CEFET/RJ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO

# TECNOLOGIA E SUSTENTABILIDADE NO CAMPO: SISTEMA DE RECOMENDAÇÃO PARA PEQUENOS PRODUTORES RURAIS

André Luiz Coutinho Merlo

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Ciência da Computação, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca CEFET/RJ, como parte dos requisitos necessários à obtenção do grau de mestre.

Orientador:
Diego Nunes Brandão

Rio de Janeiro,

Dezembro de 2025

**Tecnologia e Sustentabilidade no Campo: Sistema de Recomendação para Pequenos Produtores Rurais**

Dissertação de Mestrado em Ciência da Computação, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, CEFET/RJ.

André Luiz Coutinho Merlo

Aprovada por:

Presidente, Prof. Diego Nunes Brandão, D.Sc. (orientador)

Documento assinado digitalmente
gov.br DOUGLAS DE OLIVEIRA CARDOSO
Data: 08/01/2026 12:28:41-0300
Verifique em https://validar.iti.gov.br

Prof. Douglas Cardoso, D.Sc. - Universidade de Coimbra

Profa. Kele Teixeira Belloze, D.Sc. - Cefet/RJ

Documento assinado digitalmente
gov.br MARCOS BACIS CEDDIA
Data: 08/01/2026 16:31:29-0300
Verifique em https://validar.iti.gov.br

Prof. Marcos Bacis Ceddia, D.Sc. - UFRRJ

Rio de Janeiro,

Dezembro de 2025

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

M565 Merlo, André Luiz Coutinho
Tecnologia e sustentabilidade no campo: sistema de recomendação para pequenos produtores rurais / André Luiz Coutinho Merlo. — 2025.
84f. + apêndice : il. color. , enc.

Dissertação (Mestrado) Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, 2025.
Bibliografia : f. 78-84
Orientador: Diego Nunes Brandão

1. Tecnologia - Agricultura. 2. Inovações agrícolas. 3. Produtividade agrícola. 4. Agricultura familiar. 5. Sistemas especialistas (Computação). 6. Inteligência artificial. I. Brandão, Diego Nunes. (Orient.). II. Título.

CDD 630

Elaborada pela bibliotecária Tania Mello – CRB/7 nº 5507/04

# DEDICATÓRIA

Dedico este trabalho à minha família, pelo amor,
apoio e compreensão constantes, que tornaram
possível cada etapa desta jornada.

# AGRADECIMENTOS

Agradeço, primeiramente, à minha família, alicerce constante em todos os momentos, pelo apoio, compreensão e incentivo incondicionais ao longo desta jornada.

Ao meu orientador, pela confiança, pelas orientações precisas e pela generosidade em compartilhar conhecimento, fundamentais para o amadurecimento deste trabalho e para minha formação acadêmica.

Ao CEFET-RJ, em especial ao PPCIC, pela oportunidade, pelo ambiente acadêmico estimulante e pelo compromisso com a formação científica de qualidade, que tornaram possível a realização desta pesquisa.

# RESUMO

Tecnologia e Sustentabilidade no Campo: Sistema de Recomendação para Pequenos Produtores Rurais

André Luiz Coutinho Merlo

Orientador:
Diego Nunes Brandão

Resumo da Dissertação submetida ao Programa de Pós-graduação em Ciência da Computação do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca CEFET/RJ como parte dos requisitos necessários à obtenção do grau de mestre.

A agricultura digital tem se consolidado como um dos pilares da transformação tecnológica no campo, ao integrar sensores, algoritmos, dados meteorológicos e técnicas de inteligência artificial para tornar a produção agrícola mais eficiente, sustentável e inteligente. Nesse contexto, a agricultura familiar, responsável por grande parte da produção de alimentos no Brasil, desempenha um papel estratégico não apenas na segurança alimentar, mas também na conservação ambiental e no desenvolvimento regional. No entanto, muitos pequenos produtores ainda enfrentam desafios relacionados ao acesso a tecnologias avançadas e à tomada de decisões baseadas em dados. Diante desse cenário, este trabalho propõe o desenvolvimento de um sistema inteligente de recomendação agrícola, voltado a apoiar agricultores familiares na escolha de culturas e no manejo eficiente do solo. A solução adota uma abordagem híbrida, combinando um motor de inferência baseado em regras com técnicas de ciência de dados aplicadas à agricultura digital. O sistema utiliza dados regionais de produtividade, condições climáticas e análises detalhadas do solo para gerar recomendações personalizadas sobre o cultivo mais adequado, bem como orientações técnicas sobre adubação e calagem (aplicação de corretivos de acidez). Ao considerar variáveis como o tipo e a composição do solo, o histórico produtivo e o clima local, o sistema busca contribuir para o aumento da produtividade, a redução de impactos ambientais e a promoção da sustentabilidade econômica de pequenos produtores rurais. Experimentos, acompanhados de análise estatística das saídas, demonstram a viabilidade da solução proposta, com recomendações alinhadas às práticas agrícolas locais e às condições edafoclimáticas (integração solo–clima aplicada às recomendações agronômicas) das regiões avaliadas. A concordância entre o sistema e as referências técnicas foi quantificada por meio de medidas como a acurácia e o coeficiente Kappa de Cohen, com respectivos intervalos de confiança, além de testes de hipótese para verificar a significância dos resultados. Esses achados indicam que o sistema pode se tornar uma ferramenta acessível e escalável, capaz de democratizar o acesso à agricultura digital e fortalecer a sustentabilidade da agricultura familiar, contribuindo para reduzir as assimetrias tecnológicas no campo.

Palavras-chave:
Agricultura digital, CLIPS, Modelos híbridos, Sistema baseado em regras, Motor de inferência

Rio de Janeiro,

Dezembro de 2025

# ABSTRACT

Technology and Sustainability in Agriculture: A Recommender System for Small-Scale Farmers

André Luiz Coutinho Merlo

Advisor:
Diego Nunes Brandão

Abstract of dissertation submitted to Programa de Pós-graduação em Ciência da Computação - Centro Federal de Educação Tecnológica Celso Suckow da Fonseca CEFET/RJ as partial fulfillment of the requirements for the degree of master.

Digital agriculture has emerged as a cornerstone of technological transformation in the field by integrating sensors, algorithms, meteorological data, and artificial intelligence to make agricultural production more efficient, sustainable, and intelligent. In this context, family farming, which accounts for a large share of food production in Brazil, plays a strategic role not only in food security but also in environmental conservation and regional development. Nevertheless, small producers face barriers to accessing technologies and to making data-driven decisions. To address this gap, this work proposes an intelligent agricultural recommendation system designed to support family farmers in crop selection and soil management. The solution adopts a hybrid approach that combines a rule-based inference engine with data science techniques. The system leverages regional data on productivity, climatic conditions, and soil analyses to generate personalized recommendations on crops, as well as technical guidance on fertilization and liming (application of soil acidity amendments). By accounting for variables such as soil type and composition, production history, and climate, the system aims to increase productivity, reduce environmental impacts, and promote the economic sustainability of small rural producers. Experiments, coupled with statistical analysis of the outputs, demonstrate the feasibility of the proposed solution, with recommendations aligned with local agricultural practices and edaphoclimatic conditions (i.e., soil and climate integration applied to agronomic recommendations) for the evaluated regions. Agreement between the system and technical references was quantified using measures such as accuracy and Cohen's kappa, along with confidence intervals, and hypothesis tests to assess the significance of the results. These findings indicate that the system can become an accessible and scalable tool capable of democratizing access to digital agriculture and strengthening the sustainability of family farming, thereby helping reduce technological asymmetries in the field.

Key-words:
Digital agriculture, CLIPS, Hybrid models, Rule-based system, Inference engine

Rio de Janeiro,

Dezembro de 2025

## Lista de Figuras


II.1 Lógica da filtragem colaborativa baseada em usuário. As setas contínuas representam as escolhas dos usuários; as setas pontilhadas, as recomendações baseadas na colaboração entre os usuários. . . . . 10

II.2 Lógica da filtragem colaborativa baseada em item. As setas contínuas representam os itens escolhidos pelos usuários; as setas pontilhadas indicam recomendações baseadas na colaboração do item escolhido. . . . . 11

II.3 Lógica da filtragem baseada em conteúdo. Quando um determinado usuário acessa um artigo, o sistema recomenda outros artigos semelhantes com base no conteúdo deste artigo. . . . . 12

II.4 Lógica da filtragem baseada em contexto. Dado o contexto em que o usuário está inserido, o sistema recomenda itens. . . . . 13

II.5 Fluxo de execução do motor de regras (encadeamento progressivo) utilizado na dissertação. O *Programa Principal* instancia o motor e chama `.reset()` para limpar a memória de trabalho e gerar os fatos iniciais; em seguida, a agenda é atualizada com as regras cujas condições casam com a memória e é ordenada segundo a estratégia de resolução de conflitos definida. Com `.run()`, a primeira regra da agenda é disparada iterativamente, possivelmente modificando a memória de trabalho e reprogramando a agenda; o ciclo se repete até a agenda ficar vazia, quando a execução termina. . . . 20

III.1 Distribuição dos artigos totais e selecionados. . . . . 26

III.2 Fluxo PRISMA — Núcleo Agrícola: seleção a partir de 426 registros, resultando em 7 incluídos. . . . . 27

III.3 Fluxo PRISMA — CLIPS: seleção a partir de 35 registros, resultando em 2 incluídos. 30

IV.1 Arquitetura híbrida de recomendação. A partir dos *Modelos do Usuário* — (i) baseados em redes neurais (API), (ii) baseados em conteúdo e (iii) baseados em regras — são gerados candidatos. O *Gerenciador de Recomendações* integra essas saídas, aplicando restrições de domínio; o resultado é a *lista de recomendações* final, ordenada. 33

IV.2 Metodologia em cinco etapas: (i) coleta e pré-processamento de dados (solo, clima e produtividade); (ii) modelagem do conhecimento agronômico a partir do Manual de Adubação e Calagem da Embrapa-RJ e da API Agrofit; (iii) integração entre dados e regras com parametrização regional; (iv) implementação do motor de inferência em Python (PyKnow/CLIPS); e (v) validação e testes em múltiplos cenários. . . . . 34
IV.3 Fluxo de decisão do sistema de recomendação agrícola proposto. A partir de BDSolos/EMBRAPA, dos dados meteorológicos do INMET, da produtividade da EMATER-Rio e do Manual de Adubação e Calagem, o sistema elabora uma camada de dados de recomendação. O usuário informa a cidade e, conforme a disponibilidade de dados de solo e (opcionalmente) a escolha de uma cultura, o sistema: (i) sem dados de solo, recomenda culturas pela produtividade regional e fornece orientações genéricas de adubação/calagem e panorama climático; (ii) com dados de solo, combina análise de solo e clima (chuva, temperatura e umidade) para indicar as culturas economicamente mais promissoras e orientações de manejo; (iii) quando há seleção de cultura, as recomendações priorizam essa cultura. . . . . 35
IV.4 Coleta e Pré-processamento. Dados do INMET (clima), EMATER-Rio (produtividade), Embrapa BDSolos (solos) e Manual de Adubagem e Calagem da Embrapa (conhecimento agronômico) são padronizados, validados e integrados em um repositório único, que alimenta o sistema de recomendação. . . . . 36
IV.5 Modelagem das regras em formato JSON. . . . . 38
IV.6 Integração entre Dados e Regras. . . . . 39
IV.7 Visão esquemática da implementação do motor de inferência baseado em regras, evidenciando a inserção de fatos, a avaliação das regras e a geração das recomendações. 40
IV.8 Visão esquemática da geração e organização das recomendações no relatório final do sistema. . . . . 41

V.1 Volume de chuvas da região serrana, separado por mês do ano, nos últimos 6 anos. Fonte: O próprio autor. . . . . 47
V.2 Volume de chuvas da região serrana, separado por mês do ano, nos últimos 6 anos. Fonte: O próprio autor. . . . . 48
V.3 Média dos valores ausentes por faixa de colunas na base BDSolos. Observa-se crescimento acentuado das ausências até estabilizar-se em um patamar elevado, evidenciando alta esparsidade e um grande conjunto de atributos com baixo preenchimento; esse padrão motivou a filtragem de colunas e a padronização. . . . . 50

V.4 Distribuição das colunas por faixa de percentual de ausência na BDSolos. Nota-se forte concentração no intervalo de 90–100% de dados faltantes, superando amplamente as demais faixas, enquanto poucas colunas têm ausência inferior a 50%. Esse padrão de esparsidade levou à eliminação ou ao agrupamento de atributos com baixo preenchimento. . . . . 51
V.5 Pipeline de ETL dos dados de solo da Embrapa Solos (BDSolos). O fluxo superior executa a ingestão, transformação, limpeza e mapeamento dos dados para o esquema-alvo; em seguida, os dados normalizados são gravados em *CSV* por tabela. No fluxo inferior, os arquivos são validados e então carregados no banco de dados, garantindo padronização e consistência antes de abastecer o sistema de recomendação. . . . . 51
V.6 Gráfico comparativo do faturamento bruto por cultura cultivada entre 2021 e 2023. . 54
V.7 Gráfico comparativo da produção colhida, em toneladas, por cultura cultivada entre 2021 e 2023. . . . . 55
V.8 Mapa do volume colhido dos anos 2021 a 2023. . . . . 55

## Lista de Tabelas

III.1 Quantidade de artigos por ano de publicação da pesquisa sistemática na base *Scopus*. 26
III.2 Critérios de inclusão e exclusão aplicados na triagem e elegibilidade. . . . . 27

IV.1 Amostra dos cenários de teste realizados . . . . . 44

V.1 Resumo estatístico da base de dados meteorológicos do INMET . . . . . 48
V.2 Amostra da base de dados meteorológicos do INMET . . . . . 49
V.3 Resumo estatístico da base de dados de solo legado da Embrapa (BDSolos) . . . . . 50
V.4 Resultado dos registros afetados pelo ETL dos dados de solo. . . . . 53
V.5 Resumo estatístico da base de dados da EMATER-Rio (Projeto ASPA) . . . . . 56
V.6 Amostra da base de dados da EMATER-Rio . . . . . 56
V.7 Variáveis climáticas disponíveis na API ClimAPI . . . . . 57
V.8 Endpoints da API ClimAPI da Embrapa . . . . . 57

