademais, é necessário ressaltar a importância e a influência que o setor tem no Produto Interno Bruto (PIB) do país, tendo representado 23,5% do total em 2023, mas que sofreu uma leve queda de 1,5% em 2024, devido a alguns fatores, como: condições climáticas adversas, queda nos preços e menor produção esperada (CEPEA, 2025).

Assim como aconteceu em 2024, o Agronegócio sofre com alguns problemas que, muitas vezes, não podem ser controlados ou previstos, por exemplo, fenômenos da natureza, como pragas, secas, chuvas torrenciais ou enchentes, segundo a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) (EMBRAPA, 2018). Além desses fatores, de acordo com a FERTISYSTEM (2021), existem outros desafios que exercem grande influência sobre o setor e sobre os produtores, incluindo a alta carga tributária, que encarece os insumos e dificulta os investimentos, o desperdício na produção, que gera prejuízo e o impacto ambiental, que degrada o solo e contamina a água. Porém, algumas dessas problemáticas, podem ser previstas com o auxílio de estudos e o com o uso da tecnologia, assim, elas são minimizadas ou até completamente evitadas (SCICROP, 2024).

O início da utilização de tecnologias modernas no setor, é denominada Agricultura 4.0, que é caracterizada por técnicas como edição genômica de safras, monitoramento de variáveis meteorológicas via satélite, uso de *softwares* de gestão agrícola, sensores de controle de pesticidas e irrigação, mapeamento digitalizado de índices de fertilidade, umidade, temperatura e condições físico-geo-químicas do solo (Eduardo Viola; Vinícius Mendes, 2022). A tecnologia hoje é a grande parceira do agronegócio, com suas máquinas, equipamentos e sistemas que garantem o aprimoramento da produção rural. Sendo assim,

produtores podem encontrar soluções tecnológicas que os auxiliem no crescimento dentro do setor e facilitem as operações do campo (FERTISYSTEM, 2021).

Alguns exemplos de tecnologias que são utilizadas hoje em dia para o facilitamento das tarefas diárias são: **Internet das Coisas (IoT)** (dispositivos físico-digitaís aplicados à agricultura de precisão, monitoramento de gado, estufas inteligentes, controle de irrigação, verificação remota de condições climáticas, etc.); **Robôs e sistemas autônomos** (cultivos biodiversos, impressão 3D de alimentos, fertilização aérea via drones); **Inteligência artificial** (controle autônomo de sementes, sistemas inteligentes de classificação e colheita, diagnóstico automatizado de pragas e doenças, *machine learning* para modelagem preditiva de colheitas e preços, reconhecimento computacional de espécies), dentre outras (Eduardo Viola; Vinícius Mendes, 2022). Essas inovações, não só facilitam os afazeres diários de um produtor, como abrem margem para uma importante questão: a previsão de safras.

A previsão de safras é uma estimativa da produção agrícola de um determinado produto, em um determinado período. Ela é feita com base em dados climáticos, imagens de satélites e *softwares* modernos. Atualmente, a previsão é realizada pela Companhia Nacional de Abastecimento (CONAB) e pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Ter esse planejamento é importante para que os produtores possam se preparar para possíveis cenários adversos, como: chuvas intensas, seca, pragas e similares. Além disso, a previsão auxilia o governo a criar políticas públicas específicas para ajudar os produtores durante esse período (caso seja previsto algum problema mais grave) (FIGUEIREDO, 2005; IBGE, 2018).

Tendo em vista a importância atribuída ao processo de previsão de safras, foram feitos diversos estudos e trabalhos na literatura a respeito desse tópico, como por exemplo, o trabalho “O ‘tech’ do agro” (Teixeira Neto, Arthur Palhares, 2022) apresenta pontos que destacam como as inovações tecnológicas podem reduzir custos e riscos nas produções, mostrando os desafios na implantação dessas ferramentas em larga escala. Além desse, o trabalho “Agricultura 4.0” (Zanuto, Arthur Henrique Silva, 2024) discute os benefícios e as barreiras de acesso às tecnologias modernas, evidenciando a necessidade de investimentos e políticas públicas para democratizar o acesso. Para finalizar, o estudo “Detecção de linhas de plantio em plantações de cana-de-açúcar utilizando deep learning” (Ribeiro, João Batista, 2023) demonstra a eficácia do *deep learning* na automação de processos agrícolas, evidenciando o potencial do uso de Inteligência Artificial (IA) para aumentar a precisão das análises no campo.

1.1 Justificativa

Apesar dos avanços tecnológicos e dos benefícios apontados pelos estudos citados, essas soluções costumam exigir dos produtores um alto valor para obtenção de todos os

privilégios oferecidos pelas tecnologias. Pesquisa realizada pela Embrapa, em parceria com o Sebrae e o Instituto Nacional de Pesquisas Espaciais (INPE), com 753 produtores rurais, empresas e prestadores de serviços de todas as regiões brasileiras, aponta que 67% dos agricultores consideram o valor do investimento para aquisição de máquinas, equipamentos e *softwares* o principal desafio para a implantação da transformação digital na propriedade, processo difícil para os pequenos e médios produtores (BOLFE *et al.*, 2020). Por isso, faz-se necessária a criação de uma solução que atenda aos pequenos e médios produtores, de uma forma justa e igualitária, promovendo a democratização do acesso a esses produtos.

1.2 Objetivos

Dessa forma, este trabalho tem como **objetivo geral** oferecer aos pequenos e médios produtores um sistema web capaz de avaliar condições de plantio e apoiar o planejamento agrícola em diferentes períodos e localidades.

O recorte escolhido para a implementação foi o milho 1^a safra, que corresponde ao cultivo realizado na janela principal de plantio, normalmente associada ao início do período chuvoso. Essa escolha foi feita porque o risco agroclimático, as fases da cultura e os parâmetros de produtividade mudam em relação ao milho 2^a safra (ou “safrinha”), exigindo calibrações diferentes. Além disso, o Zoneamento Agrícola de Risco Climático (ZARC) para essa cultura possui aplicação prática voltada também a pequenos e médios produtores (Ministério da Agricultura e Pecuária, 2025a).

Esse propósito se divide nos seguintes **objetivos específicos**:

- ❑ estruturar uma plataforma web capaz de reunir cadastro de fazendas, delimitação geográfica e consulta climática em uma mesma interface;
- ❑ aplicar um modelo agroclimático capaz de estimar fim de ciclo, definir risco climático e produtividade do milho 1^a safra;
- ❑ descrever os requisitos e as decisões de desenvolvimento escolhidas na construção do sistema;
- ❑ avaliar a qualidade do sistema desenvolvido, no que se refere ao desempenho, acessibilidade, SEO e boas práticas de desenvolvimento;
- ❑ explicar, com trechos de código, como o sistema funciona, para que outros pesquisadores possam dar continuidade ou melhorar a solução proposta;
- ❑ avaliar se as saídas geradas pelo sistema se mantêm coerentes em diferentes cenários de planejamento.

Ao democratizar o acesso a esse tipo de solução, espera-se que o sistema gere impactos positivos na vida do público destinado, podendo impulsionar mais a economia do Brasil e o setor, como um todo.

1.3 Organização da Monografia

Esta monografia está organizada da seguinte forma: o Capítulo 1 mostra a **Introdução**, apresentando o problema, explicando a solução proposta, mostrando justificativa e objetivos do trabalho. O Capítulo 2 apresenta a **Fundamentação Teórica**, trazendo os conceitos fundamentais que embasam o tema (Seção 2.1), as principais tecnologias relacionadas (Seção 2.2) e trabalhos correlatos existentes na literatura (Seção 2.3). O Capítulo 3 descreve o **Método** adotado para o desenvolvimento da pesquisa, explicando detalhadamente as etapas necessárias para atingir os objetivos propostos. O Capítulo 4 apresenta a **Proposta e Desenvolvimento do Sistema**, descrevendo a solução idealizada, seus componentes e o protótipo implementado, além dos principais trechos da implementação do núcleo agroclimático (Seção 4.5). O Capítulo 5 reúne os **Resultados**, incluindo a avaliação dos testes funcionais (Seção 5.1), os resultados obtidos com o *Google Lighthouse* (Seção 5.3) e as considerações sobre os resultados (Seção 5.4). Por fim, o Capítulo 6 traz a **Conclusão**, destacando as principais contribuições do trabalho (Seção 6.1) e as possibilidades de trabalhos futuros (Seção 6.3). As **Referências** utilizadas estão listadas ao final da monografia.

Fundamentação Teórica

2.1 Conceitos Fundamentais

Nesse capítulo, serão apresentados conceitos essenciais relacionados ao tema, com destaque nas tecnologias aplicadas ao agronegócio, especialmente à agricultura digital e à IA. Esses conceitos serão detalhados com base em definições, históricos breves, avanços recentes e exemplos práticos, a fim de oferecer uma compreensão clara e fundamentada do texto.

2.1.1 Agricultura Digital

Agricultura digital é o termo que nomeia o conceito que envolve o uso de tecnologias que focam na modernização, automatização e otimização da produção agrícola. Com a digitalização das operações utilizando a agricultura digital, as atividades agrícolas ganham em eficiência e produtividade (FieldView, 2022). Mas nem sempre foi assim, o processo de modernização do setor agrícola, foi (e está sendo) feito em etapas.


Em resumo, foram 4 etapas de evolução. Elas são separadas em: **Agricultura 1.0**, que era baseada na força humana e animal; **Agricultura 2.0**, quando foram introduzidas as máquinas e mecanização; **Agricultura 3.0**, teve como característica o uso de ferramentas para coleta de dados e a automação das atividades no campo, e por fim, a **Agricultura 4.0**, que a partir de meados de 2010, teve a incorporação de tecnologia digital, com uso de IoT e *big data*¹ (Campos Dealer, 2023).

Entretanto, criou-se uma evolução natural da 4.0, que é a **Agricultura 5.0**. A principal diferença entre as duas, é que no modelo mais atual, o humano está no centro. Ou seja, enquanto na versão anterior, o foco era o uso da tecnologia para melhorar performance com automações, nessa, o objetivo principal é empregar tecnologias com capacidades de autoaprendizado, coletando dados para melhorar as ferramentas digitais, por meio de IA,

¹ Refere-se a um conjunto muito grande de dados, que crescem de maneira exponencial, e que sistemas tradicionais de gerenciamento de dados não são capazes de processá-los.

sensores, drones, *softwares* de gestão agrícola, entre outros (Campos Dealer, 2023; EOS Data Analytics, 2022). A Figura 1 sintetiza essa trajetória, apresentando as principais características de cada etapa, da Agricultura 1.0 até a Agricultura 5.0.

Figura 1 – Evolução da Agricultura do 1.0 ao 5.0.



Fonte: (Agroadvance, 2024).

Podemos citar alguns exemplos práticos de agricultores que adotaram soluções tecnológicas e foram beneficiados, como a família Carmo, proprietária de 650 hectares em Pontão, Rio Grande do Sul, que desde 2009 adotou a agricultura de precisão e a inteligência artificial para monitorar e ajustar o plantio de milho e soja com taxas variáveis por área distribuída. Com essas tecnologias, incluindo *softwares* de gestão agrícola, a produtividade das lavouras aumentou significativamente, passando de 55 para 80 sacas por hectare de soja e de 160 para 200 sacas por hectare de milho (Aliger, 2019). Outro exemplo é a empresa Tereos (TEREOS, 1932), que adotou robôs equipados com IA para identificar e remover ervas daninhas de maneira autônoma, reduzindo o uso de herbicidas e aumentando a eficiência operacional de suas plantações (OLIVEIRA, 2024).

Dentro desse contexto, a IA ocupa um papel importante na evolução da agricultura digital. Segundo (BELTRAO, 2024), a Inteligência Artificial é um campo da ciência que simula a capacidade humana de aprender, raciocinar, perceber, tomar decisões e resolver problemas. Na agricultura, seu uso começou a ganhar força a partir dos anos 1980, com sistemas simples de apoio à decisão baseados em dados meteorológicos e condições do solo para otimizar plantio, irrigação e colheita. De acordo com a Solinftec atualmente, essas tecnologias evoluíram significativamente, permitindo análises mais complexas e em maior escala.

De acordo com um estudo divulgado pela Liga Ventures em parceria com o iFood (Renan Honorato, 2024), as *agtechs*² lideram na adoção de inteligência artificial no Brasil, representando 13% das empresas que mais utilizam essa tecnologia. Essas empresas aplicam IA em setores como agricultura de precisão, automação de máquinas e veículos autônomos, mostrando como a inteligência artificial passou a fazer parte do próprio movimento de digitalização do campo.

Podemos citar alguns desses métodos, como o uso de inteligência artificial para **previsão meteorológica**, que é importante para saber o momento ideal para plantio, colheita

² Startups que desenvolvem tecnologias para o agronegócio.

e irrigação, evitando perdas de produção que seriam potencialmente causadas por fenômenos da natureza. Além dela, a **detecção de pragas** pode ser feita por meio de sensores, como a empresa Palmear (PALMEAR, 2023), que criou um sensor acústico, funcionando em tempo real, com o objetivo de identificar árvores que possuem pragas evidentes, usando IA para associar a frequência de som que elas emitem, para detectá-las em segundos. Segundo o site, já foram salvas 120.000 palmeiras e 8400 toneladas de CO₂ com a utilização desse método.

2.1.2 Análise de dados agrometeorológicos

De acordo com o site (Terra Magna, 2022), agrometeorologia é a disciplina que estuda todas as formas e as condições em que o clima influencia o meio rural. Essa influência pode ser boa ou ruim. Isso faz com que ela seja fundamental para as tomadas de decisões no setor, na previsão de safras e na utilização de recursos em geral. Os dados agrometeorológicos são informações meteorológicas que impactam a agricultura, como presença de ventos fortes, ocorrência de granizo, umidade do ar, chuvas e balanço hídrico. O monitoramento desses dados auxiliam no planejamento de atividades como irrigação, aplicação de defensivos agrícolas e preparo do solo. Além disso, possibilita o zoneamento climático, que é fundamental para orientar decisões na área. Entretanto, para isso acontecer, são necessários o uso de plataformas e equipamentos de monitoramento de alta precisão.

Algumas das plataformas que coletam esses dados, são sistemas de informação como o Agritempo, da Embrapa e o Sisdagro, do Instituto Nacional de Meteorologia (INMET). Essas são disponibilizadas no Brasil fornecendo, basicamente, informações de primeiro grau e um pouco das de segundo grau, como: monitoramento de estiagem, precipitação, disponibilidade de água no solo, previsão das condições para colheita, índice de seca, entre outros (Agroadvance, 2022).