VI.1 Resultados globais consolidados da concordância entre o sistema (manual algorítmico) e especialistas em 180 cenários. . . . . 73

A.1 Amostra dos cenários de teste realizados . . . . . 86

## Lista de Acrônimos

| | |
|---|---|
| API | Application Programming Interface. |
| ASPA | Acompanhamento Sistemático da Produtividade Agrícola. |
| CHAID | Chi-Square Automatic Interaction Detection. |
| CLIPS | C Language Integrated Production System. |
| CNN | Redes Neurais Convolucionais. |
| CTC | Capacidade de Troca Catiônica. |
| EMATER-Rio | Empresa de Assistência Técnica e Extensão Rural do Estado do Rio de Janeiro. |
| EMBRAPA | Empresa Brasileira de Pesquisa Agropecuária. |
| ETL | Extract Transform Load. |
| GNN | Graph Neural Networks. |
| HTML | HyperText Markup Language. |
| INMET | Instituto Nacional de Meteorologia. |
| IoT | Internet of Things. |
| JSON | JavaScript Object Notation. |
| REST | REpresentational State Transfer. |
| RNN | Redes Neurais Recorrentes. |
| SiBCS | Sistema Brasileiro de Classificação de Solos. |
| TF-IDF | Term Frequency-Inverse Document Frequency. |

## Sumário


**I Introdução** **6**

**II Referencial Teórico** **9**

II.1 Sistemas de Recomendação 9

II.1.1 Filtragem Colaborativa 10

II.1.2 Filtragem Baseada em Conteúdo 11

II.1.3 Filtragem Baseada em Contexto 13

II.1.4 Modelos Baseados em Redes Neurais 14

II.1.5 Modelos Baseados em Regras 14

II.1.6 Modelos Híbridos 15

II.2 Agricultura Digital 16

II.3 Motores de Regras 18

II.4 CLIPS como Motor de Regras 21

II.5 Manual de Adubagem e Calagem da Embrapa 22

**III Trabalhos Relacionados** **25**

III.1 Núcleo Agrícola 25

III.2 CLIPS em Sistemas Especialistas 30

III.3 Considerações da Revisão de Literatura 31

**IV Metodologia** **32**

IV.1 Visão Geral da Metodologia 33

IV.2 Coleta e Pré-processamento dos Dados 36

IV.3 Modelagem das Regras de Recomendação 38

IV.4 Integração entre Dados e Regras 39

IV.5 Implementação do Motor de Inferência 40

IV.6 Geração das Recomendações 41

IV.7 Metodologia de Avaliação: Coeficiente Kappa de Cohen 42

IV.8 Construção e Avaliação dos Cenários de Teste 43

IV.9 Considerações Finais da Metodologia 45

**V Aspectos de Implementação e Ambiente Experimental** **46**
V.1 Dados Meteorológicos 46
V.2 Dados de Solo 49
V.3 Dados de Produtividade Rural 53
V.4 Acesso à Previsão Climática via API da Embrapa (ClimAPI) 56
V.5 Base de Regras 58
V.5.1 Exemplo de Regra de Cultura 58
V.5.2 Exemplo de Regra para Adubação 60
V.5.3 Exemplo de Regra de Calagem 62
V.6 Considerações das Bases de Dados 63
V.7 Arquitetura Tecnológica e Ferramentas 64
V.8 Execução dos Cenários de Teste 64
V.9 Limitações Observadas 65

**VI Resultados** **66**
VI.1 Protocolo de Avaliação 66
VI.2 Hipóteses e Critérios de Aceitação 66
VI.3 Métricas de Avaliação 67
VI.4 Procedimento de Teste de Hipóteses 69
VI.5 Resultados dos Testes (Síntese) 69
VI.6 Cálculo das Métricas: Acurácia, Precisão, Revocação e F1 70
VI.7 Cálculo do Kappa de Cohen 71
VI.8 Resultados Globais 72
VI.9 Resultados por Tipo de Recomendação 73
VI.10 Desempenho e Robustez Computacional 74
VI.11 Ameaças à Validade 74
VI.12 Síntese dos Resultados 74
VI.13 Relatório Gerado 74

**VII Considerações Finais** **75**
VII.1 Trabalhos Futuros 76

**Referências** **78**

**A - Cenários de Teste** **85**

**B - Recomendações do Sistema** **93**

# Capítulo I Introdução

A agricultura é uma das atividades mais estratégicas para o desenvolvimento econômico, social e ambiental do Brasil, desempenhando papel fundamental na segurança alimentar e na geração de renda, especialmente em regiões rurais com predominância de pequenos produtores [Martinelli et al., 2010]. Contudo, o bom desempenho da produção agrícola depende de diversos fatores técnicos, entre os quais se destacam a escolha adequada das culturas, o manejo eficiente do solo e, sobretudo, as práticas de adubação e calagem. Esta última consiste na aplicação de corretivos de acidez, como o calcário calcítico ou dolomítico, com o objetivo de elevar o pH do solo, aumentar a saturação por bases e reduzir a acidez, promovendo, assim, a disponibilidade de nutrientes e a eficiência dos fertilizantes [Agegnehu et al., 2023].

A tomada de decisão sobre esses insumos envolve a análise de parâmetros químicos, físicos e climáticos, que muitas vezes não são devidamente interpretados por pequenos produtores devido à ausência de assistência técnica contínua ou à complexidade dos dados disponíveis [Alves et al., 2020]. Esse cenário tem motivado o desenvolvimento de tecnologias no campo da agricultura digital, capazes de transformar dados em recomendações práticas e acessíveis [Zhai et al., 2021]. Entre essas soluções, os sistemas de recomendação têm se destacado por sua capacidade de apoiar decisões agronômicas de forma personalizada, transparente e baseada em conhecimento técnico validado [Hinojosa et al., 2023]. Neste contexto, surge a seguinte pergunta de pesquisa: "como construir um sistema de recomendação agrícola que seja capaz de auxiliar pequenos produtores na escolha de culturas e no manejo eficiente do solo, considerando a variabilidade edafoclimática[1] e os dados regionalizados de produtividade?".

Neste trabalho, usamos *edafoclimática* para caracterizar a integração entre atributos do solo (p.ex., textura, pH, matéria orgânica, macronutrientes, CTC) e variáveis climáticas (p.ex., precipitação, temperatura, umidade, radiação/insolação, ETo), de forma a orientar a aptidão de culturas e o manejo (calagem e adubação). Essa definição é operacional: sempre que o texto mencionar "análise edafoclimática", refere-se ao uso conjunto de dados de solo e de clima para gerar recomendações específicas para cada localidade.

A relevância desta investigação está alinhada com diversos Objetivos de Desenvolvimento Sus-

[1]Refere-se à combinação de características do solo (edafo-) e do clima (-climática) que, juntas, influenciam a capacidade de uma região para o desenvolvimento de plantas e culturas agrícolas.

tentável (ODS) propostos pela Organização das Nações Unidas[2] [Carlsen and Bruggemann, 2022], em especial: o ODS 2 (Fome Zero e Agricultura Sustentável), ao promover sistemas agrícolas resilientes e produtivos; o ODS 9 (Indústria, Inovação e Infraestrutura), ao integrar soluções tecnológicas no campo; e o ODS 12 (Consumo e Produção Responsáveis), ao incentivar o uso racional de insumos agrícolas com base em evidências. Assim, a presente pesquisa busca contribuir para a democratização do acesso à agricultura digital e para o fortalecimento da sustentabilidade no setor agropecuário brasileiro.

Para responder à pergunta de pesquisa, esta dissertação desenvolve um sistema inteligente de recomendação agrícola voltado a apoiar agricultores familiares na escolha de culturas, na adubação e na calagem, bem como na definição de janelas de cultivo em função do clima [Diniz, 2016]. O percurso metodológico segue cinco etapas integradas: (i) *coleta e pré-processamento* de dados meteorológicos, de solo e de produtividade; (ii) *modelagem do conhecimento* agronômico a partir do Manual de Adubagem e Calagem da Embrapa-RJ [Freire et al., 2013] e de bases auxiliares, com formalização em regras; (iii) *integração entre dados e regras* com parametrização regional; (iv) *implementação do motor de inferência* em Python (abordagem CLIPS/PyKnow) para operacionalizar encadeamento direto e geração de recomendações explicáveis; e (v) *validação* por meio de cenários de teste comparando as saídas do sistema com referências técnicas e julgamentos de especialistas.

A solução adota uma abordagem híbrida que combina um motor de inferência baseado em regras com técnicas de ciência de dados aplicadas à agricultura digital. O sistema utiliza dados regionais de produtividade, condições climáticas e análises de solo para gerar recomendações técnicas personalizadas. As regras de recomendação foram extraídas do "Manual de Adubagem e Calagem para o Estado do RJ" [Freire et al., 2013], desenvolvido pela Embrapa-RJ[3] em 2013, e estruturadas em arquivos JSON, o que possibilita modularidade e manutenção eficiente do sistema.

O motor de inferência utilizado neste trabalho baseia-se nos princípios do sistema CLIPS (*C Language Integrated Production System*), uma ferramenta amplamente empregada no desenvolvimento de sistemas especialistas baseados em regras [Papadopoulos et al., 2022; Manoharan et al., 2023]. O CLIPS foi projetado para facilitar a construção de sistemas de tomada de decisão automatizada por meio de regras lógicas do tipo *if–then*, permitindo a representação de conhecimento de forma transparente e interpretável [Riley, 1994]. Inspirado nessa abordagem, o sistema processa dados agronômicos, como análises de solo, características das culturas e informações sobre insumos, a fim de gerar recomendações fundamentadas. As saídas são apresentadas em relatórios digitais com duas seções principais: uma seção contextual, que analisa o clima e a produtividade agrícola regionais; e uma seção técnica, que fornece recomendações específicas e justificadas para o manejo do solo e a escolha de culturas, considerando as condições edafoclimáticas locais.

[2] `https://www.un.org`

[3] Empresa Brasileira de Pesquisa Agropecuária

Em linha com os objetivos delineados, os experimentos preliminares, acompanhados de análise estatística das saídas, evidenciaram a viabilidade do sistema e o alinhamento das recomendações às práticas agrícolas locais e às condições edafoclimáticas das regiões avaliadas. A concordância entre o sistema e as referências técnicas foi quantificada por meio de métricas como acurácia e Kappa de Cohen, com intervalos de confiança e testes de hipótese para avaliar a significância, indicando potencial de aplicação prática e de escalabilidade em contextos de agricultura familiar. Espera-se, com esse arranjo, obter recomendações interpretáveis e rastreáveis, reduzir variabilidade decisória entre avaliadores, e demonstrar concordância estatisticamente significativa com padrões técnicos de referência.

A dissertação está estruturada da seguinte forma: o Capítulo II apresenta os fundamentos teóricos e o estado da arte relacionado a sistemas de recomendação e descreve o referencial teórico associado ao trabalho proposto. O Capítulo III apresenta uma revisão dos trabalhos relacionados. O Capítulo IV detalha a metodologia de desenvolvimento do sistema. O Capítulo V descreve as bases de dados e os experimentos realizados. O Capítulo VI apresenta resultados, testes e validações. Por fim, o Capítulo VII discute considerações finais, limitações e direções para trabalhos futuros.

# Capítulo II Referencial Teórico

O objetivo deste capítulo é apresentar os conceitos que fundamentam esta pesquisa. Para tanto, está dividido em cinco seções: a Seção II.1 aborda os principais tipos de sistemas de recomendação no contexto deste trabalho, a Seção II.2 discute a agricultura digital, a Seção II.3 apresenta os conceitos sobre motores de regras, a Seção II.4 apresenta o software CLIPS e a sua escolha no trabalho e a Seção II.5 apresenta o manual de adubagem e calagem criado pela EMBRAPA em conjunto com outras instituições.

## II.1 Sistemas de Recomendação

Os sistemas de recomendação são ferramentas essenciais em diversos setores, desempenhando um papel crucial na personalização de experiências e na facilitação da tomada de decisão pelos usuários [Lu et al., 2015]. Inicialmente popularizados por plataformas de e-commerce e serviços de streaming, esses sistemas evoluíram significativamente, abrangendo uma variedade de técnicas e metodologias para melhorar a precisão e a relevância das recomendações [Guan et al., 2016]. A filtragem colaborativa e a filtragem baseada em conteúdo são duas das abordagens mais conhecidas, cada uma com suas próprias vantagens e desvantagens, e frequentemente combinadas em métodos híbridos para maximizar a eficácia [Thorat et al., 2015].

Na agricultura, os sistemas de recomendação têm potencial transformador, auxiliando produtores na escolha de cultivares, na otimização do uso de insumos e na adoção de práticas agrícolas sustentáveis. Esses sistemas podem utilizar dados contextuais, como condições climáticas e características do solo, além de informações demográficas dos produtores, para oferecer recomendações personalizadas que atendam às necessidades específicas de cada região e de cada tipo de cultivo. A integração de técnicas avançadas, como redes neurais e fatoração de matrizes, permite capturar padrões complexos nas interações entre variáveis agrícolas, proporcionando *insights* valiosos para a tomada de decisão [Wolfert et al., 2017].

Nesta dissertação, exploramos diversos métodos de recomendação aplicáveis à agricultura, incluindo filtragem colaborativa, filtragem baseada em conteúdo, métodos híbridos, recomendações baseadas em regras, filtragem baseada em popularidade e demografia, além de modelos baseados em redes neurais, contexto, grafos e fatores latentes. Cada um desses métodos foi detalhado em seus

princípios, vantagens, desvantagens e exemplos de aplicação, destacando como podem ser utilizados para aprimorar a eficiência e a sustentabilidade das práticas agrícolas.