Antigamente, esses dados não eram tão fáceis de serem acessados. A coleta era feita manualmente em estações meteorológicas, via registros físicos realizados por técnicos e, posteriormente, enviadas para centros de pesquisa. Com o avanço da tecnologia no agro (e no mundo), essas informações passaram a ser transmitidas de forma mais fácil e acessível, isso por conta da modernização dos processos e ao uso de Application Programming Interfaces (APIs), que permitem a integração direta dos dados entre sistemas, como em uma plataforma digital. Um exemplo disso é o serviço oferecido pela Embrapa, que segundo a (Revista Cultivar, 2022), criou a plataforma AgroAPI, a qual disponibiliza 17 variáveis agrometeorológicas, como temperatura, umidade e velocidade do vento, para todo o território brasileiro. As informações dessas variáveis são atualizadas a cada seis horas e podem ser utilizadas em soluções digitais voltadas ao planejamento agrícola, desde o plantio até a colheita.

2.1.3 Técnicas de previsão de safras

Não é novidade que a previsão de safras se tornou crucial para o setor do agronegócio, mas assim como os dados agrometeorológicos, ela nem sempre foi moderna e acessível. Ao longo do tempo, as técnicas evoluíram bastante, incorporando avanços tecnológicos que aumentaram sua precisão e confiabilidade.

Em 1962, foi criado o Serviço de Previsão de Safras (SPS) pelo Ministério da Agricultura, que começou a operar em 1964, utilizando dados do Imposto Territorial e do Censo Agropecuário. As estimativas eram subjetivas e cobriam 16 produtos (como soja, milho, feijão etc.) em 21 estados, com previsões realizadas nos períodos de plantio, colheita e entressafra³. Em 1966, iniciou-se uma pesquisa experimental com um grupo de pessoas e, em 1969, o Plano Nacional de Estatística Agropecuária recomendou a intensificação do uso de métodos amostrais para aprimorar a precisão das estimativas (IBGE, 2018).

Atualmente, a junção de dados agrometeorológicos, uso de tecnologias como drones, sensores e, principalmente, inteligência artificial, tem revolucionado a forma de se prever as safras. O uso da IA, nesse sentido, aumenta significativamente o nível de leitura de dados, permitindo identificar padrões para diversas áreas, algo que um humano seria incapaz de fazer com a mesma rapidez, devido à sua limitação cognitiva e ao altíssimo volume de informações processadas simultaneamente. Essas inovações têm sido exploradas por instituições como a Embrapa, que criam soluções baseadas em IA para tornar as estimativas de safra mais confiáveis (AGRISHOW, 2024).

Um exemplo explícito do uso de IA para beneficiar o setor, foi feito justamente pela Embrapa, quando pesquisadores, em parceria com algumas universidades, criaram uma metodologia inovadora, que por meio de algoritmos de inteligência, aprimoram o mapeamento da intensificação agrícola no Cerrado. A técnica chegou a mais de 95% de precisão, o que auxiliou diversos agricultores na gestão de suas fazendas (EMBRAPA, 2023).

2.1.4 Zoneamento Agrícola de Risco Climático (ZARC)

O ZARC é uma política pública conduzida pelo MAPA que indica, para cada município, cultura, tipo de solo e grupo de ciclo de cultivar, as janelas de semeadura com menor probabilidade de perda por adversidades climáticas. Publicado por meio de portarias oficiais atualizadas periodicamente, o zoneamento é a principal referência técnica utilizada no país para orientar o momento de plantio e também serve de base para instrumentos como o crédito rural e o seguro agrícola (Ministério da Agricultura e Pecuária, 2025a). Por ser gratuito, oficial e disponibilizado publicamente, o ZARC é especialmente pertinente para pequenos e médios produtores, que nem sempre têm acesso a consultorias agronômicas privadas.

³ Intervalo entre o fim da colheita e o início de outra; período em que a terra fica sem cultivo.

Metodologicamente, o ZARC é construído a partir de modelos agrometeorológicos de balanço hídrico, que cruzam séries históricas de clima, características de retenção de água do solo e as exigências de cada fase da cultura. A partir dessa modelagem, o zoneamento estima o risco climático e classifica as datas de semeadura em faixas — tradicionalmente de 20%, 30% e 40% de risco de perda —, além de dividir o ciclo da cultura em fases fenológicas e agrupar as cultivares por duração de ciclo (por exemplo, ciclos precoce, médio e tardio) (Ministério da Agricultura e Pecuária, 2025b).

Neste trabalho, o ZARC é a fonte central de calibração do modelo agroclimático do milho 1^a safra. Especificamente, foram utilizados os seguintes elementos do zoneamento:

- ❑ **Ciclo de referência:** adotou-se o Grupo II (ciclo médio), com duração total de 120 dias, dividido em quatro fases fenológicas de 15, 45, 40 e 20 dias;
- ❑ **Fases críticas ao déficit hídrico:** as fases I (estabelecimento) e III (floração e enchimento de grãos) são tratadas como as mais sensíveis à falta de água;
- ❑ **Limiar térmico mínimo:** temperatura-base de 10 °C, abaixo da qual o desenvolvimento da cultura é penalizado por frio ou geada;
- ❑ **Excesso de chuva na colheita:** a ocorrência de seis ou mais dias de chuva relevante no final do ciclo (fase IV) é considerada um fator crítico para a colheita.

Esses parâmetros são detalhados e aplicados no modelo descrito no Capítulo 3, garantindo que apenas fatores com amparo técnico oficial sejam considerados na análise de risco.

2.1.5 Aplicações digitais e mobilidade no agronegócio

As aplicações digitais, no contexto agrícola, auxiliam grandemente os produtores rurais, seja para facilitar o planejamento, prevenir ou prever problemas, melhorar a organização e a gestão do campo, entre outras (Biosul Fertilizantes, 2019). O site (Desenvolvimento Rural, 2018) lista diferentes tipos de soluções digitais, com funções que ajudam o produtor agrícola a ganhar performance, ter melhores resultados e facilitar sua rotina.

No início dos anos 2000, essas soluções ainda não tinham a popularidade que possuem atualmente, e no setor agrícola a realidade não era diferente. Naquele período, o acesso à internet e às tecnologias desse tipo era limitado, ficando restrito, em sua maioria, a produtores de médio e grande porte. Porém, com o avanço da tecnologia e com a popularização dos smartphones, navegadores móveis e serviços em nuvem, as plataformas digitais passaram a ganhar espaço na rotina de muitas pessoas, inclusive no meio rural. Essa transformação permitiu que produtores de diferentes perfis e portes passassem a utilizar soluções digitais — como sites e aplicativos — no dia a dia, impulsionando a digitalização do setor.

Nos dias de hoje, a consulta a soluções digitais é parte importante da rotina dos produtores rurais. Segundo o site (Jornal do Agro Online, 2023), mais de 90% dos produtores utilizam aplicativos para saber a previsão do tempo. Esse dado evidencia a importância da mobilidade e da acessibilidade no desenvolvimento de sistemas para o agro, seja por meio de aplicativos ou plataformas web.

A crescente adesão de soluções digitais no setor agrícola não se deve apenas à popularização dos smartphones, mas também ao avanço das tecnologias que as sustentam, como serviços em nuvem, APIs especializadas, integrações com dispositivos IoT e recursos de análise computacional. Sendo assim, na próxima seção, serão apresentadas as principais tecnologias utilizadas no desenvolvimento deste trabalho, detalhando suas características, funcionalidades e justificativas para sua escolha.

2.2 Tecnologias

Para a construção da solução proposta, foram selecionadas tecnologias que permitem o desenvolvimento de uma plataforma web responsiva (que se adapta a qualquer tamanho de tela) e a integração eficiente entre *front-end* (parte visual que os usuários interagem), *back-end* (“motor” que faz o *front-end* funcionar, por trás dos panos), banco de dados, serviços climáticos e recursos de mapas.

2.2.1 *React*

O *React* (Meta Platforms, Inc., 2024) é uma biblioteca *JavaScript* de código aberto, mantida pela empresa Meta. Muito utilizada para o desenvolvimento de aplicações web. Seu principal destaque está na construção de componentes reutilizáveis, o que permite a criação de páginas dinâmicas e de fácil manutenção.

Além disso, o *React* permite a criação de Single Page Application (SPA), onde a navegação entre as páginas ocorre de forma dinâmica, sem precisar recarregar a página a cada alteração. Esse modelo corrobora para uma maior fluidez na interação do usuário.

A escolha do *React* foi feita pela necessidade de desenvolver uma aplicação web moderna e acessível por meio de diferentes dispositivos, principalmente os móveis, que são mais utilizados no dia a dia do público alvo.

2.2.2 *Node.js*

O *Node.js* (DAHL, 2009) é um ambiente de execução *JavaScript* do lado servidor, baseado no motor *V8* do *Google Chrome*. Ele permite a criação de aplicações escaláveis e de alto desempenho, utilizando um modelo assíncrono e orientado a eventos.

No contexto desse Trabalho de Conclusão de Curso (TCC), o *Node.js* é utilizado para implementar o *back-end* do sistema, por meio de uma API Transferência de Estado

Representacional (REST), capaz de intermediar a comunicação entre a plataforma web, o banco de dados e os serviços externos de clima.

2.2.3 *Firestore*

O *Firestore* (GOOGLE, 2014), também desenvolvido pelo Google, é uma plataforma que fornece diversos serviços voltados à criação de aplicações modernas. Para o escopo deste trabalho, foram adotados os seguintes serviços que atendem diretamente às necessidades de autenticação e persistência de dados:

- ❑ ***Firestore***: banco de dados *NoSQL* utilizado para armazenar usuários, fazendas, talhões, planejamentos de safra e dados climáticos;
- ❑ ***Authentication***: serviço de autenticação utilizado no cadastro e login de usuários, com validação de identidade para acesso às rotas protegidas.

A escolha pelo *Firestore* se justifica por sua integração simplificada com *React* e *Node.js*, além de oferecer uma base robusta para autenticação e persistência sem exigir uma infraestrutura própria mais complexa. Além disso, o fato de ser desenvolvido e mantido pelo Google, fornece mais segurança e confiabilidade.

2.2.4 *Open-Meteo*

O *Open-Meteo* (Open-Meteo, 2026) é um serviço de dados meteorológicos acessível por API, com suporte a previsão de curto prazo e consultas históricas com mais de 80 anos. Na PredAgro, ele é utilizado em duas frentes: obtenção de previsão diária para os próximos dias e construção de climatologia histórica para o planejamento agrícola.

Essa escolha é adequada ao contexto do trabalho, porque elimina custos de licenciamento, facilita a integração com a API REST do *back-end* e permite utilizar uma base climática aberta tanto na visualização meteorológica quanto na análise do planejamento.

2.2.5 Mapas digitais

A delimitação geográfica dos talhões é uma parte importante do sistema, pois as consultas climáticas dependem da localização real da área de cultivo. Para isso, a aplicação utiliza bibliotecas baseadas em *Leaflet* (Leaflet contributors, 2026), com dados do *OpenStreetMap* (OpenStreetMap contributors, 2026), para exibir mapas, desenhar a área dos talhões diretamente na interface web etc.

Com esse recurso, o usuário pode delimitar visualmente a área de seus talhões, enquanto o sistema calcula métricas como área em hectares e coordenadas centrais, que são utilizadas na busca de dados na *Open-Meteo*, por exemplo. Na prática, essa conexão deixa

o sistema mais dinâmico e ajuda o agricultor a planejar o trabalho olhando diretamente para o mapa real da sua fazenda.

Em resumo, a combinação entre *React*, *Node.js*, *Firebase*, *Open-Meteo* e bibliotecas de mapas fornece a base tecnológica necessária para o desenvolvimento da plataforma proposta, permitindo a integração entre interface, regras de negócio, persistência e dados agrometeorológicos. Porém, a construção de qualquer trabalho acadêmico exige não apenas a definição de ferramentas e tecnologias, mas também o conhecimento do que já foi feito anteriormente na área. Sendo assim, na próxima seção, serão apresentados e discutidos os principais trabalhos relacionados ao uso de inteligência artificial na agricultura, destacando algumas abordagens existentes, seus resultados e limitações, com o objetivo de situar este trabalho dentro do cenário atual do tema.

2.3 Trabalhos Correlatos

Essa seção apresenta uma revisão da seleção dos principais trabalhos relacionados ao tema. A análise desses estudos busca embasar a pesquisa, mostrando resultados relevantes no mundo acadêmico, e destacando a importância da aplicação do assunto no contexto global.

A pesquisa de Gomes (2024) teve como objetivo desenvolver modelos para prever a produtividade da palmeira macaúba, uma planta com potencial para produção de óleo vegetal, utilizando algoritmos de aprendizado de máquina. O trabalho foi feito com base em dados coletados de áreas experimentais em Minas Gerais, considerando informações como características do solo, clima e atributos das plantas. Foram testados vários algoritmos, como Regressão Linear Múltipla, *Random Forest*, *XGBoost* e Redes Neurais Artificiais, com o objetivo de verificar qual teria melhor desempenho nas previsões. Os modelos foram avaliados por métricas como o erro médio absoluto (MAE) e o coeficiente de determinação (R^2). Os resultados mostraram que os algoritmos baseados em árvores, como o *XGBoost* e o *Random Forest*, apresentaram melhor desempenho, com capacidade de prever a produtividade com boa precisão. A pesquisa reforça o uso de técnicas modernas de análise de dados na agricultura, oferecendo uma alternativa viável para auxiliar o planejamento agrícola. Em relação a este trabalho, o estudo é aderente por confirmar o potencial preditivo de variáveis de solo e clima; contudo, não é diretamente acessível ao pequeno produtor, pois depende de coleta de dados em campo e de modelos de aprendizado de máquina que exigem conhecimento técnico avançado.

O trabalho apresentado por Junior (2023) propõe o desenvolvimento de um protótipo de inteligência artificial voltado para aplicação na agricultura, utilizando uma porta lógica programável — em inglês, *Field-Programmable Gate Array (FPGA)* — como plataforma de implementação. A pesquisa surgiu com a necessidade de buscar soluções tecnológicas eficientes e de baixo custo para o setor agrícola, especialmente em regiões que não possuem

acesso constante à internet. O projeto usa uma Rede Neural Artificial simples, capaz de classificar tipos de solo com base em dados previamente fornecidos. A rede foi treinada fora do FPGA e depois implementada usando VHSIC Hardware Description Language (VHDL), que é uma linguagem de descrição de *hardware* que permite projetar, simular e documentar sistemas digitais. Os testes demonstraram que a proposta é viável e pode ser usada em ambientes reais, contribuindo com a automação e a inteligência no campo, sem depender de conexões com servidores externos. Isso mostra como a IA pode ser adaptada para funcionar em dispositivos embarcados, com foco em aplicações práticas e acessíveis. Para esta proposta, o trabalho é aderente ao objetivo de oferecer soluções de baixo custo e sem dependência constante de internet; entretanto, a acessibilidade ao pequeno produtor é apenas parcial, já que exige *hardware* dedicado (FPGA) e conhecimento de projeto de sistemas embarcados.