### II.1.1 Filtragem Colaborativa

A filtragem colaborativa é uma das técnicas mais populares e amplamente utilizadas em sistemas de recomendação. Esta técnica baseia-se na ideia de que usuários que tiveram preferências semelhantes no passado continuarão a ter preferências semelhantes no futuro. Existem duas abordagens principais para a filtragem colaborativa: baseada em usuário (*user-based*) e baseada em item (*item-based*) [Koren and Bell, 2015].

#### Filtragem Colaborativa Baseada em Usuário

A filtragem colaborativa baseada em usuários realiza recomendações ao identificar perfis semelhantes ao do usuário-alvo. A lógica central consiste em encontrar outros usuários com padrões de preferência próximos e sugerir ao usuário-alvo os itens que esses semelhantes apreciaram. Essa similaridade entre usuários é tipicamente mensurada por métricas como a correlação de Pearson, a similaridade do cosseno ou a distância euclidiana [Resnick et al., 1994; Sarwar et al., 2001]. Após a identificação dos usuários mais próximos, suas avaliações são agregadas para compor uma lista de recomendações. A Figura II.1 exemplifica a lógica da filtragem.

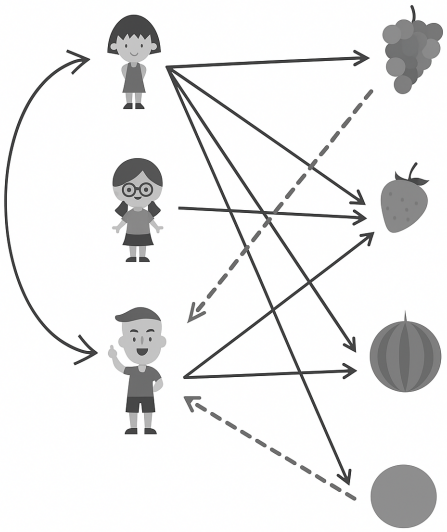


Figura II.1: Lógica da filtragem colaborativa baseada em usuário. As setas contínuas representam as escolhas dos usuários; as setas pontilhadas, as recomendações baseadas na colaboração entre os usuários.

Essa abordagem é reconhecida por sua simplicidade e por seu bom desempenho em ambientes ricos em dados de interação. No entanto, apresenta limitações importantes, como dificuldades de escalabilidade em sistemas com grandes volumes de usuários e o problema do *cold start*, que

prejudica a geração de recomendações para novos usuários sem histórico de preferências [Bobadilla et al., 2013; Ricci et al., 2011].

### Filtragem Colaborativa Baseada em Item

A filtragem colaborativa baseada em itens realiza recomendações ao analisar a similaridade entre itens, em vez de entre usuários. O sistema identifica quais itens são semelhantes aos que o usuário já avaliou positivamente e recomenda itens com perfis similares. A similaridade é calculada por meio de métricas como a correlação de Pearson, a similaridade de cosseno ou a distância euclidiana, e um modelo é construído para relacionar cada item com os demais [Sarwar et al., 2001; Koren and Bell, 2015]. Com isso, os itens mais próximos dos já apreciados pelo usuário são priorizados nas recomendações. A Figura II.2 exemplifica a lógica da filtragem por item.

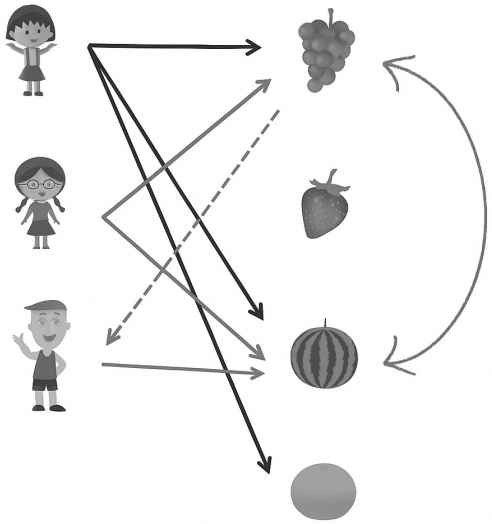


Figura II.2: Lógica da filtragem colaborativa baseada em item. As setas contínuas representam os itens escolhidos pelos usuários; as setas pontilhadas indicam recomendações baseadas na colaboração do item escolhido.

Essa abordagem se destaca por sua escalabilidade, sendo especialmente eficaz em sistemas com grandes volumes de usuários, pois o número de itens tende a ser menor que o número de usuários. Além disso, é menos suscetível ao problema do *cold start* no caso de novos usuários, embora ainda possa enfrentar limitações para itens recém-inseridos no sistema, que não possuem avaliações suficientes. A acurácia das recomendações também pode ser reduzida quando não há correlação forte entre as avaliações dos usuários e a estrutura de similaridade entre os itens [Ricci et al., 2011; Bobadilla et al., 2013].

## II.1.2 Filtragem Baseada em Conteúdo

A filtragem baseada em conteúdo é uma técnica de recomendação que sugere itens ao usuário com base em suas preferências anteriores e nas características dos próprios itens. Diferentemente

da filtragem colaborativa, que depende das avaliações de outros usuários, essa abordagem foca exclusivamente no perfil individual do usuário, construído com base em interações anteriores [Lops et al., 2011]. Cada item é representado por um conjunto de atributos, como gênero, diretor ou elenco no caso de filmes, e o sistema avalia a similaridade entre esses atributos e o perfil do usuário.

Essa similaridade é normalmente calculada por meio de técnicas como TF-IDF (*Term Frequency–Inverse Document Frequency*) ou de métodos de aprendizado de máquina, como redes neurais ou árvores de decisão [Pazzani and Billsus, 2007]. O sistema recomenda itens que compartilham características com aqueles em que o usuário já demonstrou interesse, proporcionando um alto grau de personalização. A Figura II.3 exemplifica a filtragem baseada em conteúdo.

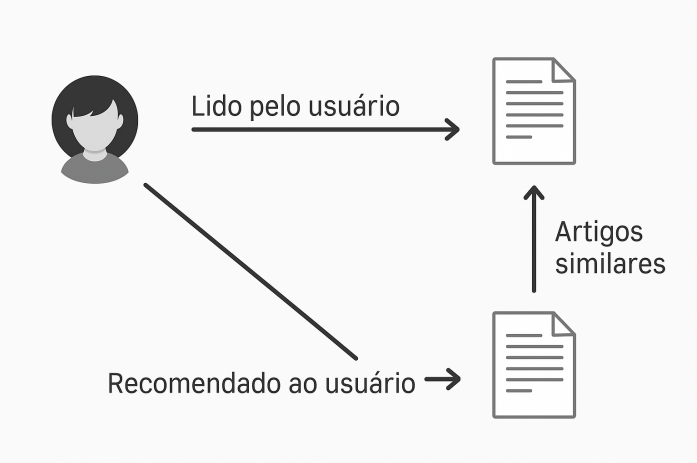



Figura II.3: Lógica da filtragem baseada em conteúdo. Quando um determinado usuário acessa um artigo, o sistema recomenda outros artigos semelhantes com base no conteúdo deste artigo.

Entre as principais vantagens desta abordagem estão a independência em relação aos dados de outros usuários (evitando o problema de *cold start* para novos perfis) e a facilidade de explicação das recomendações, já que é possível apontar quais atributos justificam a sugestão. No entanto, esse modelo também apresenta limitações. Uma delas é a superespecialização, que pode levar o usuário a receber sugestões excessivamente semelhantes, restringindo a descoberta de novos interesses, fenômeno conhecido como "filtro bolha" [Adomavicius and Tuzhilin, 2005]. Além disso, a eficácia da recomendação depende diretamente da qualidade dos atributos disponíveis, sendo difícil capturar preferências complexas com base apenas em características explícitas dos itens.

Sistemas de recomendação baseados em conteúdo são amplamente utilizados em ambientes como Netflix[1], IMDB[2] e Google Scholar[3], nos quais os itens recomendados refletem diretamente os interesses previamente demonstrados pelo usuário [Lops et al., 2011].

[1]https://www.netflix.com
[2]https://www.imdb.com
[3]https://scholar.google.com

### II.1.3 Filtragem Baseada em Contexto

A filtragem baseada em contexto é uma técnica de recomendação que amplia os modelos tradicionais ao incorporar variáveis contextuais na geração de recomendações. Além das preferências do usuário e das características dos itens, consideram-se informações como horário, localização, clima, dispositivo utilizado e até o estado emocional do usuário [Adomavicius and Tuzhilin, 2011]. O objetivo é fornecer recomendações mais relevantes e situacionais, ajustadas à realidade momentânea da interação.

Esse tipo de sistema depende da identificação e modelagem de fatores contextuais, que são integrados ao processo de recomendação por meio de técnicas como a fatoração de matrizes, o aprendizado profundo e modelos probabilísticos [Bazire and Brézillon, 2005; Hariri et al., 2012]. Por exemplo, um aplicativo de música pode sugerir playlists diferentes conforme o usuário esteja se exercitando, trabalhando ou relaxando. Da mesma forma, em e-commerce, recomendações podem variar conforme a estação do ano, o horário ou até o clima local. A Figura II.4 exemplifica a filtragem baseada em contexto.

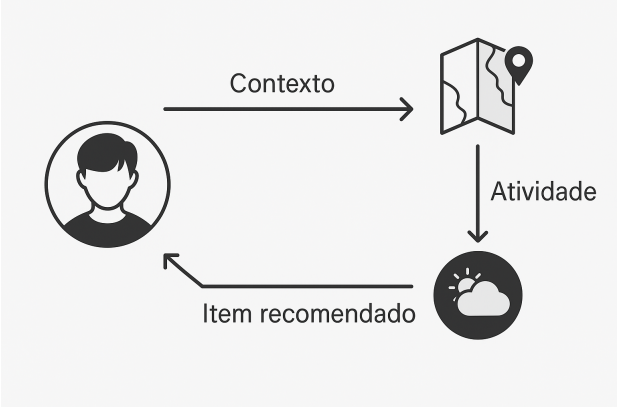



Figura II.4: Lógica da filtragem baseada em contexto. Dado o contexto em que o usuário está inserido, o sistema recomenda itens.

Entre suas vantagens estão a personalização dinâmica e a melhora significativa na relevância das recomendações, uma vez que o sistema se adapta ao ambiente e ao comportamento do usuário em tempo real. No entanto, a abordagem traz desafios adicionais, como a complexidade da coleta e da integração de dados contextuais, além de preocupações com privacidade e da necessidade de bases de dados mais ricas e detalhadas [Adomavicius and Tuzhilin, 2011; Hariri et al., 2012].

Aplicações práticas dessa técnica são encontradas em diversos domínios: em serviços de navegação, que recomendam rotas considerando o tráfego e as preferências; em plataformas de streaming, que ajustam sugestões de mídia com base no horário e na atividade; e no comércio eletrônico, que recomenda produtos conforme a sazonalidade e as preferências situacionais do usuário.

### II.1.4 Modelos Baseados em Redes Neurais

Modelos baseados em redes neurais representam um avanço significativo nos sistemas de recomendação, ao utilizar aprendizado profundo para capturar padrões complexos nas interações entre usuários e itens. Ao contrário dos métodos tradicionais, que dependem de fatoração de matrizes ou heurísticas simples, as redes neurais são capazes de modelar não linearidades e relações altamente complexas, resultando em recomendações mais precisas e personalizadas [Zhang et al., 2019; He et al., 2017].

Nessa abordagem, os históricos de interação e os atributos dos itens são transformados em representações numéricas, como embeddings, que alimentam diferentes arquiteturas de redes neurais, incluindo redes feedforward, convolucionais (CNNs), recorrentes (RNNs) e autoencoders. Recentemente, modelos mais sofisticados, como Transformers e Graph Neural Networks (GNNs), também têm sido aplicados para capturar dependências sequenciais e relacionamentos estruturais complexos [Sun et al., 2019; Wu et al., 2021].

O treinamento desses modelos requer grandes volumes de dados e poder computacional elevado, utilizando algoritmos de otimização como gradiente descendente estocástico. Uma das principais vantagens é a capacidade de unificar diferentes fontes de informação — interações, conteúdo, contexto e redes sociais — em um único modelo, aumentando significativamente a acurácia e a robustez das recomendações [Zhang et al., 2019].

No entanto, esses modelos apresentam desafios, como a alta demanda computacional, a dependência de dados em larga escala e a dificuldade de interpretabilidade, já que as decisões são produzidas por estruturas complexas, muitas vezes vistas como caixas pretas [Deldjoo et al., 2020]. Apesar disso, seu impacto é evidente em empresas como Netflix, Spotify, Amazon e Meta (Facebook e Instagram), que são fundamentais para gerar recomendações personalizadas de conteúdo, produtos e conexões sociais.

### II.1.5 Modelos Baseados em Regras

Os sistemas de recomendação baseados em regras utilizam um conjunto de regras pré-definidas para sugerir itens aos usuários. Essas regras geralmente são derivadas de heurísticas, do conhecimento de domínio ou de políticas organizacionais. Esse método é frequentemente utilizado em cenários em que o comportamento do usuário e as preferências são bem compreendidos, permitindo a definição de regras claras e precisas [Adomavicius and Tuzhilin, 2005].

As regras são criadas com base em critérios específicos. Por exemplo, uma regra pode ser “Se o usuário comprou um laptop, recomendar acessórios como mouses e teclados”. As regras são aplicadas ao perfil do usuário e ao conjunto de itens disponíveis para a geração de recomendações. Essas regras podem ser simples, como associações diretas, ou mais complexas, envolvendo múltiplas condições.

As recomendações baseadas em regras podem ser combinadas com outras técnicas de recomendação, como a filtragem colaborativa e a baseada em conteúdo, para formar sistemas híbridos.

As recomendações baseadas em regras têm várias vantagens, incluindo a facilidade de implementação e de compreensão, bem como regras explícitas que facilitam a explicação das recomendações ao usuário. Este método permite que as empresas controlem diretamente quais itens são recomendados, ajustando as regras conforme necessário, e pode ser utilizado para garantir conformidade com políticas organizacionais ou regulatórias. No entanto, também apresenta desvantagens, como a criação e manutenção de regras manuais, que podem ser trabalhosas e não escalam bem com muitos usuários e itens. Além disso, as recomendações podem não ser tão personalizadas quanto as geradas por métodos que aprendem automaticamente as preferências dos usuários, e as regras podem ser inflexíveis, não se adaptando bem a mudanças nas preferências dos usuários ou nas tendências de mercado [Jannach et al., 2011].