O artigo de Vasconcelos *et al.* (2025) trata de um projeto desenvolvido no contexto da agricultura na região Amazônica, onde muitas áreas ainda não possuem tecnologias modernas para melhorar a produção e o cuidado com os animais. A pesquisa propõe o uso da inteligência artificial como uma ferramenta educativa e prática para o controle de ambientes voltados ao bem-estar animal. Para isso, foi criado o sistema 'Ovindeck', que usa sensores conectados a uma IA, capaz de tomar decisões com base em dados do ambiente, como temperatura, umidade e luminosidade. As tecnologias envolvidas incluem o uso de Arduíno, sensores ambientais, automação e uma rede neural treinada com exemplos de variações ambientais. Com uma precisão próxima de 99%, comprovada em testes realizados na região amazônica, o *software* tem um enorme potencial de crescimento e de reconhecimento em nível nacional, auxiliando os criadores da região, comprovando mais uma vez, que o uso adequado de inteligência artificial pode trazer diversos benefícios para o setor. Ainda que voltado ao bem-estar animal, e não à predição de safras, o estudo é aderente por demonstrar o uso de IA de baixo custo no meio rural; sua acessibilidade ao pequeno produtor é parcial, pois depende da instalação de sensores e da montagem de *hardware* pelo próprio usuário.

O texto de Preite e Vignali (2024) trata de um grande problema atual: o uso excessivo de água na agricultura. Como esse setor é responsável por cerca de 70% da água doce usada no mundo, os autores propõem uma solução baseada em inteligência artificial para melhorar o controle da irrigação. O projeto foi testado em um cultivo de tomates na Itália, onde foi criado um laboratório experimental com sensores de solo, clima e um sistema de previsão do tempo. Os dados eram coletados a cada 10 minutos e usados para treinar três algoritmos de aprendizado de máquina: K-Nearest Neighbor (KNN) (vizinho próximo), Support Vector Machines (SVM) (máquina de vetores de suporte) e Artificial Neural Network (ANN) (rede neural artificial). O sistema foi capaz de prever quatro situações diferentes de irrigação e escolher quando ligar, desligar, manter ou alertar o produtor. Todos os modelos tiveram alta precisão (próximas de 99%), mas a rede neural

teve o melhor desempenho, com menos erros nas previsões. Com isso, o sistema conseguiu economizar de 14,5% a 27,6% de água e de 49,2% a 57% de energia, mostrando que a IA pode ajudar muito na agricultura de forma eficiente e sustentável. Este trabalho compartilha com a presente proposta o uso de dados climáticos para apoiar decisões no campo, mas o foco na irrigação automatizada o torna pouco acessível ao pequeno produtor, pois requer sensores de solo e uma estação experimental instalada na lavoura.

O artigo de Uribeetxebarria, Castellón e Aizpurua (2023) investiga como a combinação de dados dos satélites *Sentinel-1* (radar) e *Sentinel-2* (óptico) podem melhorar a previsão da produtividade do trigo. O estudo foi feito com dados de 39 lavouras na Espanha, usando 13 índices de vegetação e valores de retroespalhamento obtidos em três fases do ciclo da planta. Foram testados quatro algoritmos de aprendizado de máquina — regressão linear múltipla (MLR), máquinas de vetor de suporte (SVM), *random forest* (RF) e o algoritmo *CatBoost* — e o *CatBoost* obteve os melhores resultados, com RMSE (índice de erro médio) de 0,24 t/ha, rRMSE de 3,46% e R^2 de 0,95. A combinação dos dados dos dois satélites reduziu o erro em 30% em relação ao uso isolado do *Sentinel-2*, e a média de erro absoluto para prever uma lavoura com base nas demais foi de 4,38%. Os autores concluem que essa abordagem permite criar mapas de produtividade precisos com 10 metros de resolução, úteis para agricultores mesmo sem monitor de colheita. A pesquisa é aderente por reforçar a relação entre dados ambientais e produtividade, porém não é acessível ao pequeno produtor, uma vez que depende do processamento de imagens de satélite e de conhecimento especializado em sensoriamento remoto.

O trabalho de Pereira, Beker e Schmoeller (2024) teve como objetivo responder uma pergunta bem prática: é possível prever quanto uma lavoura vai produzir só olhando o clima? Para isso, os autores juntaram dados do tempo (temperatura, umidade do ar, radiação solar e evapotranspiração) de 47 municípios do oeste do Paraná, ao longo de 14 anos (de 2008 a 2022). Em cima desses dados, eles testaram três modelos de aprendizado de máquina: Regressão Linear, *Random Forest* e o *Extreme Gradient Boosting*. O *Random Forest* foi o que mais se saiu bem, acertando bastante as previsões (com um R^2 de 0,86 no treino e 0,81 no teste), enquanto a Regressão Linear simples praticamente não funcionou. No fim das contas, o estudo mostra que é possível estimar a produtividade de um jeito confiável usando só informações climáticas, o que ajuda muito o produtor a se planejar melhor. Este é um dos trabalhos mais próximos da proposta, por estimar a produtividade utilizando apenas dados climáticos públicos; a acessibilidade, no entanto, é parcial, já que os modelos de aprendizado de máquina empregados ainda exigem conhecimento técnico que o produtor normalmente não possui.

Em vez de criar mais uma ferramenta nova, Chagas e Zamberlan (2025) resolveram analisar plataformas já existentes. Eles fizeram uma revisão de estudos publicados entre 2015 e 2025 sobre sistemas que ajudam o produtor a tomar decisões no campo, juntando informações de clima e de previsão de colheita. Ao organizar tudo, perceberam que

esses sistemas costumam seguir três caminhos: uns funcionam por regras prontas, outros por modelos matemáticos e os mais modernos usam aprendizado de máquina. E foi justamente o aprendizado de máquina que apresentou os melhores resultados, errando bem pouco nas previsões (com erros abaixo de 10% em alguns casos). Mesmo assim, os autores chamam atenção para problemas que ainda atrapalham, como a falta de dados em algumas regiões e a dificuldade de fazer um modelo treinado num lugar funcionar bem em outro. Esse trabalho é interessante porque mostra um panorama geral da área e ajuda a entender onde uma solução como a deste projeto se encaixa. Por se tratar de uma revisão, ele não é, em si, uma ferramenta acessível ao produtor, mas é altamente aderente à proposta, pois evidencia justamente a lacuna que este projeto busca preencher: sistemas de apoio à decisão que sejam, ao mesmo tempo, confiáveis e acessíveis a pequenos e médios produtores.

Já o estudo de Aparecido *et al.* (2020) teve como foco principal falar sobre o milho. Os autores quiseram montar um modelo capaz de prever a produtividade do milho safrinha no estado do Mato Grosso do Sul a partir do clima da região. Para isso, usaram uma série histórica bem longa, de 1983 a 2018, com várias informações do tempo, como radiação solar, temperaturas média, máxima e mínima, umidade do ar, velocidade do vento e chuva. Com tudo isso, conseguiram um modelo estatisticamente confiável e com boa precisão para estimar quanto a lavoura renderia em diferentes condições. Esse trabalho reforça uma ideia central deste projeto: o clima tem peso enorme no resultado final da safra de milho, e olhar para o histórico climático de uma região é um caminho válido para antecipar como a cultura deve se comportar. Trata-se, portanto, de um estudo fortemente aderente à proposta, por tratar exatamente da relação entre clima e produtividade do milho a partir de séries históricas; sua acessibilidade é parcial, pois resulta em um modelo estatístico regional, e não em uma ferramenta pronta para uso direto pelo produtor.

2.3.1 Síntese dos trabalhos correlatos e posicionamento da proposta

A análise desses trabalhos destaca o avanço significativo das tecnologias e das técnicas de predição de safras aplicadas ao agronegócio. Porém, a maioria dessas abordagens exige alto investimento financeiro em *hardware* específico, infraestrutura ou conhecimento técnico avançado, o que dificulta a adoção dessas tecnologias por pequenos e médios produtores rurais. Portanto, percebe-se uma brecha na literatura em relação à disponibilidade de ferramentas de *software* preditivas de baixo custo. É exatamente nessa brecha que o presente trabalho se encaixa. Diferente das abordagens que dependem de *hardware* local ou de processamento complexo de imagens, por exemplo, a plataforma PredAgro busca democratizar o acesso à análise agroclimática preditiva. Ao cruzar dados meteorológicos abertos com regras agrônômicas oficiais, o sistema disponibiliza um modelo de risco e de

estimativa de produtividade acessível para a cultura do milho 1^a safra, sem cobrar nada do usuário final. A Tabela 1 resume os principais aspectos de cada trabalho e posiciona a proposta desta monografia frente aos demais.

Tabela 1 – Comparação entre os trabalhos correlatos e a proposta deste trabalho

Trabalho	Objetivo principal	Técnica/abordagem	Dados e infraestrutura	Acessível ao pequeno produtor
(GOMES, 2024)	Prever a produtividade da palmeira macaúba	<i>Random Forest</i> , <i>XGBoost</i> e Redes Neurais	Dados de solo, clima e atributos das plantas coletados em campo	Não
(JUNIOR, 2023)	Classificar tipos de solo no campo	Rede Neural embarcada em FPGA (VHDL)	Dados de solo e <i>hardware</i> dedicado de baixo custo	Parcial
(VASCONCELOS <i>et al.</i> , 2025)	Controlar o ambiente para o bem-estar animal	Rede Neural com sensores (Arduíno/IoT)	Sensores de temperatura, umidade e luminosidade	Parcial
(PREITE; VIGNALI, 2024)	Otimizar o consumo de água na irrigação	KNN, SVM e ANN	Sensores de solo e clima mais estação experimental	Não
(URIBEETXEBARRIA; CASTELLÓN; AIZPURUA, 2023)	Prever a produtividade do trigo	<i>CatBoost</i> , <i>Random Forest</i> , SVM e MLR	Imagens dos satélites <i>Sentinel-1</i> e <i>Sentinel-2</i>	Não
(PEREIRA; BEKER; SCHMOELLER, 2024)	Prever a produtividade da soja	Regressão, <i>Random Forest</i> e <i>XGBoost</i>	Dados agrometeorológicos públicos (séries de municípios)	Parcial
(CHAGAS; ZAMBERLAN, 2025)	Mapear sistemas de apoio à decisão (revisão)	Revisão de abordagens por regras, modelos e aprendizado de máquina	Literatura sobre clima e sensoriamento remoto	N/A
(APARECIDO <i>et al.</i> , 2020)	Prever a produtividade do milho safrinha	Modelo estatístico (regressão)	Série histórica de variáveis climáticas	Parcial
Este trabalho (PredAgro)	Estimar risco e produtividade do milho 1 ^a safra	Modelo agroclimático explicável (regras + climatologia)	Dados climáticos abertos (<i>Open-Meteo</i>) e fontes oficiais (ZARC, Embrapa, CONAB)	Sim

Fonte: Elaborado pelo autor (2026).

CAPÍTULO 3

Método

Este capítulo descreve o método escolhido para construir a solução proposta, incluindo a arquitetura do sistema, como é feita a coleta de dados e a explicação do modelo agroclimático criado para a cultura do milho 1^a safra. O capítulo também detalha de onde são obtidos os dados, como o planejamento é calibrado e quais fatores entram na análise gerada.

3.1 Arquitetura da solução

A arquitetura foi organizada em três camadas:

- ❑ **Front-end:** aplicação web desenvolvida em *React*, responsável pela interface e interação do usuário (Meta Platforms, Inc., 2024).
- ❑ **Back-end:** API REST criada em *Node.js*, que centraliza regras de negócio, integração com fontes de dados e geração das análises (DAHL, 2009).
- ❑ **Dados:** *Firebase Firestore* para persistência e *Firebase Authentication* para autenticação e controle de acesso (GOOGLE, 2014).

3.2 Abordagem de desenvolvimento

No contexto de Engenharia de Software, a construção da plataforma seguiu um **modelo incremental**. Ou seja, em vez de tentar entregar o sistema completo de uma única vez, o desenvolvimento foi organizado em partes menores, com evolução gradual das funcionalidades. Essa escolha foi adotada porque permitiu validar cada etapa com mais clareza, revisar decisões conforme o sistema crescia e manter o foco nas funcionalidades que realmente agregavam valor à proposta.

Isso significa que a solução foi sendo ampliada aos poucos: primeiro com os fluxos de cadastro de usuário e autenticação, em seguida com a criação de fazendas e delimita-

ção geográfica dos talhões, depois previsão climática, planejamento agrícola e, por fim, o refinamento do modelo de análise. Esse tipo de condução também facilitou a identificação de ajustes necessários ao longo do processo, principalmente nas regras do modelo agroclimático e na forma de apresentar os resultados ao usuário.

3.2.1 Organização do desenvolvimento em etapas

Como estrutura inicial, o desenvolvimento pode ser descrito pelas seguintes etapas:

- ❑ **Etapa 1:** definição do escopo, levantamento do problema e escolha das tecnologias;
- ❑ **Etapa 2:** desenvolvimento inicial, com cadastro de usuário e autenticação;
- ❑ **Etapa 3:** cadastro de fazendas e de talhões;
- ❑ **Etapa 4:** integração com mapas digitais e delimitação geográfica da área de cultivo;
- ❑ **Etapa 5:** integração com dados meteorológicos e estruturação da previsão climática;
- ❑ **Etapa 6:** implementação inicial do planejamento agrícola, com estimativa de fim de ciclo;
- ❑ **Etapa 7:** implementação do modelo de risco climático e da estimativa de produtividade no relatório;
- ❑ **Etapa 8:** ajustes finais, testes e alterações pontuais da interface.

3.3 Especificações técnicas da implementação

As subseções a seguir detalham as decisões técnicas adotadas na construção da plataforma, partindo da organização dos dados no *Firestore* e da integração com mapas e georreferenciamento, passando pela consulta e o cache de dados climáticos, até chegar ao núcleo do trabalho: o modelo agroclimático que estima a data final do ciclo, avalia os riscos por fase da cultura e projeta a produtividade do milho 1^a safra. Ao final, também são apresentadas as fontes utilizadas para calibrar cada etapa desse processo.

3.3.1 Persistência e organização dos dados

O modelo de persistência foi estruturado no *Firestore* de forma hierárquica, a partir da coleção de usuários (*users*). Cada usuário possui uma coleção de fazendas (*farms*) e, dentro de cada fazenda, uma coleção de talhões (*fields*). Cada talhão¹ possui subcoleções específicas para planejamentos de safra (*plans*) e registros climáticos (*weatherSnapshots*).

¹ Porção de terreno que se separa do todo por ser uma área cultivada (Dicio, 2026).