Recomendações baseadas em regras são amplamente aplicadas em diversos setores. Em e-commerce, sites frequentemente utilizam regras para recomendar produtos complementares ou relacionados, como "frequentemente comprados juntos". No marketing digital, campanhas podem usar regras para segmentar usuários e oferecer promoções específicas, como "se um usuário clicar em um anúncio de viagens, enviar ofertas de pacotes turísticos". Nos serviços financeiros, as instituições utilizam regras para recomendar produtos financeiros com base no perfil do cliente, como "se um cliente tem um saldo alto em conta-corrente, recomendar opções de investimento". Na agricultura, por exemplo, regras podem ser definidas com base em dados edafoclimáticos e recomendações técnicas estabelecidas, como "se o teor de fósforo no solo for baixo, recomendar aplicação de fertilizantes fosfatados" [Freire et al., 2013].

### II.1.6 Modelos Híbridos

Sistemas de recomendação híbridos combinam múltiplas abordagens com o objetivo de explorar as vantagens complementares de cada técnica e mitigar limitações individuais, como problemas de *cold start*, superespecialização ou baixa interpretabilidade. Ao integrar métodos distintos, esses sistemas buscam maior robustez, consistência e aderência ao contexto de aplicação, sendo amplamente discutidos na literatura clássica de sistemas de recomendação [Burke, 2002].

Burke [Burke, 2002] propõe uma tipologia amplamente adotada para classificar métodos híbridos, segundo a forma como as diferentes técnicas interagem. Entre essas categorias destacam-se os modelos de hibridização combinada (*Weighted Hybrid*), nos quais as saídas de diferentes recomendadores são agregadas por meio de pesos, os modelos baseados em alternância (*Switching Hybrid*), que selecionam dinamicamente uma técnica conforme critérios contextuais, e os modelos mistos (*Mixed Hybrid*), nos quais recomendações oriundas de diferentes abordagens são apresentadas simultanea-

mente.

Outras duas categorias são particularmente relevantes para a análise do sistema proposto neste trabalho. Nos modelos do tipo *Meta-level Hybrid*, uma técnica é utilizada para aprender representações, perfis ou parâmetros que passam a alimentar a lógica interna de outro método responsável pela recomendação final. Nesse caso, o aprendizado ocorre em nível de meta-conhecimento [Burke, 2002, 2007], influenciando diretamente o processo decisório subsequente. Já nos modelos do tipo *Cascade Hybrid*, as técnicas são aplicadas de forma sequencial, em estágios hierárquicos, nos quais um método estrutura ou restringe o espaço de decisão e o método seguinte atua no refinamento ou na validação dos resultados, sem modificar o conhecimento subjacente do estágio anterior [Burke, 2002].

À luz dessas definições, a arquitetura adotada nesta dissertação enquadra-se como um modelo híbrido do tipo *Cascade Hybrid*. O sistema de recomendação fundamenta-se inicialmente em um motor de inferência baseado em regras explícitas, extraídas do *Manual de Adubação e Calagem*, que determina diretamente as decisões de manejo do solo. As etapas subsequentes do processamento concentram-se na organização dos dados de entrada, na contextualização regional e na apresentação das recomendações, não havendo mecanismos de aprendizado automático responsáveis por gerar ou ajustar a base de conhecimento agronômico. Dessa forma, diferentemente de abordagens do tipo *Meta-level Hybrid*, o sistema proposto não aprende parâmetros ou representações que alterem dinamicamente a lógica decisória, caracterizando-se como um híbrido em cascata orientado por regras [Adomavicius and Tuzhilin, 2005; Ricci et al., 2011].

A adoção desse tipo de hibridização é particularmente adequada ao domínio agrícola, no qual a transparência, a interpretabilidade e a aderência a normas técnicas consolidadas são requisitos fundamentais. Nesse contexto, sistemas híbridos em cascata permitem combinar o rigor do conhecimento agronômico formalizado com a flexibilidade computacional necessária para lidar com múltiplas fontes de dados, preservando a rastreabilidade das decisões e facilitando sua validação por especialistas humanos [Wolfert et al., 2017; Fountas et al., 2015].

## II.2 Agricultura Digital

A agricultura digital representa uma transformação estrutural no setor agrícola ao incorporar tecnologias de informação e comunicação em toda a cadeia produtiva, possibilitando a coleta, integração e análise contínua de grandes volumes de dados provenientes de sensores, bases meteorológicas, imagens, sistemas de automação e plataformas inteligentes. Diferentemente da agricultura de precisão, que se concentra na aplicação localizada de insumos e no manejo específico por talhão, a agricultura digital abrange uma perspectiva mais ampla, orientada por dados e processos digitais que integram monitoramento, modelagem, recomendação, rastreabilidade e apoio à decisão

em escala sistêmica [Wolfert et al., 2017]. Nesse contexto, a agricultura de precisão constitui um subconjunto da agricultura digital, focado em intervenções espaciais e operacionais, enquanto a agricultura digital engloba também camadas analíticas, gerenciais e preditivas apoiadas por inteligência artificial, *big data* e Internet das Coisas [Zhang et al., 2002].

A coleta e a análise de dados desempenham um papel central na agricultura digital. Sensores distribuídos pelos campos monitoram uma ampla gama de variáveis, como umidade do solo, temperatura, níveis de nutrientes e o estado de saúde das plantas. Esses dados são transmitidos para sistemas centralizados, onde são processados e analisados para gerar percepções valiosas. A análise desses dados permite identificar padrões e tendências que não seriam detectáveis visualmente, facilitando ajustes precisos nas práticas de cultivo, como a aplicação de fertilizantes, a irrigação e o controle de pragas. Isso resulta em um uso mais eficiente de insumos, reduzindo desperdícios e aumentando a produtividade [Kamilaris and Prenafeta-Boldú, 2018; Wolfert et al., 2017].

A agricultura digital também se destaca por ampliar a eficiência no uso de recursos, o que é importante em um contexto de crescente preocupação com a sustentabilidade ambiental. Ao possibilitar o uso racional de água, fertilizantes e pesticidas, a agricultura digital contribui para reduzir os impactos ambientais, promovendo práticas mais sustentáveis. Além disso, a automação e a robótica, componentes-chave da agricultura digital, permitem que operações como plantio, colheita e pulverização sejam realizadas com precisão e consistência, reduzindo a dependência de trabalho manual e aumentando a produtividade [Bechar and Vigneault, 2016].

A inteligência artificial desempenha um papel especialmente importante na agricultura digital, permitindo a criação de modelos preditivos que ajudam a antecipar problemas, como surtos de doenças ou pragas, evitando que causem danos significativos às culturas. Esses modelos também podem ser utilizados para recomendar as melhores práticas agrícolas, como o tipo de cultura a ser plantada em determinada estação ou a quantidade ideal de insumos a ser aplicada, considerando uma ampla variedade de fatores contextuais, como previsões climáticas, histórico do solo e características específicas da propriedade agrícola [Kamilaris and Prenafeta-Boldú, 2018; Schemberger et al., 2017].

Outro elemento central da agricultura digital é a conectividade no campo. O conceito de fazendas conectadas está se tornando cada vez mais prevalente, com tratores, colheitadeiras e outros equipamentos agrícolas equipados com tecnologia IoT, o que permite a comunicação entre dispositivos e sistemas centrais para coordenar operações de forma autônoma e eficiente [Wolfert et al., 2017]. Essa conectividade também promove a rastreabilidade das operações agrícolas, permitindo o monitoramento completo do ciclo de vida de uma cultura, desde o plantio até a colheita e distribuição, garantindo maior transparência e controle. No entanto, a adoção da agricultura digital enfrenta desafios consideráveis. Um dos principais é o alto custo inicial das tecnologias, o que pode dificultar o acesso de pequenos produtores e agricultores em regiões menos desenvolvidas. Além

disso, a análise dos grandes volumes de dados gerados (*big data*) requer infraestrutura robusta e conhecimentos especializados, o que também pode limitar a adoção em larga escala. Outro entrave é a conectividade rural: muitas regiões agrícolas ainda carecem de acesso à Internet de alta velocidade, o que é importante para o funcionamento dessas tecnologias [Hundal et al., 2023].

Apesar desses desafios, a tendência global é a crescente adoção da agricultura digital, impulsionada por avanços tecnológicos contínuos e pela necessidade urgente de aumentar a eficiência e a sustentabilidade no setor agrícola. À medida que essas tecnologias se tornam mais acessíveis e integradas, a agricultura digital tende a desempenhar um papel cada vez mais importante na transformação da agricultura, ajudando a enfrentar os desafios da segurança alimentar e das mudanças climáticas de maneira mais eficaz e sustentável. Este movimento promete não apenas melhorar a produtividade e a rentabilidade das operações agrícolas, mas também contribuir para práticas mais responsáveis e conscientes, que considerem o bem-estar ambiental e a sustentabilidade a longo prazo [Kamilaris and Prenafeta-Boldú, 2018].

### II.3 Motores de Regras

Um motor de regras opera com base em um conjunto de regras lógicas previamente definidas, que determinam a relação entre os dados de entrada e as ações recomendadas. Em sua essência, um motor de regras aplica princípios de lógica proposicional ou de predicados para inferir novas informações ou acionar operações específicas a partir de fatos conhecidos [Giarratano and Riley, 2005; Russell and Norvig, 2009].

O funcionamento básico de um motor de regras envolve dois principais mecanismos de inferência: o encadeamento para frente (*forward chaining*) e o encadeamento para trás (*backward chaining*). No encadeamento para frente, as regras são avaliadas sequencialmente a partir dos fatos disponíveis, permitindo que novas conclusões sejam geradas até que se alcance um estado final. Já no encadeamento para trás, o sistema parte de uma meta predefinida e trabalha de forma retroativa, avaliando quais regras e fatos a sustentam [Giarratano and Riley, 2005; Luger, 2008].

Por exemplo, uma regra pode especificar: *SE o pH do solo for menor que 5,5, ENTÃO recomendar a aplicação de calcário.* Estas regras podem ser formalmente expressas por meio do princípio do *modus ponens*. A robustez do motor de regras também reside em sua capacidade de lidar com a complexidade. Além de regras simples, é possível implementar relações hierárquicas ou condições compostas [Giarratano and Riley, 2005; Russell and Norvig, 2009].

A base matemática de um motor de regras é fundamentada em princípios de lógica formal, incluindo a lógica proposicional e a lógica de predicados. Essas ferramentas permitem que o motor tome decisões com base em um conjunto de regras e fatos conhecidos, derivando novas conclusões ou ações de forma estruturada [Russell and Norvig, 2009].

As regras em um motor de regras são expressas como implicações lógicas na forma:

$$\text{SE (condições) ENTÃO (ações ou conclusões).}$$

Por exemplo:

$$\text{SE (umidade do solo} < 20\%\text{) ENTÃO (irrigar).}$$

Essa estrutura pode ser representada como:

$$\text{Condição} \implies \text{Ação.}$$

Baseando-se no *modus ponens*:

$$\text{Se } A \implies B \text{ e } A \text{ é verdadeiro, então } B \text{ também é verdadeiro.}$$

Cada regra é avaliada por meio de funções que verificam se suas condições são verdadeiras. Por exemplo:

$$f(x_1, x_2, ..., x_n) = \begin{cases} 1, & \text{se as condições forem verdadeiras;} \\ 0, & \text{caso contrário.} \end{cases}$$

Com base nos fatos derivados, o sistema executa ações ou fornece recomendações. No caso de um sistema agrícola, isso pode incluir recomendações de insumos agrícolas, ajustes nos sistemas de irrigação, ações específicas para melhorar a saúde do solo, recomendações de culturas, etc.

Exemplificando o que foi detalhado acima, considere o seguinte conjunto de regras:

$$\textit{SE (umidade do solo} < 20\%\textit{) ENTÃO (irrigar)};$$

$$\textit{SE (pH} < 5.5\textit{) ENTÃO (adicionar calcário).}$$

Com os fatos conhecidos:

$$\textit{umidade} = 15\%;$$

$$\textit{pH} = 5.0.$$

O motor de regras deduziria:

$$\text{A primeira regra é ativada porque } 15\% < 20\%, \text{resultando na ação } \textit{irrigar};$$

A segunda regra também é ativada porque $5.0 < 5.5$, resultando na ação *adicionar calcário*.

Em sistemas com inúmeras regras, é comum que múltiplas regras sejam ativadas simultaneamente, gerando um conflito. A resolução de conflitos é o processo de determinar qual regra será aplicada primeiro, o que pode ser feito por meio de diversas estratégias. Uma delas é a especificidade, que prioriza regras mais específicas em detrimento das mais gerais. Outra é a prioridade atribuída, na qual pesos ou níveis de prioridade são definidos para cada regra. Há também a estratégia de recência, que seleciona regras associadas aos fatos mais recentes. Por fim, existe a ordem fixa, na qual as regras são aplicadas em uma sequência previamente definida. Essas estratégias asseguram que o sistema funcione de maneira consistente e previsível, mesmo diante de cenários complexos [Giarratano and Riley, 2005; Luger, 2008]. A Figura II.5 apresenta o fluxo de um motor de regras.