Essa estrutura lógica centraliza a coleta e o processamento de dados, organizando-os da seguinte forma:

- ❑ **users/{userId}**: armazena os dados de cadastro do usuário (nome completo, telefone, e-mail e credenciais de autenticação);
- ❑ **users/{userId}/farms/{farmId}**: armazena os dados da propriedade (nome, cidade e UF);
- ❑ **users/{userId}/farms/{farmId}/fields/{fieldId}**: contém os detalhes do talhão (nome e delimitação geográfica);
- ❑ **users/{userId}/farms/{farmId}/fields/{fieldId}/plans/{planId}**: registra o planejamento da safra (data de início da semeadura, data final estimada pelo sistema e duração projetada do ciclo).
- ❑ **users/{userId}/farms/{farmId}/fields/{fieldId}/weatherSnapshots/{snapshotId}**: guarda em cache da previsão meteorológica de curto prazo (temperaturas mínima e máxima, precipitação, umidade e vento).

Essa organização simplifica as regras de segurança e mantém cada usuário restrito aos próprios dados. O “desenho” do talhão é salvo em formato *GeoJSON* serializado, acompanhado de atributos como área, em hectares, e coordenadas centrais, calculadas via servidor.

3.3.2 Mapas, localização e georreferenciamento

A visualização dos mapas foi construída com *Leaflet* e *OpenStreetMap*, por meio de componentes *React* feitos exatamente para esse fim (Leaflet contributors, 2026; OpenStreetMap contributors, 2026). O usuário consegue delimitar o talhão conectando os pontos de um polígono diretamente sobre o mapa. No *front-end*, essa interação mostra uma área visual imediata e uma estimativa prévia da área. No *back-end*, os valores recebidos são validados e processados para cálculo da área e das coordenadas centrais, que se tornam as referências geográficas para consultas climáticas.

Quando o talhão já possui geometria cadastrada, o mapa se ajusta automaticamente para enquadrar o polígono salvo na visualização. Quando ainda não existe desenho, o sistema tenta centralizar o mapa com base na cidade cadastrada da fazenda e, na ausência dessa referência ou caso cidade não identificada, utiliza uma visão padrão do território brasileiro completo. Além disso, o cadastro da fazenda pode ser auxiliado por busca de CEP, reduzindo erros de preenchimento e melhorando a experiência de uso.

3.3.3 Consulta climática e cache

A previsão meteorológica é obtida a partir da *Open-Meteo* (Open-Meteo, 2026), utilizando a latitude e longitude salvas do talhão. A consulta diária considera temperatura mínima, temperatura máxima, precipitação acumulada, umidade relativa média e velocidade máxima do vento. Esses dados são usados na visualização climática diária do talhão, funcionando como apoio para previsão do tempo em curto prazo.

Como a fonte utilizada possui margem limitada de previsão, o sistema restringe a estimativa direta ao período disponibilizado pela API, atualmente até 16 dias. Para reduzir latência e evitar chamadas repetitivas, cada resposta é armazenada como snapshot climático com tempo de expiração de uma hora. Enquanto o cache estiver válido, as próximas consultas reutilizam os dados salvos.

3.3.4 Climatologia histórica

Para o planejamento agrícola, o sistema consulta o histórico climático da *Open-Meteo* via API e calcula médias históricas com base nos últimos 10 anos completos disponíveis. O procedimento consiste em buscar, para cada dia do plano, os valores equivalentes em anos anteriores e calcular médias de temperatura e precipitação dessas datas. Essa média histórica não é tratada como previsão diária, mas como referência climática para estimar como será o comportamento sazonal durante o ciclo.

Essa escolha foi adotada porque o ciclo completo do milho 1^a safra é muito superior (mais de 100 dias) à janela direta de previsão disponibilizada pela fonte climática. Em vez de misturar uma previsão curta com uma projeção longa no mesmo relatório, a plataforma passou a usar uma base única de climatologia histórica para todo o ciclo. Com isso, a análise fica mais estável e evita transmitir ao usuário uma diferença de confiança causada pelo limite de dias disponíveis na API.

3.3.5 Visão geral da plataforma

Do ponto de vista do produtor, a plataforma concentra em um único fluxo as tarefas necessárias para planejar a safra. A Figura 2 resume o que o usuário faz na PredAgro: cadastra suas fazendas e talhões, delimita a área diretamente no mapa, consulta o clima do talhão e gera o plano de safra informando apenas a data de plantio. O resultado desse processo é um relatório com o risco por categoria, recomendações e a faixa de produtividade estimada para a área. O núcleo que sustenta a geração desse plano — o modelo agroclimático explicável — é detalhado nas subseções seguintes.




Figura 2 – O que o produtor faz na PredAgro.

Fonte: Elaborado pelo autor (2026).

3.3.6 Estimativa da data final do ciclo

Na versão atual da plataforma, o usuário informa apenas a **data inicial da safra**. A **data final do plano** não é digitada manualmente. Ela é estimada pelo sistema a partir do local do talhão, da temperatura projetada para o período e dos parâmetros técnicos do milho 1ª safra.

Essa estimativa é obtida por meio de uma regra simplificada de **soma térmica**, em que o ponto de partida é o ciclo do Grupo II do ZARC, com 120 dias (Ministério da Agricultura e Pecuária, 2025b). A partir desse ciclo, o sistema adota temperatura-base de 10 °C, compatível com o zoneamento, e uma temperatura média de 22,5 °C, ideal para a cultura do milho 1ª safra. Com isso, o “alvo térmico” para o ciclo é de aproximadamente 1500 graus-dia.

Na prática, o sistema verifica a data em que o usuário planeja iniciar a safra e mapeia todo o ciclo dia por dia. Para cada data desse período, é verificado como aquele mesmo dia se comportou naquela região nos últimos 10 anos. Com isso, é estimado o término do ciclo e, depois, analisado se em cada fase as condições de chuva e temperatura ficaram mais ou menos favoráveis para a cultura.

O cálculo funciona somando o calor de cada dia que ultrapassa os 10 °C. O ciclo é considerado encerrado quando essa soma atinge o alvo térmico definido para a cultura (1500 graus-dia), e fica mais próximo do necessário para seu amadurecimento. Para evitar datas finais irreais geradas por temperaturas extremas, a duração é limitada a uma faixa entre 105 e 150 dias, respeitando o que acontece em uma lavoura real. Dessa forma, a

data final apresentada não é um “chute”, mas uma projeção calculada e baseada no ciclo técnico do milho, junto do clima esperado para a região selecionada.

3.3.7 Motor de análise de risco

O núcleo preditivo da plataforma utiliza um **modelo agroclimático explicável**, que atua em duas frentes: um sistema de regras agronômicas para avaliar os riscos climáticos por fase da cultura, e um modelo linear calibrável para estimar a produtividade final (detalhado na subseção 3.3.8).

Para a avaliação de riscos por meio das regras, o motor de análise utiliza um catálogo técnico dedicado ao milho 1^a safra. Nesse catálogo, o ciclo adotado como referência é o Grupo II do ZARC, com duração total de 120 dias e divisão em quatro fases: 15, 45, 40 e 20 dias, respectivamente (Ministério da Agricultura e Pecuária, 2025b). Depois que a data final é estimada, essas fases são distribuídas de forma sequencial ao longo do ciclo e passam a orientar a análise de risco climático.

O ponto central do modelo é que somente fatores que possuem base técnica nas fontes utilizadas são considerados na pontuação do planejamento. Assim, o sistema analisa os critérios:

- ❑ **Estresse hídrico:** calculado nas fases I e III, porque o ZARC do milho 1^a safra destaca essas fases como críticas para o atendimento hídrico (Ministério da Agricultura e Pecuária, 2025b).
- ❑ **Calor na fase reprodutiva:** calculado na fase III, porque de acordo com o Embrapa, as altas temperaturas no florescimento e no enchimento inicial de grãos afetam a polinização e a formação dos grãos (Empresa Brasileira de Pesquisa Agropecuária, 2022).
- ❑ **Frio e geada:** calculado ao longo do ciclo, porque o ZARC adota temperatura mínima de 10 °C para a cultura (Ministério da Agricultura e Pecuária, 2025b).
- ❑ **Excesso de chuva na colheita:** calculado na fase IV, usando o critério do ZARC que considera crítico quando ocorre seis ou mais dias de chuva no final do ciclo (Ministério da Agricultura e Pecuária, 2025b).

Na implementação da plataforma, dois ajustes foram necessários para que a o modelo refletisse melhor a realidade do campo. O primeiro foi adaptar a necessidade hídrica de acordo com a temperatura média de cada fase, ou seja, em ciclos frios o sistema reduz a exigência hídrica, já que a planta necessita de menos água. O segundo ajuste foi considerar, no excesso de chuva da colheita, apenas dias com chuvas relevantes e com volume acumulado mínimo, evitando que chuvas leves ou garoas passem a contar como evento crítico de colheita.

Cada fator avaliado recebe uma pontuação de 0 a 100, e o resultado final é obtido por uma média ponderada entre as fases do ciclo. Os quatro fatores não têm o mesmo peso na composição do risco: como o ZARC e a Embrapa apontam a disponibilidade hídrica como principal determinante da produtividade do milho, o estresse hídrico recebe o maior peso, seguido pelo calor no período reprodutivo, pelo frio e pelo excesso de chuva na colheita (Ministério da Agricultura e Pecuária, 2025b; Empresa Brasileira de Pesquisa Agropecuária, 2022). Os pesos (w_i) adotados são apresentados na Tabela 2.

Tabela 2 – Pesos dos fatores de risco no modelo do milho 1^a safra.

Fator de risco	Peso (w_i)
Estresse hídrico (fases I e III)	0,50
Calor na fase reprodutiva (fase III)	0,25
Frio e geada (todo o ciclo)	0,15
Excesso de chuva na colheita (fase IV)	0,10

Os valores em si foram definidos de forma heurística na calibração do modelo: eles seguem essa ordem de importância, somam 1 e deixam o fator hídrico com metade do peso, por ser o que mais afeta a produtividade do milho (segundo as fontes oficiais). Esses pesos podem ser refinados em trabalhos futuros com dados reais de produtividade.

O impacto climático global do planejamento (I) é a soma ponderada dos *scores* dos fatores, conforme a Equação 1.

$$I = \sum_i w_i \text{score}_i, \quad (1)$$

em que score_i varia de 0 a 100 e é a pontuação do fator i , e w_i é o seu peso. O valor de I , também na escala de 0 a 100, define o nível de risco por faixas: **baixo** para $I < 40$, **médio** para $40 \leq I < 70$ e **alto** para $I \geq 70$. Esse nível também alimenta a estimativa de produtividade descrita na próxima subseção.

O resultado gerado inclui nível de risco, estimativa de fim de ciclo, *score* geral, justificativas e recomendações.

3.3.8 Estimativa de produtividade

A estimativa de produtividade do sistema utiliza um modelo construído especificamente para o milho 1^a safra. A produtividade-base foi definida de acordo com a publicação feita pela CONAB no 5^o Levantamento da Safra Brasileira de Grãos 2025/26. Esse valor foi calculado a partir da produtividade média das safras de 2019/20 a 2025/26 (Companhia Nacional de Abastecimento, 2026). Os valores obtidos por meio desse levantamento foram adotados como produtividade-base, enquanto os limites mínimo e máximo são utilizados para definir uma variação esperada para a cultura.

Após o cálculo dos riscos, o sistema aplica pesos aos fatores analisados. Essa ponderação foi baseada na avaliação descrita pelo ZARC e pela Embrapa, mantendo o fator hídrico como elemento de maior peso na projeção final (Ministério da Agricultura e Pecuária, 2025b; Empresa Brasileira de Pesquisa Agropecuária, 2022). O resultado desse processo é uma estimativa de produtividade em t/ha, uma faixa aceitável e a produção total esperada para a área planejada.

A produtividade-base ($Prod_{base}$) adotada para o milho 1ª safra é de 6,06 t/ha, correspondente à média das safras de 2019/20 a 2025/26 apurada pela CONAB (Companhia Nacional de Abastecimento, 2026). A partir do impacto climático global I (Equação 1), o sistema calcula um fator de produtividade f , que representa a produtividade-base preservada após o efeito dos riscos:

$$f = \text{clamp}\left(1 - \frac{I}{100} \cdot s, 0,2, 1,2\right), \quad s = 0,35 \quad (2)$$

em que s é a sensibilidade do modelo (a cada 100% de impacto, reduz-se 35% da produtividade-base) e a função clamp restringe f ao intervalo $[0,2; 1,2]$, evitando valores irreais. A produtividade estimada ($Prod$) e a faixa apresentada ao usuário são, então, definidas por:

$$Prod = Prod_{base} \cdot f, \quad [Prod \cdot (1 - e); Prod \cdot (1 + e)] \quad (3)$$

em que e é a amplitude da faixa, que varia entre 0,18 e 0,28 conforme o histórico do período analisado. Por fim, a produção total esperada para o talhão é o produto entre $Prod$ e a área planejada, em hectares.

3.3.9 Fontes de calibração do planejamento

Para que o funcionamento da plataforma fique claro e transparente, a Tabela 3 resume as fontes utilizadas para calibrar o planejamento do milho 1ª safra e o papel de cada uma no sistema.

Tabela 3 – Fontes utilizadas para calibrar o planejamento do milho 1ª safra

Fonte	Tipo de dado	Uso na plataforma
<i>Open-Meteo</i> (Open-Meteo, 2026)	Previsão meteorológica diária e histórico climático	Fornecer temperatura mínima/máxima, precipitação, umidade e vento para a visualização climática de curto prazo e para a construção da climatologia histórica usada no planejamento.
MAPA (Ministério da Agricultura e Pecuária, 2025b)	Critérios oficiais de risco agroclimático	Define a estrutura do ciclo em quatro fases, as fases críticas ao déficit hídrico, o limiar térmico mínimo e o critério de excesso de chuva na colheita.
Nota Técnica do ZARC (Ministério da Agricultura e Pecuária, 2025a)	Contexto técnico e institucional do zoneamento	Fundamenta o uso do ZARC como referência aplicada ao planejamento agrícola e reforça sua pertinência para pequenos e médios produtores.
Embrapa (Empresa Brasileira de Pesquisa Agropecuária, 2022)	Metodologia agrônômica do milho	Enfatiza o estresse hídrico e o calor durante o período reprodutivo como fatores centrais de perda de produtividade.
CONAB (Companhia Nacional de Abastecimento, 2026)	Série histórica de produtividade do milho 1ª safra	Calibra produtividade-base, limite mínimo e limite máximo usados na projeção de produtividade do sistema.

3.4 Requisitos da solução

Os requisitos foram organizados em dois grupos: requisitos do usuário e requisitos do sistema. Em ambos os casos, a separação entre requisitos funcionais e não funcionais ajuda a deixar mais claro **o que** o sistema deve fazer e **como** ele deve fazer.

3.4.1 Requisitos funcionais do usuário

- ❑ o usuário deve conseguir criar conta e acessar a plataforma com e-mail e senha;
- ❑ o usuário deve conseguir acessar a plataforma com sua conta Google;
- ❑ o usuário deve conseguir solicitar a redefinição de senha via e-mail;
- ❑ o usuário deve conseguir visualizar e editar seus dados de perfil;
- ❑ o usuário deve conseguir cadastrar, editar e remover fazendas;
- ❑ o usuário deve conseguir cadastrar, editar e remover talhões associados a uma fazenda;
- ❑ o usuário deve conseguir delimitar a área do talhão em mapa;

- ❑ o usuário deve conseguir consultar a previsão do tempo do talhão em um intervalo de datas disponível;
- ❑ o usuário deve conseguir informar a data inicial de semeadura para gerar um plano;
- ❑ o usuário deve conseguir visualizar o risco climático por categoria e a estimativa de produtividade do plano gerado;
- ❑ o usuário deve conseguir consultar e remover planejamentos já registrados.

3.4.2 Requisitos não funcionais do usuário

- ❑ a plataforma deve ser acessível por navegador, sem exigir instalação nenhuma;
- ❑ a interface deve permitir que um usuário sem conhecimento técnico prévio conclua as tarefas principais (cadastrar fazenda, delimitar talhão e gerar um plano) sem necessidade de treinamento ou manual, exigindo apenas um dado de entrada obrigatório do usuário para gerar o plano: a data de semeadura;
- ❑ a navegação deve funcionar em computador e em dispositivos móveis;
- ❑ os resultados da análise (nível de risco, produtividade estimada e recomendações) devem ser exibidos com rótulo textual e indicação visual de categoria — por exemplo, cores distintas para risco baixo, médio e alto —, evitando termos técnicos sem explicação;
- ❑ o acesso às funcionalidades deve ocorrer apenas após autenticação do usuário.

3.4.3 Requisitos funcionais do sistema

- ❑ o sistema deve autenticar usuários e restringir o acesso aos próprios dados;
- ❑ o sistema deve suportar autenticação via provedores externos (Google);
- ❑ o sistema deve persistir dados de usuários, fazendas, talhões, planejamentos e snapshots climáticos;
- ❑ o sistema deve calcular área e coordenadas centrais a partir do polígono desenhado no mapa;
- ❑ o sistema deve consumir dados meteorológicos externos por meio da API da *Open-Meteo*;
- ❑ o sistema deve armazenar em cache a previsão de curto prazo para evitar consultas repetitivas desnecessárias;

- ❑ o sistema deve consultar e processar histórico climático dos últimos 10 anos para construir a climatologia utilizada no planejamento;
- ❑ o sistema deve estimar a data final do ciclo do milho 1^a safra a partir da data inicial informada;
- ❑ o sistema deve calcular o risco climático por fase da cultura com base em regras agronômicas;
- ❑ o sistema deve estimar a produtividade e a produção total esperada da área planejada.

3.4.4 Requisitos não funcionais do sistema

- ❑ o sistema deve utilizar uma arquitetura web separada em *front-end*, *back-end* e persistência de dados;
- ❑ o sistema deve permitir integração com serviços externos de clima por meio de API;
- ❑ o sistema deve manter consistência entre os dados de planejamento e os dados climáticos utilizados na análise;
- ❑ o sistema deve ser organizado em camadas separadas (interface, regras de negócio e armazenamento), de modo que uma alteração em uma camada não exija modificações nas demais;
- ❑ o sistema deve manter segurança na autenticação e isolamento dos dados por usuário;
- ❑ o sistema deve responder às operações de cadastro e de consulta climática em tempo compatível com uso interativo (meta de até 3 segundos em condições normais de rede), reutilizando os dados climáticos em cache dentro do período de validade para evitar novas requisições à API.

3.5 Diagramas do sistema

Para representar a estrutura e o funcionamento da plataforma, este trabalho inclui diagramas que complementam a descrição do sistema. Os diagramas foram construídos com o auxílio da plataforma *Mermaid* (Mermaid, 2026). Como parte da organização do capítulo, os tópicos a seguir mostram os diagramas escolhidos para representar algumas das funcionalidades da plataforma.

3.5.1 Diagrama Entidade-Relacionamento

O Diagrama Entidade-Relacionamento (DER) representa como os dados principais da plataforma são organizados. Ele mostra a relação entre usuários, fazendas, talhões, planejamentos de safra e registros climáticos, ajudando a visualizar a estrutura utilizada na persistência. As Figuras 3 e 4 ilustram essa estrutura, apresentada em duas partes para facilitar a leitura.




Figura 3 – Diagrama Entidade-Relacionamento da plataforma (Parte 1 de 2).




Figura 4 – Diagrama Entidade-Relacionamento da plataforma (Continuação).

3.5.2 Diagrama de Caso de Uso

O diagrama de caso de uso mostra as principais interações entre o usuário e a plataforma. Ele ajuda a resumir o que o produtor pode fazer no sistema, como cadastrar fazendas, delimitar talhões, consultar previsão climática e gerar planejamentos. A Figura 5 apresenta essas interações.




Figura 5 – Diagrama de caso de uso da plataforma.

3.5.3 Diagrama de Classes

O diagrama de classes descreve a estrutura lógica dos principais objetos usados pela solução. Ele representa entidades como usuário, fazenda, talhão, plano de safra e análise de risco, além dos atributos mais relevantes de cada uma. A estrutura completa pode ser vista na Figura 6.




Figura 6 – Diagrama de Classes da plataforma.

Fonte: Elaborado pelo autor.

3.5.4 Fluxo do processo

O fluxo do processo mostra a sequência geral de uso da plataforma, desde o cadastro do usuário até a geração da análise de risco e produtividade. Esse diagrama ajuda a entender o caminho percorrido pelos dados e pelas ações do usuário dentro da solução. O fluxo completo está representado na Figura 7.




Figura 7 – Fluxo de processo da plataforma (Parte 1 de 2).




Figura 8 – Fluxo de processo da plataforma (Continuação).

3.6 Avaliação da solução

A avaliação da solução foi conduzida em duas frentes. A primeira consiste em testes funcionais, que verificam se os principais fluxos do sistema são concluídos com sucesso. A segunda analisa o desempenho técnico da interface por meio da ferramenta *Google Lighthouse*, permitindo medir aspectos como tempo de carregamento, acessibilidade e boas práticas de desenvolvimento.

3.6.1 Testes funcionais

Os testes funcionais têm como objetivo verificar se os principais fluxos da plataforma operam conforme o esperado. Cada cenário descreve uma situação de uso real e define uma tarefa a ser executada pelo avaliador. A Tabela 4 apresenta os cenários escolhidos.

Tabela 4 – Cenários dos testes funcionais

ID	Cenário	Tarefa Solicitada
1	Primeiro Acesso	“Você é um usuário novo do sistema. Realize seu cadastro e faça login.”
2	Gerenciamento de Fazenda	“Cadastre uma nova fazenda informando nome, cidade e estado.”
3	Cadastro de Talhão	“Dentro da fazenda cadastrada, crie um novo talhão e preencha suas informações básicas.”
4	Delimitação Geográfica	“Delimite a área do talhão diretamente no mapa, desenhando o polígono da área de cultivo.”
5	Consulta Climática	“Acesse a previsão climática do talhão delimitado e visualize os dados de temperatura, chuva, umidade e vento.”
6	Planejamento de Safra	“Crie um planejamento de safra para o talhão, informando a cultura e a data de início da semeadura. Verifique a data final estimada e o relatório gerado.”
7	Edição e Exclusão	“Edite as informações de uma fazenda cadastrada e, em seguida, exclua um talhão existente.”

3.6.2 Avaliação de Desempenho

Além dos testes funcionais, a plataforma será avaliada sob a perspectiva de desempenho técnico utilizando o *Google Lighthouse* (Google, 2024). O *Lighthouse* é uma ferramenta de código aberto desenvolvida pelo Google, integrada ao navegador *Chrome*, que analisa automaticamente páginas web e gera um relatório com pontuações em quatro categorias principais: *Performance*, *Acessibilidade*, *Boas Práticas* e *SEO*. A análise é realizada simulando o carregamento da página em condições controladas e medindo métricas como tempo de carregamento, estabilidade visual e interatividade.

Neste trabalho, os critérios avaliados pelo *Lighthouse* são:

- ❑ **Performance:** tempo de carregamento inicial da aplicação e velocidade de resposta da interface;
- ❑ **Acessibilidade:** conformidade com boas práticas de acessibilidade web, como contraste de cores e uso correto de elementos semânticos;
- ❑ **Boas Práticas:** uso de protocolos seguros, ausência de bibliotecas vulneráveis e conformidade com padrões modernos de desenvolvimento web;
- ❑ **SEO:** estrutura da página em relação à indexação por mecanismos de busca.

Proposta e Desenvolvimento do Sistema

Este trabalho propõe a plataforma **PredAgro**, um sistema web de apoio à tomada de decisão para pequenos e médios produtores, com foco no planejamento do milho 1ª safra, na análise de risco climático e na estimativa de produtividade.

4.1 Contribuição principal

O ponto principal do sistema é o **modelo agroclimático explicável**, responsável por gerar uma previsão de produtividade e um relatório de risco por fase do cultivo. O modelo foi organizado a partir de:

- ❑ indicadores climáticos de curto prazo (previsão do tempo);
- ❑ climatologia histórica como base do relatório de planejamento;
- ❑ regras agronômicas focadas para o milho 1ª safra com base em fontes oficiais.

Essa organização permite criar uma estimativa viável e adequada para produtores que possuem acesso limitado a ferramentas técnicas avançadas. A proposta não depende de dados privados ou pagos para operar, pois a parametrização do planejamento parte de fontes públicas e oficiais, como ZARC, Embrapa, *Open-Meteo* e CONAB.

4.2 Componentes do sistema

O sistema é composto por módulos integrados, como:

- ❑ **Autenticação:** cadastro e login de usuários.
- ❑ **Cadastro agrícola:** fazendas, talhões e características básicas do solo.
- ❑ **Delimitação geográfica:** desenho e edição de talhão em mapa digital.
- ❑ **Previsão climática:** painel com previsão do tempo em determinado intervalo de datas.
- ❑ **Análise de risco:** avaliação por categoria e fase da cultura a partir da data de semeadura.
- ❑ **Previsão de produtividade:** faixa estimada em t/ha.

A plataforma ajuda principalmente aquele produtor que precisa responder a perguntas práticas, como: quando vale a pena iniciar o plantio, qual seria a data final estimada da safra, qual o nível de exposição climática naquele período e qual a produtividade estimada para a área planejada. Todas essas respostas são construídas a partir da localização e do clima no talhão cadastrado e das fontes oficiais utilizadas para calibrar o modelo.

4.3 Protótipo implementado

A implementação da plataforma foi organizada para conduzir o usuário, de forma intuitiva, desde a visão geral do sistema até a análise detalhada de um talhão específico. As telas a seguir mostram as principais funcionalidades do sistema.

A Figura 9 apresenta o painel principal da plataforma, disponível após login. Nessa tela, o sistema reúne indicadores resumidos daquele usuário, como: quantidade de fazendas cadastradas, número de talhões, área total e alertas relevantes.




Figura 9 – Painel principal da plataforma.

Fonte: Elaborado pelo autor (2026).

A Figura 10 mostra duas etapas complementares do cadastro. À esquerda, mostra a lista de fazendas cadastradas, com ações de cadastro, edição, exclusão e navegação. À direita, é exibida a lista de talhões pertencentes a uma fazenda, com as mesmas ações disponíveis.



Figura 10 – Cadastro de fazendas e talhões na plataforma.

Fonte: Elaborado pelo autor (2026).

A Figura 11 apresenta a visualização de um talhão cadastrado. Nela, são mostrados atributos do cadastro como área estimada e nome além dos botões para visualização de previsão, delimitação de área e planejamento.

 PredAgro



TALHÃO

Milho

Resumo e atalhos para previsão, delimitação e planejamento do talhão.

Resumo do talhão

Fazenda	Área
Fazenda Talismã	23.561,74 ha
Textura do solo	Drenagem
Não informado	Não informado
Irrigação	Delimitação
Não informado	Cadastrada

Ações do talhão

Abrir planejamento

Ver base climática


Editar delimitação

Editar cadastro

Delimitação do talhão

Visualize o contorno cadastrado e revise rapidamente se a área desenhada corresponde ao talhão monitorado.

Ajustar delimitação



Essa é a delimitação atualmente salva para o talhão.

Figura 11 – Visualização de um talhão.

Fonte: Elaborado pelo autor (2026).

Por fim, a Figura 12 apresenta a tela do planejamento de safra e análise de risco climático. Nela, é possível visualizar e apagar planos gerados além de gerar um novo plano. Para criar uma nova análise, o usuário precisa apenas fornecer a data inicial de semeadura, e o sistema gera o resultado com base no nível de risco, na estimativa do ciclo, na previsão de produtividade e nos fatores de impacto.

PredAgro Bruno Brito
brunocauderito@gmail.com

Fazenda Fazenda Talismã. Informe a data de início da semeadura para estimar o fim do ciclo e acompanhar risco climático e produtividade.

Novo plano de plantio

CULTURA ANALISADA
Milho 1ª safra
Milho de sequeiro com análise agroclimática baseada no ZARC da 1ª safra.

Data inicial
dd/mm/aaaa

A data inicial pode ser informada para os próximos 365 dias. Previsão diária disponível até 30/04/2026; após isso o sistema complementa a análise com climatologia histórica.

Gerar análise

Planos cadastrados

Milho 1ª safra
Semeadura em 01/11/2026 - colheita estimada em 13/02/2027

Ver análise
Apagar

Risco climático e produtividade

Resultado do modelo agroclimático com base no plano e nos dados climáticos disponíveis.

Nível de risco **Baixo**

Resumo do plano

Fazenda: Fazenda Talismã
Talhão: Milho
Cultura: Milho 1ª safra
Período: 01/11/2026 até 13/02/2027
Ciclo projetado: 105 dias
Score geral: 0
Tipo de análise: Tendência histórica
Confiabilidade: Baixa

Previsão de produtividade

Modelo: milho-zarc-v2
Base: 6,06 t/ha
Estimada: 6,06 t/ha
Faixa: 4,1-6,61 t/ha
Produção total: 142.784,16 t
Confiância: Baixa

Estimativa calculada por modelo agroclimático parametrizado para milho 1ª safra. Base de produtividade ajustada pela série histórica da Conab para milho 1ª safra. Média térmica do período: 26.7°C; precipitação média diária: 6.6 mm. Baseada exclusivamente em climatologia histórica.

Observações

- Análise baseada em climatologia histórica, com menor confiabilidade para o dia a dia.
- Data final estimada para 2027-02-13 com ciclo projetado de 105 dias,

Figura 12 – Tela de planejamento de safra.

Fonte: Elaborado pelo autor (2026).

4.4 Saídas esperadas

O sistema entrega um relatório que inclui:

- ❑ data inicial informada pelo usuário e data final estimada para o ciclo da cultura;
- ❑ nível de risco geral e por categoria;
- ❑ justificativas e recomendações gerais;
- ❑ produtividade estimada em faixa (mínimo, provável e máximo);
- ❑ produção total estimada para a área planejada;
- ❑ indicação clara de que a análise foi construída com base em climatologia histórica.