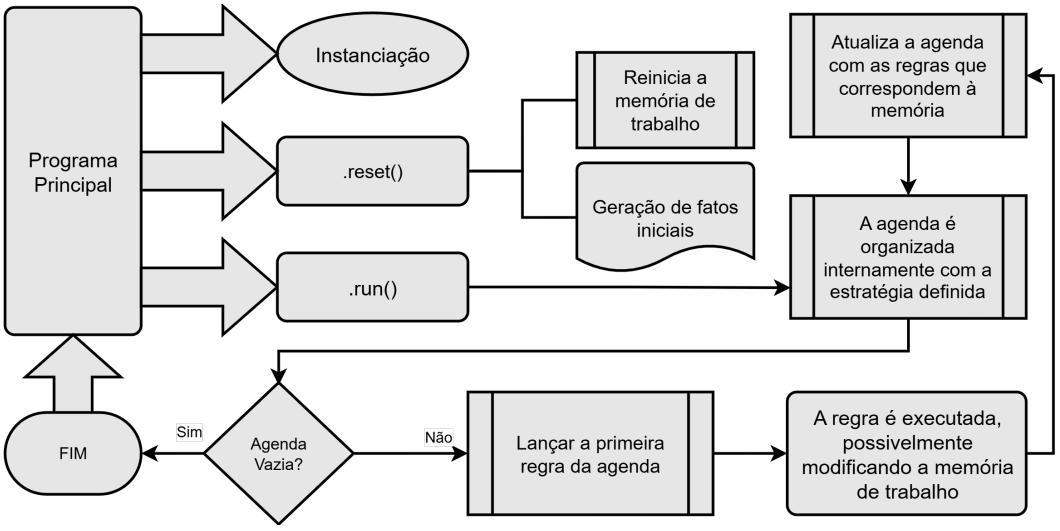



Figura II.5: Fluxo de execução do motor de regras (encadeamento progressivo) utilizado na dissertação. O *Programa Principal* instancia o motor e chama `.reset()` para limpar a memória de trabalho e gerar os fatos iniciais; em seguida, a agenda é atualizada com as regras cujas condições casam com a memória e é ordenada segundo a estratégia de resolução de conflitos definida. Com `.run()`, a primeira regra da agenda é disparada iterativamente, possivelmente modificando a memória de trabalho e reprogramando a agenda; o ciclo se repete até a agenda ficar vazia, quando a execução termina.

Como extensão aos motores de regras mais avançados, podemos incorporar probabilidades (lógica fuzzy) para lidar com incertezas, aprendizado de máquina para ajustar regras com base em dados históricos e regras hierárquicas para lidar com situações complexas em que regras dependem de outras [Zadeh, 1965; Mitchell, 1997].

Este arcabouço matemático torna os motores de regras ferramentas poderosas para sistemas de tomada de decisão. Na próxima seção apresentaremos o CLIPS, ferramenta adotada para a implementação do motor de regras [Giarratano and Riley, 2005].

## II.4 CLIPS como Motor de Regras

No desenvolvimento de sistemas de recomendação, a implementação de um motor de regras é uma abordagem que permite a geração de recomendações baseadas em conhecimento especializado e em regras predefinidas. Uma das ferramentas mais utilizadas para essa finalidade é o CLIPS (*C Language Integrated Production System*), um motor de regras reconhecido por sua eficiência e flexibilidade. Desenvolvido originalmente pela NASA nos anos 1980, o CLIPS continua amplamente utilizado em sistemas que requerem inferência lógica e processamento baseado em regras [Giarratano and Riley, 2005; Riley, 2024; Almulla, 2025].

O CLIPS é especialmente adequado para sistemas de recomendação baseados em regras, devido à sua capacidade de lidar com grandes conjuntos de regras e de realizar inferências complexas de forma eficiente. Sua arquitetura utiliza regras de produção, em que cada regra possui uma condição (if) e uma ação (then). Quando as condições de uma regra são satisfeitas pelos dados fornecidos ao sistema, as ações correspondentes são executadas, resultando em recomendações apropriadas. Essa arquitetura permite que o CLIPS manipule tanto regras simples quanto complexas, facilitando a personalização das recomendações com base em múltiplos fatores e variáveis contextuais [Giarratano and Riley, 2005; Riley, 2006].

Além de robustez e versatilidade, o CLIPS oferece integração com outras linguagens de programação, como C e Python, permitindo a criação de sistemas híbridos que combinam o raciocínio baseado em regras com abordagens complementares, como redes neurais. No contexto desta dissertação, o CLIPS foi utilizado para recomendações baseadas em regras, fornecendo uma base sólida e explicável para as recomendações geradas [Riley, 2006].

Embora o CLIPS seja uma excelente opção para sistemas baseados em regras, há outras alternativas dignas de nota. O Drools, por exemplo, é um motor de regras de código aberto baseado em Java, amplamente empregado em ambientes corporativos devido à sua linguagem de regras sofisticada e à integração nativa com ecossistemas Java [Proctor et al., 2012].

Outra alternativa é o Jess (*Java Expert System Shell*), inspirado diretamente no CLIPS, mas adaptado para a plataforma Java. Jess oferece flexibilidade semelhante à do CLIPS, com a vantagem adicional de ser integrado naturalmente ao ambiente Java, aspecto valorizado em certos contextos de desenvolvimento [Friedman-Hill, 2003].

Adicionalmente, o OpenL Tablets é uma ferramenta que combina motores de regras com interfaces de planilhas eletrônicas, permitindo que regras complexas sejam definidas e geridas por usuários que não possuem domínio em programação tradicional, sendo particularmente útil em cenários que exigem atualizações frequentes das regras por parte de usuários não técnicos [OpenL Tablets, 2024].

Embora cada uma dessas ferramentas apresente vantagens específicas, a escolha pelo CLIPS

neste projeto é justificada por sua maturidade, estabilidade e comprovada capacidade de integração eficaz com outros sistemas [Almulla, 2025]. Essa combinação permite oferecer recomendações altamente personalizadas, transparentes e adaptativas, adequadas às necessidades específicas de agricultores que buscam otimizar suas práticas agrícolas com base em conhecimento especializado [Giarratano and Riley, 2005; Riley, 2006].

Na próxima seção, apresentaremos o Manual de Adubagem e Calagem, desenvolvido em 2013 por um conjunto de pesquisadores, incluindo a Embrapa[4], a UFRRJ[5] e a Pesagro[6], que serviu de base para a construção das regras utilizadas pelo CLIPS.

## II.5 Manual de Adubagem e Calagem da Embrapa

A produtividade agrícola é influenciada por diversos fatores que interagem de maneira dinâmica, como características das plantas, condições do solo, clima e práticas de manejo [Sharma et al., 2012]. Esses elementos, interdependentes, determinam a capacidade de um sistema agrícola de alcançar elevados níveis de produção e, ao mesmo tempo, garantir a sustentabilidade ambiental. A produtividade máxima que uma planta pode atingir é controlada geneticamente, mas sua realização depende do equilíbrio entre fatores externos, como a disponibilidade de nutrientes, a eficiência na fotossíntese, as condições meteorológicas e a adoção de técnicas agrícolas adequadas.

O solo, enquanto base física e fonte de recursos para as plantas, desempenha um papel essencial. Sua fertilidade, ou seja, a capacidade de fornecer nutrientes na quantidade e no momento adequados, é determinante, mas não é o único aspecto que interfere na produção [Khalil et al., 2015]. Características físicas do solo, como sua estrutura e profundidade, também influenciam diretamente o crescimento radicular, afetando a absorção de água e de nutrientes. Intervenções, como o uso de corretivos, podem melhorar as condições do solo e aumentar a eficiência das culturas, especialmente em períodos de escassez hídrica.

O clima, por sua vez, afeta diretamente o desenvolvimento vegetal, com elementos como radiação solar, precipitação e temperatura desempenhando papéis centrais. Para um planejamento agrícola eficaz, é indispensável compreender as condições climáticas locais e regionais, considerando não apenas as médias anuais, mas também as variações sazonais e anuais que podem impactar o desempenho das culturas [Hansen, 2005]. A elaboração de estratégias baseadas em balanços hídricos e na seleção de espécies adaptadas ao clima são medidas essenciais para mitigar riscos e otimizar resultados.

O manejo agrícola é a ferramenta pela qual o ser humano ajusta as condições naturais às necessidades das plantas, utilizando práticas que vão desde o preparo do solo e a escolha da época de

[4]Empresa Brasileira de Pesquisa Agropecuária
[5]Universidade Federal Rural do Rio de Janeiro
[6]Empresa de Pesquisa Agropecuária do Estado do Rio de Janeiro

plantio até a aplicação de insumos, como adubos e corretivos [Shah and Wu, 2019]. No entanto, a eficiência dessas práticas depende de um diagnóstico preciso das condições locais e da adoção de métodos que minimizem perdas e impactos ambientais. Por exemplo, erros na aplicação de irrigação podem causar lixiviação de nutrientes, desperdício de recursos e contaminação ambiental.

A integração de todos esses fatores é fundamental para maximizar a produção e, ao mesmo tempo, preservar os recursos naturais. Estratégias agrícolas bem planejadas devem considerar tanto o potencial produtivo das plantas quanto as limitações impostas pelas condições climáticas, do solo e pelo manejo, priorizando intervenções que promovam um equilíbrio sustentável entre produção e conservação ambiental.

O Manual de Calagem e Adubação do Estado do Rio de Janeiro[7] é uma referência técnica essencial para profissionais da área agrícola, reunindo recomendações para a correção e fertilização dos solos no estado. Publicado pela Embrapa Solos, em parceria com outras instituições de pesquisa e extensão rural, o manual busca fornecer informações fundamentadas para a tomada de decisões sobre o manejo do solo e a nutrição de plantas, com foco na realidade agrícola fluminense. Sua estrutura abrange desde conceitos básicos sobre a fertilidade do solo até recomendações específicas para diferentes culturas, tornando-se um instrumento prático tanto para pesquisadores quanto para técnicos e produtores rurais.

A obra destaca-se pela abordagem detalhada dos fatores que influenciam a produtividade vegetal, incluindo características do solo, do clima e do manejo agrícola. A revisão das principais classes de solos do estado, com base no Sistema Brasileiro de Classificação de Solos (SiBCS), permite um entendimento preciso das limitações e potencialidades das diferentes regiões agrícolas. Além disso, o manual apresenta diretrizes para a análise química do solo, o uso de corretivos e fertilizantes, o manejo da matéria orgânica e aplicações específicas para a agricultura orgânica e para cultivos protegidos. Essas informações são complementadas por recomendações de adubação para diversas culturas, abrangendo desde grandes culturas até espécies frutíferas, hortaliças e forrageiras.

Entre os pontos positivos, destaca-se a riqueza de informações técnicas, fundamentadas em estudos científicos e na experiência de especialistas da área. O manual não apenas apresenta recomendações genéricas, mas também adapta suas diretrizes às condições edafoclimáticas do estado, considerando aspectos como a acidez do solo, a disponibilidade de nutrientes e as exigências específicas das culturas. Outro aspecto relevante é a preocupação com a sustentabilidade, evidenciada na ênfase dada ao manejo da matéria orgânica, ao uso de insumos biológicos e à conservação do solo, o que incentiva práticas que minimizem impactos ambientais.

Por outro lado, alguns pontos negativos podem ser apontados. Apesar da profundidade técnica, a linguagem do manual pode ser um desafio para produtores com menor nível de escolaridade ou

[7] https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/963089

experiência na interpretação de análises de solo. Além disso, embora as recomendações sejam baseadas em dados regionais, a rápida evolução da pesquisa agrícola e a introdução de novas tecnologias podem exigir atualizações mais frequentes para garantir que as orientações permaneçam alinhadas aos avanços científicos e às mudanças nas condições ambientais.

De maneira geral, o Manual de Calagem e Adubação do Estado do Rio de Janeiro destaca-se como uma ferramenta importante para a otimização do manejo do solo e da adubação no estado. Seu caráter técnico e embasamento científico conferem credibilidade às informações apresentadas, enquanto sua estrutura abrangente permite que seja utilizado tanto para consulta rápida quanto para aprofundamento teórico. Apesar de algumas limitações, sua contribuição para o planejamento agrícola sustentável na região é inegável, ao fornecer diretrizes que auxiliam na melhoria da produtividade e na conservação dos recursos naturais.

No próximo capítulo, apresentaremos uma revisão da literatura existente, baseada em um mapeamento sistemático [Grant and Booth, 2009], com foco em sistemas de recomendação para a agricultura. O objetivo é identificar e analisar os estudos disponíveis sobre o tema.

# Capítulo III Trabalhos Relacionados

Este capítulo sintetiza a literatura relevante por meio de uma estratégia em duas etapas: (i) um *mapeamento do núcleo agrícola*, voltado a sistemas de recomendação aplicados à agricultura; e (ii) uma *busca complementar* especificamente orientada a sistemas especialistas *rule-based* implementados com *CLIPS*, independentemente do domínio, para fundamentar decisões de engenharia de conhecimento. A Etapa 1 utiliza consulta ampla na *Scopus* para identificar pesquisas alinhadas à recomendação agronômica (culturas, manejo, nutrientes, clima/solo), enquanto a Etapa 2 incorpora evidências metodológicas sobre o desenho, a validação e a manutenção de bases de conhecimento em CLIPS. Ao final, retemos um conjunto enxuto de trabalhos com suficiente detalhamento técnico, representatividade recente e transferibilidade para a arquitetura proposta nesta dissertação.

## III.1 Núcleo Agrícola

Aplicou-se a seguinte *string* de busca na *Scopus*: `TITLE-ABS-KEY(“recommendation system” AND “agriculture”) AND PUBYEAR > 2002 AND PUBYEAR < 2026`. A consulta retornou 426 documentos. Após triagem por título e resumo, permaneceram 126 estudos diretamente relacionados à recomendação em agricultura, considerando a aderência ao problema agronômico, a comparação de métodos e o potencial de contribuição ao sistema proposto. Mais de 90% dos estudos selecionados foram publicados entre 2018 e 2025, evidenciando a atualidade do tema. A Tabela III.1 resume a produção anual, e a Figura III.1 apresenta a distribuição dos totais e dos selecionados.