Com isso, o sistema proposto contribui não apenas com uma plataforma funcional, mas também com um método de análise agroclimática baseado em dados públicos, perfeito para o uso prático de pequenos e médios produtores rurais, mais especificamente de milho, que não possuem acesso fácil às tecnologias de predição.

4.5 Implementação do núcleo agroclimático

Esta seção apresenta os trechos centrais da implementação do sistema, organizados em três partes: estimativa do ciclo por soma térmica, construção da climatologia histórica e avaliação do risco hídrico com ajuste térmico. Os exemplos foram extraídos diretamente do código-fonte da plataforma, desenvolvida em *TypeScript*. O código-fonte completo da PredAgro está disponível publicamente no repositório <<https://github.com/brun-brito/PredAgro>>, permitindo que outros pesquisadores reproduzam, avaliem ou deem continuidade à solução proposta.

4.5.1 Estimativa do ciclo por soma térmica

O cálculo da data final do ciclo é feito por acúmulo de graus-dia. A função itera dia a dia sobre a projeção climática histórica, somando o calor efetivo de cada dia acima da temperatura-base ($T_{base} = 10^{\circ}\text{C}$). O ciclo é encerrado quando o acúmulo atinge o alvo térmico de 1500 graus-dia, derivado do ciclo de 120 dias do Grupo II do ZARC e da temperatura média de referência de $22,5^{\circ}\text{C}$.

```

1  // targetDegreeDays = cycleDays * (referenceTempC - baseTempC)
2  // Para milho 1a safra: 120 * (22.5 - 10) = 1500 graus-dia
3  const targetDegreeDays =
4    crop.cycleDays * (cycleModel.referenceTempC - cycleModel.
      baseTempC);
5
6  let cumulativeDegreeDays = 0;
7  let estimatedCycleDays = maxProjectionDays;
8
9  for (let index = 0; index < projectedDays.length; index++) {
10    const day = projectedDays[index];
11    const tempAvg = (day.temperatureMin + day.temperatureMax) /
      2;
12    const daily = Math.max(0, tempAvg - cycleModel.baseTempC);
13    cumulativeDegreeDays += daily;
14
15    // Respeita duracao minima do ciclo (105 dias para milho)
16    if (index + 1 < cycleModel.minCycleDays) continue;
17
18    if (cumulativeDegreeDays >= targetDegreeDays) {
19      estimatedCycleDays = index + 1;
20      break;
21    }
22  }

```

```
23
24 const endDate = addDays(startDate, estimatedCycleDays - 1);
```

Listing 4.1 – Acúmulo de graus-dia para estimativa do fim de ciclo.

4.5.2 Construção da climatologia histórica

Para cada dia do plano, o sistema busca os valores meteorológicos equivalentes nos últimos 10 anos completos disponíveis na *Open-Meteo Archive* e calcula a média. O resultado é uma série de *normals* climáticas com a mesma extensão do ciclo estimado, usada como base de toda a análise de risco.

```
1  // yearlySeries: array com a serie diaria de cada ano historico
2  // totalDays:     duracao do ciclo estimado
3  const normals: WeatherDay[] = Array.from({ length: totalDays },
4    (_, index) => {
5      const tempMin = yearlySeries.map(s => s[index].
6        temperatureMin);
7      const tempMax = yearlySeries.map(s => s[index].
8        temperatureMax);
9      const precip  = yearlySeries.map(s => s[index].
10        precipitationSum);
11
12     const avg = (values: number[]) =>
13       values.reduce((sum, v) => sum + v, 0) / values.length;
14
15     return {
16       date:          formatDate(addDays(planStart, index)),
17       temperatureMin: avg(tempMin),
18       temperatureMax: avg(tempMax),
19       precipitationSum: avg(precip),
20     };
21   }
22 );
```

Listing 4.2 – Média histórica de 10 anos para cada dia do ciclo.

4.5.3 Avaliação do risco hídrico com ajuste térmico

O estresse hídrico é calculado comparando a precipitação acumulada observada com um limiar mínimo ajustado pela temperatura média da fase. Essa correção reduz a exigência hídrica em ciclos mais frios, refletindo o menor consumo evapotranspirativo da cultura nesses períodos.


```
3 // baselineYield = 6.06 t/ha (media Conab safras 2019/20 a
  2025/26)
4 // sensitivity = 0.35 (cada 100% de impacto reduz 35%
  do baseline)
5
6 const weightSum = categories.reduce(
7   (sum, c) => sum + (riskWeights[c.id] ?? 0), 0);
8 const weightedImpact = categories.reduce(
9   (sum, c) => sum + (riskWeights[c.id] ?? 0) * (c.score / 100),
10   0);
11 const normalizedImpact = weightedImpact / weightSum;
12
13 // yieldFactor: fracao da produtividade-base retida apos o
  impacto dos riscos
14 const yieldFactor = clamp(1 - normalizedImpact * sensitivity
15   , 0.2, 1.2);
16
17 // Faixa de producao: spread fixo de 18% + componente de
  variabilidade hidrica
18 const spread = baseSpread + variabilitySpread; // tipicamente
  0.18 a 0.28
19 const minYield = clamp(estimatedYield * (1 - spread), 0,
20   maxYield);
21
22 // Producao total estimada para a area do talhao (em toneladas)
23 const totalProduction = estimatedYield * planArea;
```

Listing 4.4 – Conversão dos *scores* de risco em estimativa de produtividade.

Resultados

Este capítulo apresenta os resultados da avaliação da plataforma PredAgro, organizada em testes funcionais, avaliação do comportamento do modelo em diferentes cenários, análise de desempenho com o *Google Lighthouse* e considerações finais sobre os resultados obtidos.

5.1 Avaliação dos Testes Funcionais

Os testes funcionais foram conduzidos seguindo os cenários definidos na Tabela 4 (Capítulo 3). A Tabela 5 reproduz os mesmos cenários acrescidos da coluna de resultado.

Tabela 5 – Resultados dos testes funcionais

ID	Cenário	Resultado
1	Primeiro Acesso	Cadastro e Login concluídos; usuário redirecionado ao painel principal após entrar.
2	Gerenciamento de Fazenda	Fazenda criada e listada corretamente; dados salvos no <i>Firestore</i> .
3	Cadastro de Talhão	Talhão criado dentro da fazenda selecionada; atributos salvos corretamente.
4	Delimitação Geográfica	Polígono desenhado no mapa; área em hectares e centro calculados automaticamente pelo servidor.
5	Consulta Climática	Previsão de 16 dias exibida com temperatura, precipitação, umidade e vento.
6	Planejamento de Safra	Data final estimada gerada; relatório exibido com risco, <i>score</i> , produtividade e recomendações.
7	Edição e Exclusão	Edição de fazenda realizada com sucesso; talhão excluído removido sem falhas.

5.2 Avaliação do Comportamento do Modelo em Diferentes Cenários

Além dos testes funcionais, foi avaliado o comportamento do modelo agroclimático explicável em três cenários reais de planejamento para o milho 1^a safra. Os cenários foram definidos para variar a data inicial da semeadura e a localização do talhão, permitindo comparar como o sistema responde a contextos agroclimáticos distintos utilizando o mesmo modelo de ciclo e a mesma base de climatologia histórica. Como o modelo não utiliza aprendizado de máquina nem uma base de produtividade real para validação estatística, a avaliação apresentada aqui não mede a exatidão numérica das previsões, mas verifica se as saídas do sistema variam na direção agronomicamente esperada: cenários com clima mais favorável devem resultar em menor risco e produtividade mais estável, enquanto cenários com clima adverso devem elevar o risco e reduzir a produtividade estimada. Além disso, cada resultado deve ser rastreável até os fatores climáticos e às regras do ZARC que o originaram. A Tabela 6 sintetiza os resultados obtidos.

Tabela 6 – Comparação entre os cenários avaliados para o milho 1^a safra

Cen.	Local	Data inicial	Data final estimada	Risco	Fator dominante	Interpretação
C1	Goiânia/GO	20/10/26	01/02/27	Baixo	Estresse hídrico leve (8)	Cenário compatível com a janela chuvosa do Centro-Oeste, com ciclo curto (105 dias), sem penalização relevante por frio, calor ou chuva na colheita.
C2	Uberlândia/MG	05/11/26	22/02/27	Médio	Excesso de chuva na colheita (60)	Cenário intermediário, em que o risco não aparece durante o desenvolvimento do ciclo, mas cresce na maturação por persistência de chuva no trecho final.
C3	Curitiba/PR	05/09/26	01/02/27	Alto	Excesso de chuva na colheita (100)	Cenário mais restritivo, com ciclo alongado ao limite operacional de 150 dias e forte exposição à chuva no período final da colheita.

A Tabela 6 mostra que o sistema responde de forma diferente mesmo quando os três cenários usam exclusivamente climatologia histórica. Em Goiânia, o comportamento climático do período resultou em risco baixo, com produtividade estimada de 5,98 t/ha e praticamente nenhuma penalização fora do componente hídrico residual. Em Uberlândia, a resposta passou para risco médio porque o trecho final do ciclo concentrou condições desfavoráveis para a colheita. Em Curitiba, o modelo elevou o risco para alto porque o ciclo não atingiu o alvo térmico antes do limite operacional e terminou em uma janela historicamente mais chuvosa. Em todos os casos, o resultado pôde ser explicado diretamente pela climatologia histórica de cada local e pelas regras do ZARC, sem a intervenção de fatores não rastreáveis. É nesse sentido que as saídas são consideradas consistentes:

não por coincidirem com uma produtividade medida em campo, mas por responderem de forma previsível e explicável às condições climáticas de cada cenário.

Do ponto de vista do cálculo, vale observar que o sistema não tenta inferir fatores para os quais não há base técnica configurada. Em outras palavras, quando a plataforma mostra quatro categorias de risco para o milho 1^a safra, isso não significa simplificação arbitrária, mas sim a decisão de limitar a análise ao conjunto de fatores que pode ser efetivamente rastreado até as fontes de calibração do modelo.

5.3 Resultados do *Google Lighthouse*

A avaliação de desempenho da plataforma foi realizada com o *Google Lighthouse* em dois momentos. A primeira análise foi conduzida com a aplicação executando no servidor local, em modo de desenvolvimento. A segunda análise foi realizada após melhorias no código e sobre o *build* de produção gerado pelo *framework Vite*, que produz código minimizado e elimina dependências não referenciadas. A diferença de ambiente é relevante para o resultado final e é discutida ao longo desta seção. A Tabela 7 apresenta as pontuações e métricas da primeira análise.

Tabela 7 – Resultados do primeiro relatório do *Google Lighthouse* (modo de desenvolvimento)

Critério / Métrica	Resultado	Referência
<i>Pontuações gerais</i>		
<i>Performance</i>	57%	Bom (50–89%)
Acessibilidade	100%	Excelente ($\geq 90\%$)
Boas Práticas	96%	Excelente ($\geq 90\%$)
<i>SEO</i>	83%	Bom (50–89%)
<i>Métricas de desempenho</i>		
<i>First Contentful Paint</i> (FCP)	3,7 s	Ideal: $\leq 1,8$ s
<i>Largest Contentful Paint</i> (LCP)	8,0 s	Ideal: $\leq 2,5$ s
<i>Speed Index</i> (SI)	3,7 s	Ideal: $\leq 3,4$ s
<i>Total Blocking Time</i> (TBT)	22 ms	Ideal: ≤ 200 ms
<i>Cumulative Layout Shift</i> (CLS)	0,008	Ideal: $\leq 0,1$
<i>Time to Interactive</i> (TTI)	8,1 s	Ideal: $\leq 3,8$ s

O primeiro relatório revelou os seguintes atributos: acessibilidade perfeita e boas práticas muito próximas do máximo. A métrica de TBT — que mede o tempo em que a página ficou bloqueada para interações do usuário — também apresentou resultado excelente (22 ms), assim como o CLS (0,008), indicando ausência de instabilidade visual

no carregamento. Entretanto, as métricas de tempo de carregamento (FCP, LCP e TTI) ficaram acima dos valores de referência, principalmente por conta do tamanho elevado das imagens da tela inicial — o peso total da página foi de aproximadamente 9,36 MB. O relatório identificou duas imagens como os principais responsáveis pelo atraso. A pontuação de *SEO* (83%) também indica espaço para melhoria.

A partir dessas observações, foram aplicadas as seguintes melhorias ao *front-end*:

- ❑ **Otimização de imagens:** as imagens da página inicial foram convertidas do formato PNG para *WebP*, reduzindo o peso total de aproximadamente 9,36 MB para menos de 500 KB. Versões redimensionadas para 800 px de largura foram geradas para dispositivos menores;
- ❑ **Remoção de dependência não utilizada:** a biblioteca `react-icons/fc`, era usada apenas para exibir um ícone do Google na tela de login, foi substituída por um componente SVG, eliminando aproximadamente 346 KB do pacote *JavaScript*;
- ❑ **Carregamento tardio de rotas:** as páginas autenticadas da aplicação foram convertidas para importação dinâmica com `React.lazy`, reduzindo o volume de *JavaScript* carregado na entrada pública da plataforma.

Além dessas mudanças no código, a segunda análise foi executada sobre o *build* de produção, o que, por si só, contribuiu de forma relevante para a melhora dos resultados: o *Vite* aplica minificação e eliminação de código morto, o que não ocorre em modo de desenvolvimento. A Tabela 8 apresenta os resultados obtidos na segunda análise.

Tabela 8 – Resultados do segundo relatório do *Google Lighthouse* (*build* de produção)

Critério / Métrica	Resultado	Referência
<i>Pontuações gerais</i>		
<i>Performance</i>	100%	Excelente ($\geq 90\%$)
Acessibilidade	100%	Excelente ($\geq 90\%$)
Boas Práticas	96%	Excelente ($\geq 90\%$)
<i>SEO</i>	91%	Excelente ($\geq 90\%$)
<i>Métricas de desempenho</i>		
<i>First Contentful Paint</i> (FCP)	0,6 s	Ideal: $\leq 1,8$ s
<i>Largest Contentful Paint</i> (LCP)	0,7 s	Ideal: $\leq 2,5$ s
<i>Speed Index</i> (SI)	0,6 s	Ideal: $\leq 3,4$ s
<i>Total Blocking Time</i> (TBT)	0 ms	Ideal: ≤ 200 ms
<i>Cumulative Layout Shift</i> (CLS)	0,01	Ideal: $\leq 0,1$

O segundo relatório indicou melhora em todas as métricas de desempenho. O FCP e o LCP passaram, respectivamente, de 3,7 s e 8,0 s para 0,6 s e 0,7 s, ambos dentro do intervalo considerado ideal. O TBT atingiu 0 ms e o SI ficou em 0,6 s. A pontuação geral de *Performance* alcançou 100%, e o *SEO* subiu de 83% para 91%, reflexo da reorganização das dependências e do carregamento mais eficiente dos recursos. Os alertas remanescentes nas categorias de Boas Práticas e *SEO* referem-se a aspectos de infraestrutura, que dependem de hospedagem e, por isso, estão fora desta versão da plataforma. Os relatórios completos da primeira e da segunda análise encontram-se nos Apêndices A e B, respectivamente.

5.4 Considerações sobre os Resultados

Os resultados confirmam que a plataforma funciona de acordo com o planejado no Capítulo 3. Nos testes funcionais, todos os sete cenários avaliados foram concluídos com sucesso, cobrindo desde o cadastro inicial até a geração do relatório de planejamento. Nenhuma falha foi identificada nos fluxos principais do sistema.

Na avaliação do comportamento do modelo, os três cenários de planejamento mostraram que o modelo distingue corretamente um cenário de baixo risco (Goiânia), um intermediário (Uberlândia) e um de alto risco (Curitiba), mesmo utilizando apenas climatologia histórica. Isso reforça a utilidade do modelo como ferramenta de planejamento sazonal e indica que as saídas se mantêm consistentes e explicáveis em diferentes contextos.

Na avaliação de desempenho com o *Google Lighthouse*, a plataforma partiu de uma pontuação de *Performance* de 57% no modo de desenvolvimento e atingiu 100% após a combinação de melhorias no código e a execução em produção. Esse resultado demonstra que as otimizações aplicadas foram suficientes para que todas as métricas de carregamento atingissem os valores de referência definidos pelo *Lighthouse*.

Duas limitações persistem na versão atual. A primeira é a ausência de uma *meta description* na página inicial, que impede a pontuação máxima em *SEO*. A segunda refere-se aos alertas de segurança relacionados à configuração de cabeçalhos HTTP, que dependem de hospedagem e não podem ser resolvidos testando em *localhost*. Apesar disso, essas restrições não comprometem o funcionamento do protótipo proposto nessa etapa do projeto.

Conclusão

Este trabalho apresentou a plataforma PredAgro como uma solução de apoio ao planejamento agrícola voltada, principalmente, para pequenos e médios produtores de milho 1^a safra. A proposta reuniu, em um mesmo sistema web, o cadastro de fazendas e talhões, a delimitação geográfica da área de cultivo, a consulta climática e um modelo agroclimático capaz de estimar a data final do ciclo, o risco climático por fase da cultura e a produtividade esperada para a área planejada.

Ao longo do desenvolvimento, foi possível perceber que o maior desafio não estava apenas em construir o sistema em si, mas em fazer com que ele entregasse respostas coerentes e que pudessem ser explicadas ao usuário. Por isso, a maior preocupação foi manter o modelo transparente, usando somente fatores que tivessem amparo técnico nas fontes oficiais consultadas, como o ZARC, a Embrapa e a CONAB. Os resultados apresentados no Capítulo 5 mostraram que os objetivos definidos no início foram atingidos: a plataforma funcionou conforme o planejado nos testes funcionais e apresentou bom desempenho técnico na avaliação feita com o *Google Lighthouse*.

6.1 Principais Contribuições

As principais contribuições desta pesquisa foram:

- ❑ o desenvolvimento de uma plataforma web que reúne, em uma única interface, cadastro agrícola, delimitação geográfica do talhão e consulta climática, sem exigir instalação ou conhecimento técnico avançado por parte do produtor;
- ❑ a criação de um modelo agroclimático explicável para o milho 1^a safra, que estima o fim do ciclo por soma térmica, avalia o risco climático por fase da cultura e projeta a produtividade a partir de dados públicos e oficiais;
- ❑ a organização de uma análise que pode ser rastreada até suas fontes, deixando claro de onde vêm os dados, o que o sistema avalia e o que ele ainda não avalia;

- ❑ uma interface simples e objetiva, que traduz informações técnicas em um relatório de fácil leitura, voltado para quem não tem acesso fácil a ferramentas pagas de previsão de safra.

Esses elementos mostram que é possível oferecer uma solução funcional e de baixo custo, sem abrir mão da coerência técnica, mesmo trabalhando com limitações de dados e de orçamento.

6.2 Dificuldades e Limitações

Durante o desenvolvimento, surgiram algumas dificuldades que vale a pena registrar. A primeira foi ligada à área agronômica: como o trabalho parte da Computação, foi necessário estudar conceitos do agronegócio que não fazem parte da formação, como fases da cultura, graus-dia, déficit hídrico e janelas de plantio. Entender esses conceitos a ponto de transformá-los em regras de código exigiu bastante leitura das fontes técnicas.

A segunda dificuldade foi encontrar dados confiáveis e gratuitos. Boa parte das soluções e bases de dados mais completas do setor é paga ou de acesso restrito, o que vai justamente contra a proposta deste trabalho, que é atender quem tem pouco recurso. Por isso, foi preciso selecionar com cuidado fontes públicas e oficiais que pudessem sustentar o modelo.

A partir dessas dificuldades, algumas limitações ficaram claras na versão atual da plataforma:

- ❑ **Limite da fonte climática:** a API da *Open-Meteo* disponibiliza previsão direta para um período curto, de até 16 dias, enquanto o ciclo do milho 1^a safra ultrapassa 100 dias. Por isso, o planejamento precisou ser baseado inteiramente em climatologia histórica, considerando os últimos 10 anos, que funciona como uma referência do comportamento esperado do clima, e não como uma previsão exata para aquele ano;
- ❑ **Ausência de calibração com dados reais de campo:** o modelo foi calibrado com base em fontes oficiais, mas não chegou a ser ajustado com dados reais de produtividade em nível de talhão ou de município, o que ainda limita a precisão das estimativas;
- ❑ **Conjunto reduzido de fatores de risco:** foram considerados apenas quatro fatores na pontuação final (estresse hídrico, calor na fase reprodutiva, frio e geada e excesso de chuva na colheita), pois somente esses possuíam amparo técnico direto nas fontes utilizadas. Fatores como pragas, doenças e vento ficaram de fora da análise nesta versão;

- ❑ **Foco em uma única cultura:** o sistema foi construído especificamente para o milho 1ª safra, com parâmetros calibrados para esse cenário, o que impede o uso direto em outras culturas sem novos ajustes;
- ❑ **Avaliação ainda sem validação em campo:** os resultados confirmaram a coerência funcional e a consistência das respostas do sistema, mas não houve validação estatística com produtores reais nem comparação com métodos tradicionais de previsão;

Apesar dessas limitações, elas não comprometem o funcionamento do protótipo nesta etapa do projeto e, na verdade, apontam caminhos para a sua evolução.

6.3 Trabalhos Futuros

Como continuidade do trabalho, destacam-se as seguintes possibilidades:

- ❑ calibrar e validar o modelo com dados reais de produtividade em nível municipal ou de talhão, comparando as estimativas do sistema com o que foi efetivamente colhido;
- ❑ integrar a plataforma a bases oficiais de zoneamento e produtividade, como as da Embrapa e da CONAB, de forma automática;
- ❑ incluir novos fatores na análise de risco, como pragas, doenças e vento, à medida que existam fontes técnicas gratuitas que deem suporte a essas regras;
- ❑ ampliar o sistema para outras culturas, criando novos catálogos de parâmetros;
- ❑ usar imagens de satélite para enriquecer as variáveis do modelo e melhorar a análise da área de cultivo;
- ❑ realizar testes com produtores reais, coletando retorno sobre a usabilidade e a utilidade prática das informações geradas.

Referências

- AGRISHOW. **Inteligência Artificial no Agro: o futuro do campo já chegou? Descubra com Silvia Masshurá**. 2024. <<https://digital.agrishow.com.br/artigos/inteligencia-artificial-no-agro-o-futuro-do-campo-ja-chegou-descubra-com-silvia-masshura>>. Acesso em: 09 jul. 2026.
- Agroadvance. **Agrometeorologia: Data Science como aliada**. 2022. <<https://agroadvance.com.br/blog-agrometeorologia-data-science-como-aliada/>>. Acesso em: 09 jul. 2026.
- _____. **Agricultura 5.0: A nova revolução do campo**. 2024. <<https://agroadvance.com.br/blog-agricultura-50/>>. Acesso em: 09 jul. 2026.
- Aliger. **4 cases de Inteligência Artificial na agricultura para inspirar sua produção no campo**. 2019. <<https://aliger.com.br/cases-de-inteligencia-artificial-na-agricultura-para-melhorar-sua-producao-no-campo/>>. Acesso em: 09 jul. 2026.
- APARECIDO, L. E. d. O.; TORSONI, G. B.; MESQUITA, D. Z.; MENESES, K. C. d.; MORAES, J. R. d. S. C. d. Modelagem da produtividade do milho safrinha em função das condições climáticas do mato grosso do sul. **Revista Brasileira de Climatologia**, v. 26, 2020. Disponível em: <<https://revistas.ufpr.br/revistaabclima/article/view/69183>>.
- BELTRAO, A. **Inteligência Artificial: o que é IA e como funciona?** 2024. <<https://distrito.me/blog/inteligencia-artificial-ia-o-que-e-entenda-tudo-sobre-o-assunto/>>. Acesso em: 09 jul. 2026.
- Biosul Fertilizantes. **Dispositivos móveis agitam o mercado do agronegócio**. 2019. <<https://www.biosul.com/noticia/dispositivos-moveis-agitam-o-mercado-do-agronegocio>>. Acesso em: 09 jul. 2026.
- BOLFE, É. L.; BARBEDO, J. G. A.; MASSRUHÁ, S. M. F. S.; SOUZA, K. X. S. d.; ASSAD, E. D. Desafios, tendências e oportunidades em agricultura digital no Brasil. In: **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília, DF: Embrapa, 2020. cap. 16, p. 380–406. Acesso em: 12 jul. 2026. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/217713/1/LV-Agricultura-digital-2020-cap16.pdf>>.

- Campos Dealer. **Qual a diferença entre agricultura 4.0 e 5.0?** 2023. <<https://camposdealer.com.br/blog/qual-a-diferenca-entre-agricultura-4.0-e-5.0/>>. Acesso em: 09 jul. 2026.
- CEPEA. **PIB do Agronegócio Brasileiro**. 2025. <<https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>>. Acesso em: 09 jul. 2026.
- CHAGAS, E. d. S.; ZAMBERLAN, M. F. Modelos de sistemas de suporte à decisão para agricultura de precisão: Aplicações no monitoramento climático e previsão de rendimento agrícola. **ARACÊ**, v. 7, n. 11, p. e10310, 2025. Disponível em: <<https://periodicos.newsciencepubl.com/arace/article/view/10310>>.
- Companhia Nacional de Abastecimento. **5º Levantamento da Safra Brasileira de Grãos 2025/26**. 2026. <https://www.gov.br/conab/pt-br/atuacao/informacoes-agropecuarias/safras/safra-de-graos/boletim-da-safra-de-graos/5o-levantamento-safra-2025-26/e-book_boletim-de-safras-5o-levantamento_2026.pdf>. Acesso em: 12 abr. 2026.
- DAHL, R. **Executar a JavaScript em Toda Parte**. 2009. <<https://nodejs.org/pt>>. Acesso em: 10 abr. 2025.
- Desenvolvimento Rural. **Aplicativos Agrícolas e sua Importância para o Desenvolvimento Rural**. 2018. <<https://desenvolvimentorural.com/aplicativo-agricola/>>. Acesso em: 24 mar. 2025.
- Dicio. **Significado de Talhão**. 2026. <<https://www.dicio.com.br/talhao/>>. Acesso em: 3 mai. 2026.
- Eduardo Viola; Vinícius Mendes. **Agricultura 4.0 e mudanças climáticas no Brasil**. 2022. <<https://www.scielo.br/j/asoc/a/Bwg7NVTs5kcrK6WRxbqh4LS/?lang=pt#>>. Acesso em: 09 jul. 2026.
- EMBRAPA. **Riscos na agricultura**. 2018. <<https://www.embrapa.br/visao/riscos-na-agricultura>>. Acesso em: 09 jul. 2026.
- _____. **Inteligência artificial torna mais preciso o mapeamento da intensificação agrícola no Cerrado**. 2023. <<https://www.embrapa.br/busca-de-noticias/-/noticia/83327528/inteligencia-artificial-torna-mais-preciso-o-mapeamento-da-intensificacao-agricola-no-cerrado>>. Acesso em: 09 jul. 2026.
- Empresa Brasileira de Pesquisa Agropecuária. **Metodologia para o Zoneamento Agrícola de Risco Climático da produtividade do milho**. 2022. <<https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1159479/1/Metodologia-para-o-Zoneamento-Agricola-de-Risco-Climatico-da-produtividade-do-milho.pdf>>. Acesso em: 12 abr. 2026.
- EOS Data Analytics. **Tecnologia na Agricultura: Importância, Tipos, Implementação**. 2022. <<https://eos.com/pt/blog/tecnologia-na-agricultura/>>. Acesso em: 09 jul. 2026.
- FERTISYSTEM. **Conheça os 5 principais desafios do agronegócio no Brasil**. 2021. <<https://www.fertisystem.com.br/m/blog/60d36532b3d122039320bba8/conheca-os-5-principais-desafios-do-agronegocio-no-brasil>>. Acesso em: 09 jul. 2026.

FieldView. **Agricultura Digital: o que é, como fazer e tendências**. 2022. <<https://blog.climatefieldview.com.br/agricultura-digital>>. Acesso em: 09 jul. 2026.

FIESC. **Produção de grãos chegará a 390 milhões de toneladas em 10 anos**. 2023. <<https://fiesc.com.br/pt-br/imprensa/producao-de-graos-chegara-390-milhoes-de-toneladas-em-10-anos>>. Acesso em: 09 jul. 2026.

FIGUEIREDO, D. C. Projeto GeoSafras: sistema de previsão de safras da Conab. **Revista de Política Agrícola**, v. 14, n. 2, p. 110–120, 2005. Acesso em: 12 jul. 2026. Disponível em: <<https://seer.sede.embrapa.br/index.php/RPA/article/view/543>>.

GOMES, J. A. Dissertação de Mestrado em Fitotecnia, **Modelagem da produtividade da palmeira macaúba [*Acrocomia aculeata* (Jacq.) Lodd. ex Mart.] utilizando algoritmos de aprendizado de máquina**. Piracicaba: [s.n.], 2024. Acesso em: 10/04/2025. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/11136/tde-08102024-071618/publico/Jhonatah_Albuquerque_Gomes_versao_revisada.pdf>.

GOOGLE. **Make your app the best it can be with Firebase and generative AI**. 2014. <<https://firebase.google.com/>>. Acesso em: 10 abr. 2025.

Google. **Lighthouse**. 2024. Ferramenta de código aberto para auditoria de qualidade de páginas web. Disponível em: <<https://developer.chrome.com/docs/lighthouse/overview>>. Acesso em: 24 mai. 2026.

IBGE. **Pesquisas agropecuárias**. 2018. <<https://biblioteca.ibge.gov.br/visualizacao/livros/liv101552.pdf>>. 3. ed. Rio de Janeiro: IBGE, 2018. (Série Relatórios Metodológicos, v. 6). Acesso em: 12 jul. 2026.