Tabela III.1: Quantidade de artigos por ano de publicação da pesquisa sistemática na base *Scopus*.

| **Ano da publicação** | **Documentos totais** | **Documentos filtrados** |
|---|---|---|
| 2004 | 4 | 1 |
| 2006 | 2 | 0 |
| 2007 | 2 | 1 |
| 2009 | 4 | 2 |
| 2011 | 3 | 2 |
| 2013 | 2 | 1 |
| 2014 | 3 | 0 |
| 2015 | 2 | 1 |
| 2016 | 4 | 0 |
| 2017 | 3 | 2 |
| 2018 | 9 | 3 |
| 2019 | 11 | 4 |
| 2020 | 21 | 9 |
| 2021 | 33 | 15 |
| 2022 | 67 | 26 |
| 2023 | 102 | 38 |
| 2024 | 145 | 19 |
| 2025 | 9 | 2 |

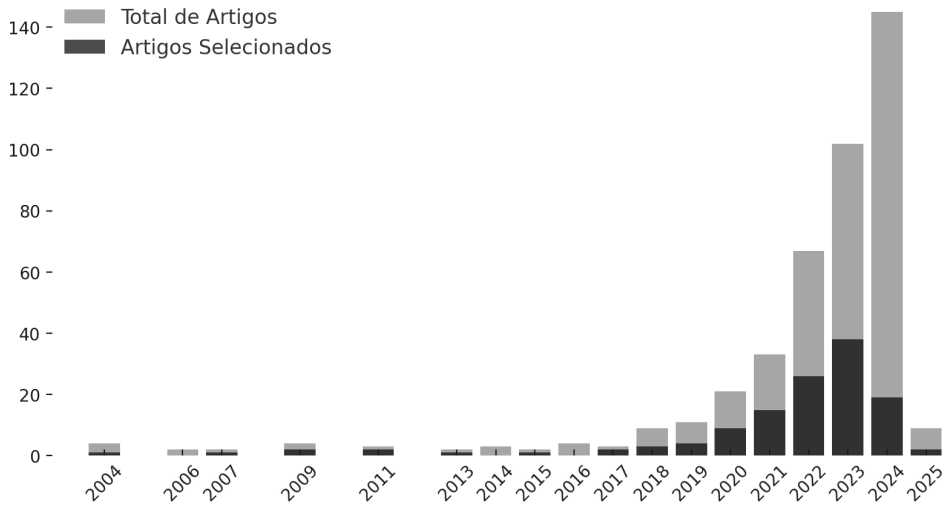



Figura III.1: Distribuição dos artigos totais e selecionados.

No entanto, mesmo entre os 126 artigos inicialmente selecionados, observou-se grande heterogeneidade quanto aos objetivos, às metodologias e aos domínios de aplicação. Muitos estudos, embora relacionados a sistemas de recomendação, possuíam foco restrito em áreas adjacentes, como comércio eletrônico, saúde ou automação, não oferecendo contribuições diretas para o problema de recomendação agrícola tratado nesta dissertação. Outros apresentavam um escopo excessivamente geral ou superficial, sem detalhamento técnico suficiente para fundamentar a metodologia aqui proposta. A Figura III.2 apresenta o fluxo PRISMA utilizado, e a Tabela III.2 apresenta os critérios de elegibilidade dos artigos.

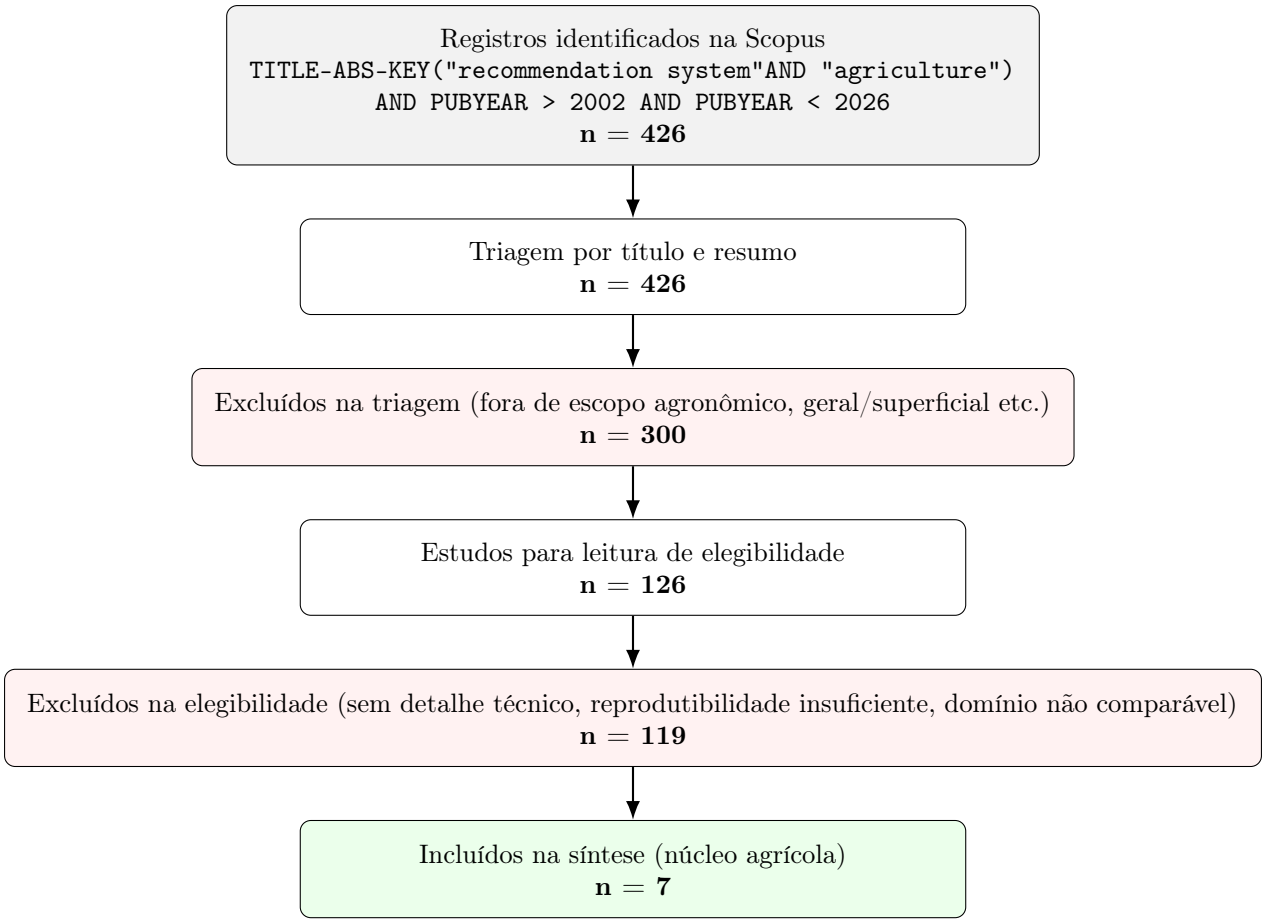



Figura III.2: Fluxo PRISMA — Núcleo Agrícola: seleção a partir de 426 registros, resultando em 7 incluídos.

Tabela III.2: Critérios de inclusão e exclusão aplicados na triagem e elegibilidade.

| **Inclusão** | **Exclusão** |
|---|---|
| Foco em sistemas de recomendação **aplicados à agricultura** (culturas, manejo, nutrientes, clima/solo). | Estudos de *e-commerce*, domínios clínicos ou automação sem transferência clara ao problema agronômico (exceto CLIPS como evidência metodológica). |
| Uso de **sistemas baseados em regras**, **lógica fuzzy** ou **modelos híbridos** (regras + ML). | Falta de **detalhamento técnico** (regras, fatos, mecanismo de inferência, variáveis), impedindo reprodutibilidade. |
| **Detalhamento** suficiente para replicação (variáveis de entrada/saída, base de conhecimento, fluxo de inferência, métricas). | Escopo excessivamente geral/superficial, revisões sem método, *position papers* sem implementação. |
| Contexto agrícola ou domínios **comparáveis em complexidade/ incerteza**. | Dependência de dados/protocolos inacessíveis ou sem descrição de disponibilidade. |
| Publicados entre **2003–2025**; idiomas EN/PT. | Duplicatas; versões preliminares sem conteúdo adicional relevante. |

Dessa forma, foi necessária uma filtragem adicional, que reduziu o conjunto a apenas 7 artigos centrais. Essa redução teve como critérios: (i) a proximidade metodológica com a abordagem desta pesquisa, em especial o uso de sistemas baseados em regras, lógica fuzzy ou modelos híbridos;

(ii) a aplicação em contextos agrícolas ou em domínios comparáveis em termos de complexidade e incerteza; e (iii) o detalhamento técnico que permitisse a reprodutibilidade, com contribuições efetivas para o desenho e implementação do sistema proposto. Estes artigos serão apresentados nos próximos parágrafos deste capítulo.

O trabalho de Pudumalar et al. [2017] propõe um sistema de recomendação de culturas para a agricultura digital utilizando um modelo de ensemble com a técnica de votação majoritária, combinando os algoritmos Random Tree, CHAID, K-Nearest Neighbor e Naïve Bayes. A relevância desse estudo para esta dissertação reside na similaridade de abordagem, pois também busca otimizar a recomendação de culturas com base em parâmetros específicos do solo. A principal vantagem do método apresentado no artigo é sua capacidade de melhorar a precisão da recomendação ao integrar múltiplos classificadores, reduzindo erros individuais. Além disso, a implementação no RapidMiner demonstra a aplicabilidade do modelo em cenários reais. No entanto, algumas limitações devem ser consideradas: o estudo utiliza um conjunto de dados restrito à região de Madurai, na Índia, o que pode comprometer a generalização do modelo para outras localidades. Além disso, a escolha dos classificadores pode não ser a mais adequada para todos os tipos de solo, pois não há uma análise comparativa extensa com outras técnicas de aprendizado de máquina mais recentes.

Banerjee et al. [2021] propõem um sistema de recomendação de culturas baseado em lógica fuzzy, considerando a incerteza presente nas condições do solo e ambientais, a fim de fornecer recomendações mais adaptáveis às condições reais do campo. A relevância desse estudo para esta dissertação reside no uso da lógica fuzzy como ferramenta para modelar a variabilidade dos atributos do solo, conceito também explorado neste trabalho, por meio de regras extraídas do manual de adubação e calagem da Embrapa-RJ. Um dos principais pontos positivos do sistema apresentado é sua capacidade de lidar com dados imprecisos e subjetivos, o que permite recomendações mais flexíveis. Dessa forma, o estudo serve como referencial importante para a construção do modelo proposto.

Já Raveena and Surendran [2023] apresentam um sistema híbrido de recomendação baseado em regras para fertilizantes em plantações de café, combinando filtragem baseada em conhecimento e filtragem colaborativa. A relevância deste trabalho reside na similaridade metodológica, pois ambos os sistemas utilizam regras especializadas para orientar as recomendações agrícolas. A principal vantagem do modelo híbrido apresentado no artigo é a sua alta precisão (91,95%), o que demonstra que a combinação de múltiplas técnicas pode melhorar a assertividade das recomendações. Por outro lado, sua abordagem limita-se ao cultivo de café e não considera a influência de variáveis climáticas.

Bin et al. [2023] apresentam um sistema de controle de irrigação baseado em lógica fuzzy para o cultivo de algodão, visando à otimização do uso da água e à redução de infestações por pragas,

como a mosca-branca. A relevância deste trabalho para esta dissertação reside na aplicação da lógica fuzzy à tomada de decisão na agricultura, conceito importante para o sistema proposto. Um dos principais pontos positivos do trabalho é a eficiência do modelo na economia de água e energia, reduzindo desperdícios e automatizando processos agrícolas. No entanto, uma limitação do estudo é sua dependência de sensores físicos e de infraestrutura específica, o que pode dificultar sua adoção por pequenos produtores. Além disso, o sistema é voltado para uma única cultura (algodão). Dessa forma, o trabalho serve como referencial importante, destacando o potencial da lógica fuzzy na agricultura digital e reforçando a necessidade de abordagens híbridas para recomendações agrícolas mais robustas e acessíveis.

Outro estudo relevante, o de Madhumathi et al. [2022], propõe um sistema baseado em IoT e em lógica fuzzy para a detecção e recomendação de nutrientes no solo, utilizando sensores colorimétricos para medir os níveis de nitrogênio (N), fósforo (P) e potássio (K) e um sistema especialista fuzzy para determinar a quantidade ideal de fertilizantes a serem aplicados. A relevância desse trabalho para esta dissertação reside na adoção da lógica fuzzy na recomendação agrícola, conceito essencial para modelar a incerteza na nutrição do solo. Um dos principais pontos positivos do modelo é a automação do processo de análise do solo, reduzindo a necessidade de coletas laboratoriais demoradas e permitindo recomendações rápidas e acessíveis aos agricultores por meio de um aplicativo móvel. No entanto, uma limitação do estudo é sua dependência de sensores específicos e de infraestrutura de conectividade, o que pode dificultar a escalabilidade para pequenos produtores em regiões remotas. Além disso, a calibração do sistema está restrita aos macronutrientes NPK, sem considerar outros fatores essenciais, como o pH e os micronutrientes, que também influenciam a fertilidade do solo.

No artigo de Corno et al. [2019], é proposto um sistema híbrido e semântico de recomendação de regras "SE-ENTÃO", projetado para auxiliar usuários finais no desenvolvimento de automações personalizadas sem necessidade de programação. A relevância deste trabalho para esta dissertação reside na abordagem de recomendação baseada em funcionalidade, que pode ser aplicada no contexto agrícola para sugerir práticas de manejo agrícola com base em objetivos específicos, indo além de simples variáveis técnicas. A principal vantagem do modelo é sua capacidade de gerar recomendações mais contextualizadas e adaptáveis às necessidades dos usuários, superando abordagens tradicionais baseadas apenas na popularidade ou na similaridade técnica. No entanto, uma limitação do estudo é sua dependência de dados históricos e de um modelo semântico bem estruturado, o que pode dificultar sua aplicação em domínios com baixa disponibilidade de dados semânticos bem estruturados. Em contrapartida, a presente dissertação propõe um sistema baseado em conhecimento agronômico consolidado, que pode ser mais facilmente adaptado a diferentes realidades produtivas.