Jornal do Agro Online. **Mais de 90% dos produtores rurais utilizam aplicativo para saber a previsão do clima**. 2023. <<https://www.jornaldoagroonline.com.br/noticias/2356/mais-de-90-dos-produtores-rurais-utilizam-aplicativo-para-saber-a-previsao-do-clima>>. Acesso em: 09 jul. 2026.

JUNIOR, N. A. U. C. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica), **Implementação de um protótipo de uma inteligência artificial em um FPGA para agricultura**. Goiânia: [s.n.], 2023. Acesso em: 10/04/2025. Disponível em: <<https://repositorio.pucgoias.edu.br/jspui/handle/123456789/7024>>.

Leaflet contributors. **Leaflet**. 2026. <<https://leafletjs.com/>>. Acesso em: 10 abr. 2025.

MAPA. **Projeções do Agronegócio - Brasil 2023/24 a 2033/34**. 2024. <<https://www.gov.br/agricultura/pt-br/assuntos/politica-agricola/todas-publicacoes-de-politica-agricola/projecoes-do-agronegocio/projecoes-do-agronegocio-2022-2023-a-2032-2033.pdf>>. Acesso em: 24 mar. 2025.

Mermaid. **Mermaid: Generation of diagram and flowchart from text in a similar manner as markdown**. 2026. <<https://mermaid.js.org/>>. Acesso em: 11 mai. 2026.

Meta Platforms, Inc. **React – Team**. 2024. Acesso em: 10 abr. 2025. Disponível em: <<https://pt-br.legacy.reactjs.org/community/team.html>>.

Ministério da Agricultura e Pecuária. **Nota técnica do Zoneamento Agrícola de Risco Climático para milho e milho consorciado 1ª safra**. 2025. <<https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/programa-nacional-de-zoneamento-agricola-de-risco-climatico/notas-tecnicas-air/notas-tecnicas-2024/NotaTcnica9MilhoeMilhoconsorciado1Safra.pdf>>. Acesso em: 12 abr. 2026.

_____. **Portaria do Zoneamento Agrícola de Risco Climático para a cultura do milho 1ª safra**. 2025. <<https://www.gov.br/agricultura/pt-br/assuntos/riscos-seguro/programa-nacional-de-zoneamento-agricola-de-risco-climatico/portarias/2024-2025/rondonia-ro/PO933D1.PDF>>. Acesso em: 12 abr. 2026.

OLIVEIRA, B. **IA no agronegócio: como tecnologia está se tornando imprescindível**. 2024. <<https://digitalagro.com.br/2024/05/03/ia-no-agronegocio-como-tecnologia-esta-se-tornando-imprescindivel/>>. Acesso em: 09 jul. 2026.

Open-Meteo. **Open-Meteo Weather API**. 2026. <<https://open-meteo.com/>>. Acesso em: 10 abr. 2025.

OpenStreetMap contributors. **OpenStreetMap**. 2026. <<https://www.openstreetmap.org/>>. Acesso em: 10 abr. 2025.

PALMEAR. **Usando IA e acústica para detectar pragas na agricultura**. 2023. <<https://www.palmear.ai/>>. Acesso em: 09 jul. 2026.

PEREIRA, E. M.; BEKER, J. P. d. S.; SCHMOELLER, R. P. Aplicação de machine learning na previsão da produtividade da soja. **Revista Pleiade**, v. 18, n. 45, 2024. Disponível em: <<https://pleiade.uniamerica.br/index.php/pleiade/article/view/1069>>.

PREITE, L.; VIGNALI, G. Artificial intelligence to optimize water consumption in agriculture: A predictive algorithm-based irrigation management system. **Computers and Electronics in Agriculture**, v. 223, p. 109126, 2024. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169924005179>>.

Renan Honorato. **Liga Ventures: agricultura é o setor que mais usa IA**. 2024. <<https://www.meioemensagem.com.br/proxima/liga-ventures-agricultura-e-o-setor-que-mais-usa-ia>>. Acesso em: 09 jul. 2026.

Revista Cultivar. **Embrapa oferece serviço de acesso a dados agrometeorológicos para uso em soluções digitais**. 2022. <<https://revistacultivar.com.br/noticias/embrapa-oferece-servico-de-acesso-a-dados-agrometeorologicos-para-uso-em-solucoes-digitais>>. Acesso em: 09 jul. 2026.

Ribeiro, João Batista. **Deteção de linhas de plantio em plantações de cana-de-açúcar utilizando deep learning**. 2023. <https://repositorio.ufu.br/bitstream/123456789/39346/1/Deteccao_linhas_plantio.pdf>. Acesso em: 24 mar. 2025.

SCICROP. **Como a Tecnologia Está Transformando a Agricultura de Precisão**. 2024. <<https://scicrop.com/2024/04/23/como-a-tecnologia-esta-transformando-a-agricultura-de-precisao/>>. Acesso em: 09 jul. 2026.

Solinftec. **Inteligência artificial na agricultura: principais atribuições.**

<<https://www.solinftec.com/pt-br/blog/inteligencia-artificial-agricultura/>>. Acesso em: 09 jul. 2026.

Teixeira Neto, Arthur Palhares. **O “tech” do agro: uma revisão bibliográfica sobre o impacto da aplicação de tecnologias no agronegócio brasileiro.** 2022.

<<https://repositorio.ufu.br/bitstream/123456789/35997/3/TechAgroUma.pdf>>. Acesso em: 24 mar. 2025.

TEREOS. **Dia a dia, cultivando o futuro.** 1932. <<https://br.tereos.com/pt-pt/>>. Acesso em: 24 mar. 2025.

Terra Magna. **Agrometeorologia: o que é e como aplicá-la em sua atividade rural.** 2022.

<<https://terramagna.com.br/blog/agrometeorologia/>>. Acesso em: 09 jul. 2026.

URIBEETXEBARRIA, A.; CASTELLÓN, A.; AIZPURUA, A. Optimizing wheat yield prediction integrating data from sentinel-1 and sentinel-2 with catboost algorithm. **Remote Sensing**, v. 15, n. 6, 2023. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/15/6/1640>>.

VASCONCELOS, O. C. d. M.; NASCIMENTO, C. J. E. d.; SIQUEIRA, M. R. S.; SILVA, M. P. d.; DIAS, G. A.; BRITO, C. Y. d. O.; SILVA, G. R. d.; BRITO, A. U.; MARANHÃO, G. N. d. A.; OLIVEIRA, W. D. d. Ensino das ferramentas de inteligência artificial para soluções na agricultura amazônica - ovindeck: sistema de controle de ambientes e bem estar animal. **OBSERVATÓRIO DE LA ECONOMÍA LATINOAMERICANA**, v. 23, n. 1, p. e8663, jan. 2025. Disponível em: <<https://ojs.observatoriolatinoamericano.com/ojs/index.php/olel/article/view/8663>>.

Zanuto, Arthur Henrique Silva. **Agricultura 4.0: Desafios e impactos das novas tecnologias na agricultura brasileiro.** 2024. <<https://repositorio.ufu.br/bitstream/123456789/44031/1/AgriculturaDesafiosImpactos.pdf>>. Acesso em: 24 mar. 2025.

APÊNDICE **A**

Relatório *Google Lighthouse* – Primeira Análise

O relatório a seguir foi gerado pelo *Google Lighthouse* e corresponde à primeira avaliação de desempenho da plataforma PredAgro, realizada com a aplicação em modo de desenvolvimento, antes das melhorias descritas no Capítulo 5.

24/05/2026, 22:25

Lighthouse Report Viewer

 http://localhost:5173/

57

Performance

100

Accessibility

96

Best Practices

83

SEO

There were issues affecting this run of Lighthouse:

- **Chrome extensions negatively affected this page's load performance. Try auditing the page in incognito mode or from a Chrome profile without extensions.**

57

Performance

Values are estimated and may vary. The [performance score is calculated](#) directly from these metrics. [See calculator.](#)

▲ 0–49

■ 50–89

● 90–100

METRICS

Expand view

▲ First Contentful Paint

▲ Largest Contentful Paint



<https://googlechrome.github.io/lighthouse/viewer/>

1/7

24/05/2026, 22:25

Lighthouse Report Viewer

3.7 s

Total Blocking Time

20 ms


Speed Index

3.7 s

8.0 s

Cumulative Layout Shift

0.008



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [TBT](#) [CLS](#)

INSIGHTS

- ▲

LCP request discovery

▼
- ▲

Network dependency tree

▼
- Improve image delivery — Est savings of 2,016 KiB

▼
- Layout shift culprits

▼
- LCP breakdown

▼
- 3rd parties

▼

These insights are also available in the Chrome DevTools Performance Panel - [record a trace](#) to view more detailed information.

24/05/2026, 22:25

Lighthouse Report Viewer

DIAGNOSTICS

▲	Reduce unused JavaScript — Est savings of 10,164 KiB	▼
▲	Minify JavaScript — Est savings of 1,925 KiB	▼
▲	Page prevented back/forward cache restoration — 1 failure reason	▼
■	Image elements do not have explicit width and height	▼
■	Avoid enormous network payloads — Total size was 9,361 KiB	▼
○	User Timing marks and measures — 6 user timings	▼
○	Avoid long main-thread tasks — 4 long tasks found	▼

More information about the performance of your application. These numbers don't [directly affect](#) the Performance score.

PASSED AUDITS (16)

Show



24/05/2026, 22:25

Lighthouse Report Viewer

Accessibility

These checks highlight opportunities to [improve the accessibility of your web app](#). Automatic detection can only detect a subset of issues and does not guarantee the accessibility of your web app, so [manual testing](#) is also encouraged.

ADDITIONAL ITEMS TO MANUALLY CHECK (10) Show

These items address areas which an automated testing tool cannot cover. Learn more in our guide on [conducting an accessibility review](#).

PASSED AUDITS (20) Show

NOT APPLICABLE (40) Show



Best Practices

24/05/2026, 22:25

Lighthouse Report Viewer

GENERAL

- ▲ Browser errors were logged to the console ▼
- Detected JavaScript libraries ▼

TRUST AND SAFETY

- Ensure CSP is effective against XSS attacks ▼
- Use a strong HSTS policy ▼
- Ensure proper origin isolation with COOP ▼
- Mitigate clickjacking with XFO or CSP ▼
- Mitigate DOM-based XSS with Trusted Types ▼

PASSED AUDITS (12)

Show

NOT APPLICABLE (1)

Show



SEO

These checks ensure that your page is following basic search engine optimization advice. There are many additional factors Lighthouse does not score here that may affect your search ranking, including performance on [Core Web Vitals](#). [Learn more about Google Search Essentials](#).

CONTENT BEST PRACTICES

▲ Document does not have a meta description ▼

Format your HTML in a way that enables crawlers to better understand your app's content.

CRAWLING AND INDEXING

▲ robots.txt is not valid — 18 errors found ▼

To appear in search results, crawlers need access to your app.

ADDITIONAL ITEMS TO MANUALLY CHECK (1)

Show

24/05/2026, 22:25

Lighthouse Report Viewer

Run these additional validators on your site to check additional SEO best practices.

PASSED AUDITS (7)


[Show](#)

NOT APPLICABLE (1)

[Show](#) Captured at May 24, 2026, 10:21 PM
GMT-3 Emulated Desktop with Lighthouse
13.0.2 Single page session Initial page load Custom throttling Using Chromium 148.0.0.0 with
devtoolsGenerated by **Lighthouse** 13.0.2 | [File an issue](#)

Relatório *Google Lighthouse* – Segunda Análise

O relatório a seguir corresponde à segunda avaliação de desempenho, realizada sobre o *build* de produção da plataforma PredAgro, após a aplicação das melhorias de otimização de imagens, remoção de dependências não utilizadas e carregamento atrasado de rotas.



01/06/2026, 15:15

Lighthouse Report Viewer

● Speed Index
0.6 s



Show audits relevant to: [All](#) [FCP](#) [LCP](#) [CLS](#)

INSIGHTS

- ▲ Use efficient cache lifetimes — Est savings of 262 KiB
- ▲ Render-blocking requests — Est savings of 190 ms
- ▲ LCP request discovery
- ▲ Network dependency tree
- Improve image delivery — Est savings of 23 KiB
- Layout shift culprits
- LCP breakdown
- 3rd parties

These insights are also available in the Chrome DevTools Performance Panel - [record a trace](#) to view more detailed information.

DIAGNOSTICS

01/06/2026, 15:15

Lighthouse Report Viewer

-
- ▲ Reduce unused JavaScript — Est savings of 103 KiB ▼
 - ▲ Reduce unused CSS — Est savings of 13 KiB ▼
-

More information about the performance of your application. These numbers don't [directly affect](#) the Performance score.

PASSED AUDITS (19)

Show



Accessibility

These checks highlight opportunities to [improve the accessibility of your web app](#). Automatic detection can only detect a subset of issues and does not guarantee the accessibility of your web app, so [manual testing](#) is also encouraged.

ADDITIONAL ITEMS TO MANUALLY CHECK (10)

Show

These items address areas which an automated testing tool cannot cover. Learn more in our guide on [conducting an accessibility review](#).

01/06/2026, 15:15

Lighthouse Report Viewer

PASSED AUDITS (20)	Show
NOT APPLICABLE (40)	Show



Best Practices

USER EXPERIENCE	
▲ Displays images with incorrect aspect ratio	▼
TRUST AND SAFETY	
○ Ensure CSP is effective against XSS attacks	▼
○ Use a strong HSTS policy	▼

01/06/2026, 15:15

Lighthouse Report Viewer

- Ensure proper origin isolation with COOP ▾
- Mitigate clickjacking with XFO or CSP ▾
- Mitigate DOM-based XSS with Trusted Types ▾

GENERAL

- Detected JavaScript libraries ▾
- ▲ Missing source maps for large first-party JavaScript ▾

PASSED AUDITS (11)

Show

NOT APPLICABLE (1)

Show

91

01/06/2026, 15:15

Lighthouse Report Viewer

SEO

These checks ensure that your page is following basic search engine optimization advice. There are many additional factors Lighthouse does not score here that may affect your search ranking, including performance on [Core Web Vitals](#). [Learn more about Google Search Essentials](#).

CONTENT BEST PRACTICES

▲ Document does not have a meta description ▼

Format your HTML in a way that enables crawlers to better understand your app's content.

ADDITIONAL ITEMS TO MANUALLY CHECK (1) Show

Run these additional validators on your site to check additional SEO best practices.

PASSED AUDITS (7) Show

NOT APPLICABLE (2) Show

01/06/2026, 15:15

Lighthouse Report Viewer

 Captured at Jun 1, 2026, 3:15 PM GMT-3	 Emulated Desktop with Lighthouse 13.0.2	 Single page session
 Initial page load	 Custom throttling	 Using Chromium 148.0.0.0 with devtools

Generated by **Lighthouse** 13.0.2 | [File an issue](#)