Por fim, o trabalho de Narayana and Saxena [2023] apresenta uma aplicação web que utiliza

aprendizado de máquina e redes neurais profundas para recomendar culturas, sugerir fertilizantes e detectar doenças em tomateiros. O uso de CNNs para a análise de imagens de folhas e o ajuste de recomendações com base em dados do solo e do clima oferecem uma valiosa contribuição para a personalização de sistemas de recomendação agrícola, especialmente em diagnósticos de pragas e no manejo de nutrientes.

### III.2 CLIPS em Sistemas Especialistas

Para contemplar dois estudos com uso explícito de *CLIPS*, relevantes aqui como evidência metodológica de engenharia de conhecimento, realizamos busca complementar na *Scopus*: `TITLE-ABS-KEY( ‘‘CLIPS’’ AND ‘‘expert system’’ AND ‘‘rule-based’’) AND PUBYEAR > 2010 AND PUBYEAR < 2026`. A consulta retornou 35 documentos; após aplicação dos critérios de elegibilidade (motor *rule-based/if-then* com inferência compatível com CLIPS; descrição suficiente de regras, fatos e encadeamento; relevância transferível para a arquitetura agrícola), **mantivemos 2 artigos**. O objetivo não é expandir o escopo para o domínio clínico, mas sim aproveitar práticas consolidadas de desenho, verificação e atualização de bases de conhecimento em CLIPS para embasar decisões de engenharia no domínio agrícola. A Figura III.3 apresenta o fluxo PRISMA utilizado.

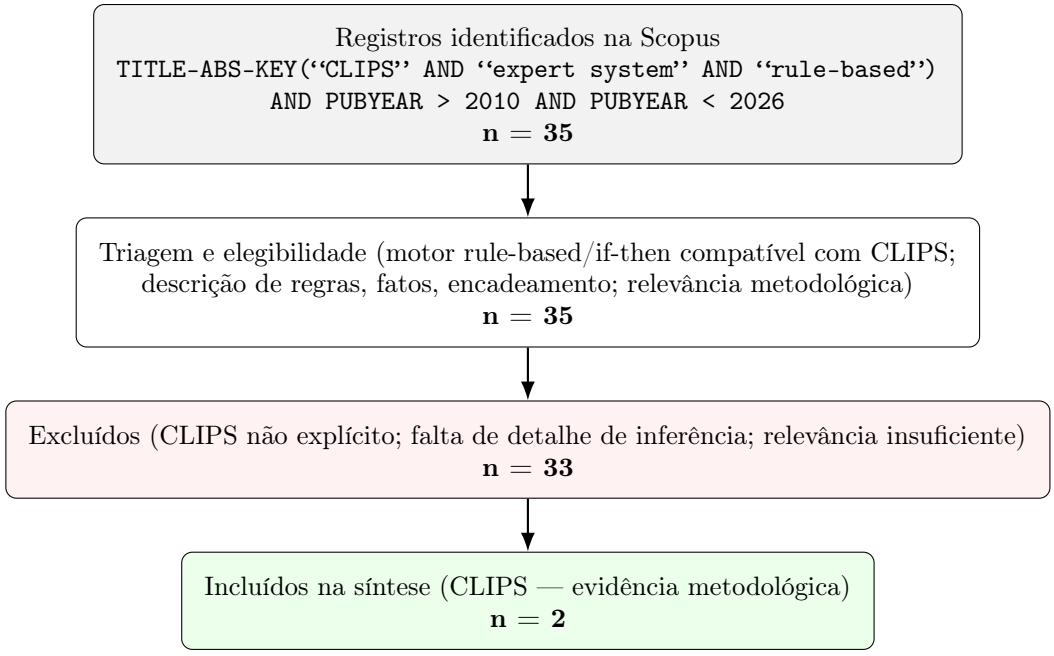



Figura III.3: Fluxo PRISMA — CLIPS: seleção a partir de 35 registros, resultando em 2 incluídos.

O estudo de Almulla [2025] apresenta um sistema especialista para diagnóstico e recomendação de tratamento da enxaqueca, baseado na plataforma CLIPS. A relevância desse trabalho para esta dissertação reside na aplicação de um sistema baseado em regras para a tomada de decisão, abordagem também adotada no presente estudo para recomendações agrícolas. Um dos principais pontos positivos do estudo é a alta precisãoum no diagnóstico, alcançando 100% de acurácia nos testes

após o treinamento, o que demonstra a eficiência dos sistemas especialistas baseados em regras. No entanto, uma limitação do trabalho é a necessidade de atualizações manuais na base de conhecimento para incorporar novas diretrizes médicas, problema semelhante ao enfrentado por sistemas especialistas na agricultura, que precisam ser constantemente ajustados às mudanças climáticas e a novas pesquisas agronômicas. Assim, o estudo reforça a viabilidade de sistemas baseados em regras e serve de referência para a construção de sistemas híbridos mais flexíveis e adaptáveis ao contexto agrícola.

Gebremariam et al. [2024] apresenta um sistema especialista baseado em regras do tipo "SE-ENTÃO" para o diagnóstico de complicações maternas durante a gravidez, com foco em cenários de poucos recursos. A relevância deste trabalho para esta dissertação reside na utilização de um modelo baseado em conhecimento para a tomada de decisão, abordagem semelhante à proposta. Um dos principais pontos positivos do sistema é sua alta taxa de acurácia (94%), demonstrando a eficácia de sistemas especialistas baseados em regras para diagnósticos complexos. No entanto, uma limitação do estudo é a necessidade de atualização manual das regras para incorporar novos conhecimentos médicos, um desafio semelhante ao enfrentado por sistemas agrícolas que dependem de dados agronômicos atualizados.

### III.3 Considerações da Revisão de Literatura

A revisão dos trabalhos relacionados demonstra a crescente aplicação de sistemas baseados em regras e em lógica fuzzy em diversos domínios, incluindo saúde, automação e agricultura. Observou-se que abordagens híbridas, que combinam regras especializadas com técnicas de aprendizado de máquina e integração de dados em tempo real, apresentam vantagens significativas na adaptação a cenários dinâmicos e na melhoria da precisão das recomendações. No contexto agrícola, estudos anteriores reforçam a viabilidade do uso de sistemas especialistas para recomendações agronômicas, mas também evidenciam desafios, como a necessidade de atualizações constantes das regras e a dependência de dados externos, como as informações meteorológicas. Com base nesses fundamentos, o próximo capítulo apresenta a metodologia adotada para o desenvolvimento do sistema proposto, detalhando a estrutura da base de conhecimento, a modelagem das regras extraídas do Manual de Adubação e Calagem da Embrapa, a implementação do motor de inferência e a integração de dados meteorológicos e de produtividade rural, a fim de aprimorar as recomendações agrícolas.

# Capítulo IV Metodologia

Este capítulo descreve os procedimentos metodológicos adotados para o desenvolvimento do sistema de recomendação agrícola inteligente proposto nesta dissertação. O sistema visa auxiliar pequenos produtores rurais na escolha de culturas, no manejo de solo e na tomada de decisões relacionadas à adubação, calagem e aplicação de nitrogênio, com base em dados edafoclimáticos e produtivos regionais [EMBRAPA Solos, 2013; EMATER-Rio, 2024; EMBRAPA Solos, 2024; Instituto Nacional de Meteorologia (INMET), 2025].

A metodologia adotada combina uma abordagem híbrida, integrando um sistema baseado em regras, por meio de um motor de inferência, com dados históricos e ambientais provenientes de fontes confiáveis. Essa integração permite que o sistema ofereça recomendações técnicas personalizadas, considerando tanto o conhecimento técnico consolidado quanto a realidade produtiva local. Sistemas especialistas baseados em regras são amplamente utilizados em contextos em que o conhecimento técnico pode ser formalizado em declarações lógicas, permitindo a realização de inferências automáticas a partir de fatos conhecidos [Giarratano and Riley, 2005].

Como inovação metodológica, este trabalho incorpora, além dos dados históricos de clima, solo e produtividade, uma camada de predição climática de curto prazo. Para isso, foi utilizada a API ClimAPI, desenvolvida pela Embrapa Agricultura Digital, que fornece previsões meteorológicas dos próximos dez dias com resolução espacial baseada nas coordenadas geográficas (latitude e longitude) do município de interesse. Essa previsão inclui variáveis climáticas fundamentais, como temperatura máxima e mínima, precipitação acumulada e pressão atmosférica, que são automaticamente recuperadas e processadas pelo sistema durante a geração das recomendações. A incorporação da predição climática permite que o sistema ajuste suas recomendações considerando não apenas as condições edafoclimáticas históricas, mas também os cenários climáticos imediatos, oferecendo ao produtor uma orientação mais aderente às condições atuais e, portanto, mais precisa e operacionalmente útil.

Ao longo deste capítulo, serão apresentadas as etapas de coleta e tratamento dos dados, a modelagem das regras de inferência, o processo de integração entre dados e regras, a implementação do motor de inferência e o mecanismo de geração das recomendações. Também será descrita a estratégia de validação adotada para verificar a consistência e a aplicabilidade prática do sistema, bem como as ferramentas tecnológicas utilizadas durante o desenvolvimento.

## IV.1 Visão Geral da Metodologia

O desenvolvimento do sistema de recomendação agrícola adotou uma abordagem híbrida, combinando (i) conhecimento agronômico codificado em regras (Manual de Adubação e Calagem/Embrapa, implementado em CLIPS/PyKnow), (ii) um componente baseado em conteúdo (similaridade entre perfil de solo/clima e produtividade histórica) e (iii) inferência por redes neurais, consumida como serviço externo por meio de APIs da Embrapa.

A Figura IV.1 apresenta a arquitetura geral do sistema de recomendação híbrido proposto, destacando os principais componentes responsáveis pela geração e integração das recomendações. Nesse arranjo, o bloco denominado "Modelo Baseado em Redes Neurais" corresponde a um serviço externo consumido por meio de uma API da Embrapa, que disponibiliza previsões meteorológicas de 10 dias (precipitação, temperatura mínima e máxima, entre outras variáveis) geradas pelo Global Forecast System (GFS) da National Oceanic and Atmospheric Administration (NOAA)[1]. Neste trabalho, tais previsões são apresentadas diretamente como séries temporais para o município selecionado, sem qualquer transformação, agregação ou cálculo de indicadores derivados. A função desse componente é informativa e contextual, oferecendo ao usuário a visualização da janela meteorológica prevista que pode orientar o momento de executar práticas recomendadas (plantio, adubação, etc.). Em caso de indisponibilidade da API, o sistema apenas omite essa visualização, mantendo a reprodutibilidade dos demais módulos.

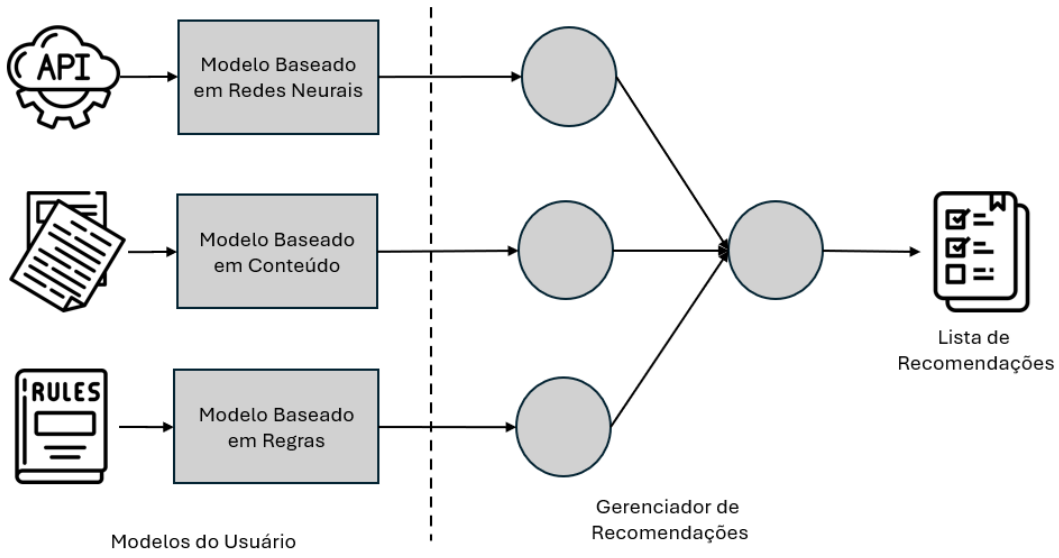



Figura IV.1: Arquitetura híbrida de recomendação. A partir dos *Modelos do Usuário* — (i) baseados em redes neurais (API), (ii) baseados em conteúdo e (iii) baseados em regras — são gerados candidatos. O *Gerenciador de Recomendações* integra essas saídas, aplicando restrições de domínio; o resultado é a *lista de recomendações* final, ordenada.

A opção pelo uso de um sistema baseado em regras, implementado pelo motor de inferência

[1] https://www.ncei.noaa.gov/products/weather-climate-models/global-forecast

CLIPS [Gary Riley, 2024] e integrado à linguagem Python por meio da biblioteca PyKnow [Werneck, 2018], justifica-se pela necessidade de representar o conhecimento técnico agronômico de forma explícita, interpretável e transparente. Essa característica é particularmente relevante no contexto de assistência a pequenos produtores rurais, que demandam recomendações claras, fundamentadas e alinhadas às práticas consolidadas no campo.

A metodologia foi estruturada em cinco etapas principais: (i) coleta e pré-processamento dos dados, reunindo informações de solo, clima e produtividade de diferentes fontes institucionais; (ii) modelagem do conhecimento agronômico, com base no manual de calagem e adubação da Embrapa-RJ (2013) e API AgroFit[2] da Embrapa, de onde foram extraídas as regras formais que compõem a base de conhecimento do sistema; (iii) integração entre dados e regras, permitindo que o sistema considerasse características regionais para personalizar as recomendações; (iv) implementação do motor de inferência; e (v) validação e testes, nos quais o sistema foi aplicado a diferentes cenários para verificar a coerência e aplicabilidade das recomendações geradas. A Figura IV.2 apresenta as etapas metodológicas propostas neste trabalho.

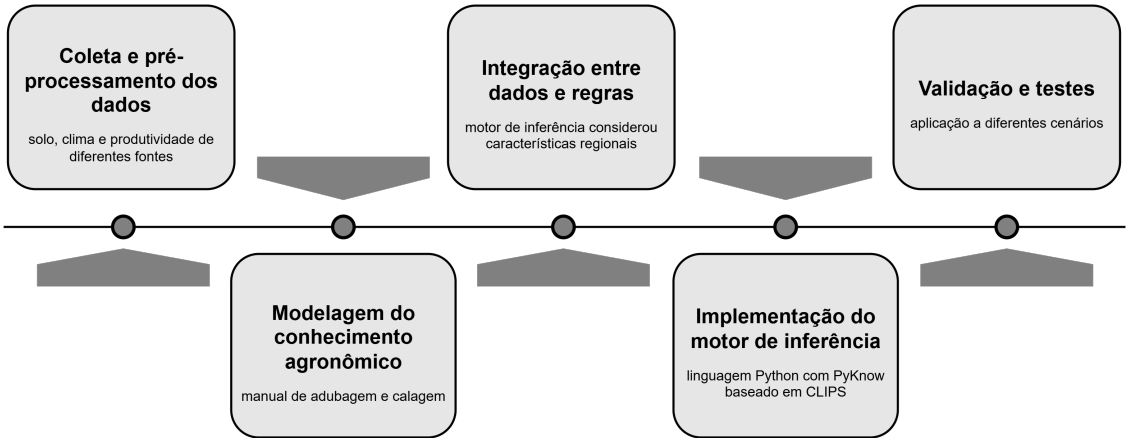



Figura IV.2: Metodologia em cinco etapas: (i) coleta e pré-processamento de dados (solo, clima e produtividade); (ii) modelagem do conhecimento agronômico a partir do Manual de Adubação e Calagem da Embrapa-RJ e da API Agrofit; (iii) integração entre dados e regras com parametrização regional; (iv) implementação do motor de inferência em Python (PyKnow/CLIPS); e (v) validação e testes em múltiplos cenários.

Essa abordagem busca equilibrar o conhecimento técnico consolidado com dados atualizados e contextualizados, permitindo ao sistema responder com precisão às variabilidades edafoclimáticas e às práticas produtivas regionais. A seguir, cada etapa é detalhada, com ênfase nos métodos empregados e nas decisões técnicas que fundamentaram o projeto.

A Figura IV.3 ilustra, de forma esquemática, o funcionamento geral do sistema de recomendação agrícola desenvolvido. O fluxograma representa o fluxo de decisões e de dados que compõe a lógica do sistema, desde a inserção da cidade pelo usuário até a geração das recomendações finais. O

[2]https://www.embrapa.br/busca-de-solucoes-tecnologicas/-/produto-servico/11779/api-agrofit

diagrama destaca os caminhos possíveis, de acordo com a presença ou ausência de dados de solo. Na ausência dessa informação, o sistema utiliza perfis de solo do BDSolos [EMBRAPA Solos, 2024] como referência e fornece recomendações baseadas na produtividade regional e em informações climáticas gerais. Quando o usuário fornece uma análise local, os dados são integrados ao motor de inferência para gerar uma recomendação mais precisa. O fluxograma sintetiza os principais módulos e suas interações, refletindo a metodologia híbrida adotada, que combina conhecimento técnico com dados regionais, e orienta o leitor quanto à estrutura lógica.

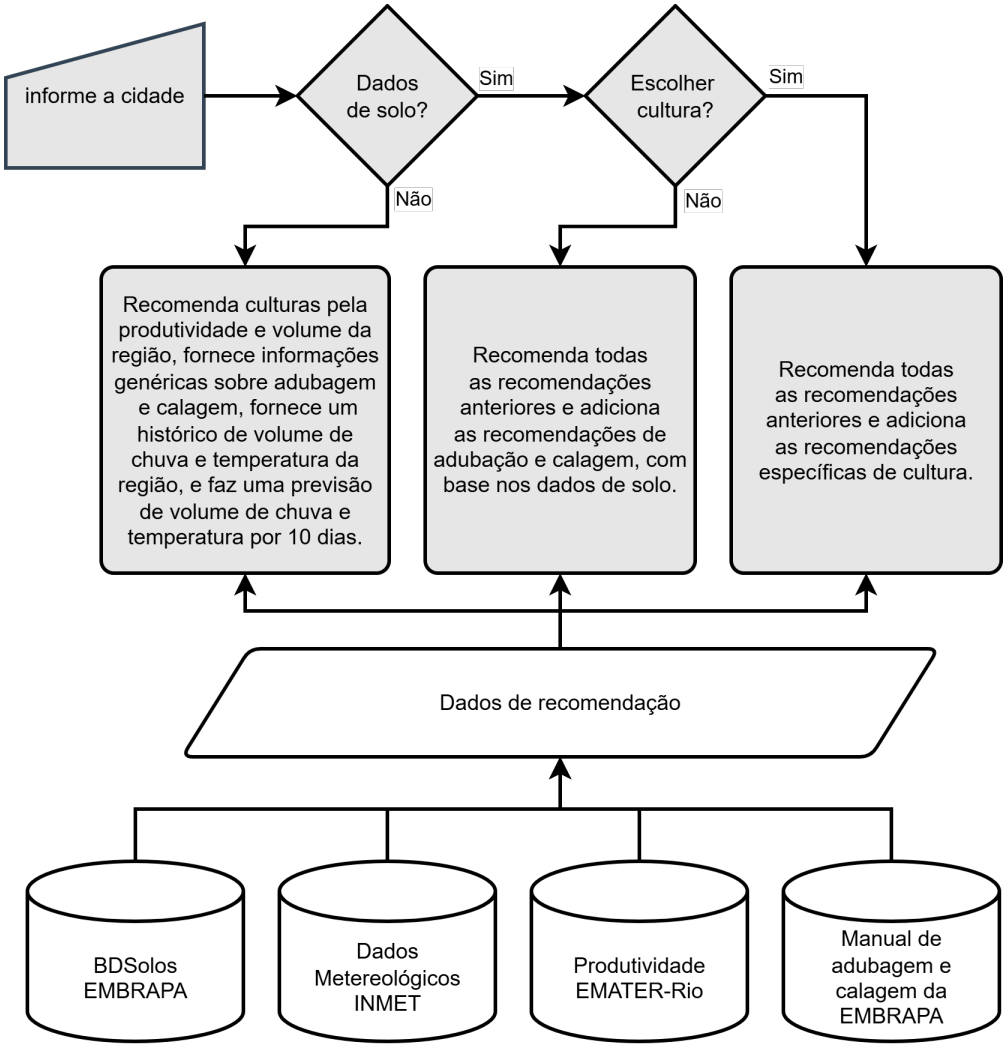



Figura IV.3: Fluxo de decisão do sistema de recomendação agrícola proposto. A partir de BDSolos/EMBRAPA, dos dados meteorológicos do INMET, da produtividade da EMATER-Rio e do Manual de Adubação e Calagem, o sistema elabora uma camada de dados de recomendação. O usuário informa a cidade e, conforme a disponibilidade de dados de solo e (opcionalmente) a escolha de uma cultura, o sistema: (i) sem dados de solo, recomenda culturas pela produtividade regional e fornece orientações genéricas de adubação/calagem e panorama climático; (ii) com dados de solo, combina análise de solo e clima (chuva, temperatura e umidade) para indicar as culturas economicamente mais promissoras e orientações de manejo; (iii) quando há seleção de cultura, as recomendações priorizam essa cultura.

## IV.2 Coleta e Pré-processamento dos Dados

A primeira etapa metodológica consistiu na coleta e no pré-processamento das bases de dados que alimentam o sistema de recomendação. Foram integradas quatro fontes principais de dados: (i) dados meteorológicos do INMET [Instituto Nacional de Meteorologia (INMET), 2025], (ii) dados de produtividade agrícola da EMATER-Rio [EMATER-Rio, 2024], (iii) dados de solo do banco BDSolos da Embrapa [EMBRAPA Solos, 2024], (iv) dados sobre produtos contra pragas e suas aplicações, disponibilizado pela plataforma de APIs da Embrapa, chamada AgroFIT, (v) e o manual de calagem e adubação da Embrapa-RJ (2013) [EMBRAPA Solos, 2013], utilizado como base de conhecimento agronômico.

A Figura IV.4 apresenta uma representação esquemática da etapa de coleta e pré-processamento dos dados utilizados pelo sistema de recomendação. O diagrama sintetiza o fluxo de entrada das quatro principais fontes de informação e serve de base para a definição das regras de recomendação. Cada uma dessas fontes alimenta o sistema com informações específicas que passam por procedimentos de padronização, validação e integração. A imagem destaca a transformação dos dados brutos em um repositório computacional unificado, que serve de base para o raciocínio automatizado do sistema.

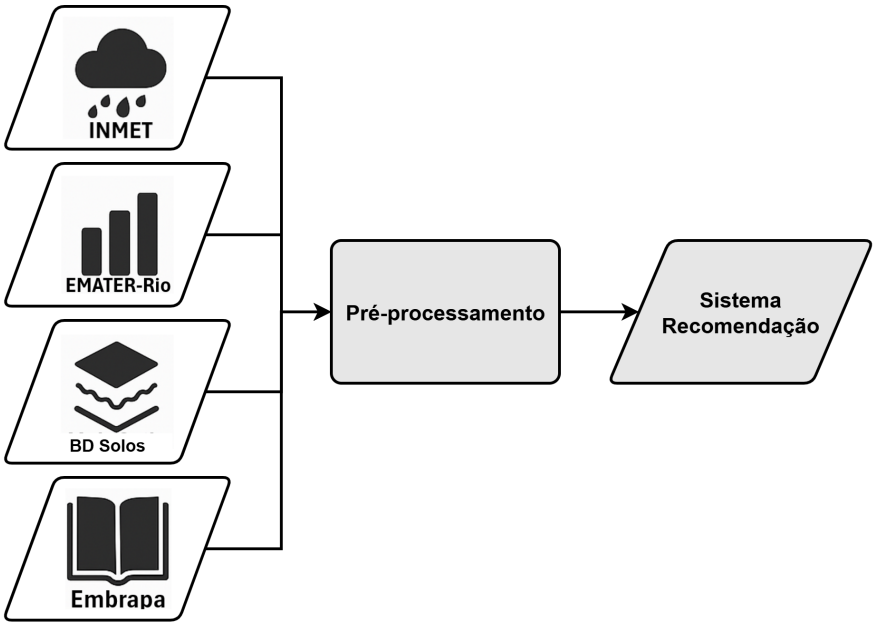



Figura IV.4: Coleta e Pré-processamento. Dados do INMET (clima), EMATER-Rio (produtividade), Embrapa BDSolos (solos) e Manual de Adubagem e Calagem da Embrapa (conhecimento agronômico) são padronizados, validados e integrados em um repositório único, que alimenta o sistema de recomendação.

Durante a coleta, priorizou-se a obtenção de dados atualizados, abrangendo as culturas e as regiões do estado do Rio de Janeiro. No caso dos dados meteorológicos, foram selecionadas as estações automáticas do INMET distribuídas pelo estado do RJ, cujos registros diários incluíam

variáveis como temperatura, umidade relativa, precipitação, pressão atmosférica e velocidade do vento. Esses dados foram submetidos a procedimentos de limpeza visando à remoção de registros nulos, inconsistentes ou fora de faixa. As falhas identificadas corresponderam a uma pequena fração do conjunto total de observações, tipicamente inferior a 3% dos registros por estação, e estiveram associadas principalmente a janelas curtas de indisponibilidade de sensores automáticos, decorrentes de interrupções temporárias na coleta. Considerando o reduzido volume de dados ausentes, sua natureza pontual e o fato de que as informações meteorológicas são utilizadas neste trabalho de forma contextual e descritiva, optou-se pela exclusão desses registros, sem a aplicação de técnicas de imputação. Após esse tratamento, os dados foram consolidados em uma base unificada, representativa do perfil climático médio de cada região analisada.

Os dados da EMATER-Rio, provenientes do projeto ASPA (Acompanhamento Sistemático da Produtividade Agrícola)[3], abrangiam as safras de 2021, 2022 e 2023. Esses dados fornecem informações por município, como o tipo de cultura cultivada, a produtividade (t/ha), as toneladas colhidas, o preço de mercado e o faturamento bruto. Durante o pré-processamento, foram realizadas tarefas de padronização dos nomes das culturas e das localidades, além da organização dos registros em uma estrutura temporal e geográfica que facilitasse o cruzamento com os dados climáticos e de solo.

O banco de dados do BDSolos da Embrapa [EMBRAPA Solos, 2024] foi utilizado para fornecer perfis representativos de solo nas regiões analisadas. Quando o usuário não disponibilizava uma análise de solo local, o sistema recorria ao BDSolos para preencher essa lacuna, permitindo inferir a aptidão agrícola da área com base nos perfis de solo mais próximos geograficamente. Foram considerados atributos físicos, químicos e morfológicos previamente tratados e padronizados, o tratamento dos dados será detalhado na seção V.2 .

Por fim, todas as bases de dados estruturadas foram integradas em um ambiente computacional unificado em memória, no qual as informações meteorológicas, produtivas e de solo foram organizadas em estruturas de dados otimizadas para acesso eficiente durante o processo de inferência. Esse arranjo privilegia o desempenho do sistema, evitando acessos persistentes a banco de dados e permitindo a avaliação rápida dos cenários de recomendação a partir dos dados já carregados e validados. Paralelamente, o *Manual de Adubação e Calagem* foi submetido a um pré-processamento conceitual, no qual suas recomendações textuais foram analisadas, sistematizadas e traduzidas em estruturas formais de conhecimento, contemplando classes de fertilidade, faixas de pH, níveis críticos de nutrientes, condições de aplicação e exceções técnicas. Esse tratamento inicial visa garantir a coerência semântica entre os dados e o conhecimento agronômico formalizado, além de estabelecer a base lógica para a etapa subsequente de modelagem das regras de recomendação.

[3] `https://www.rj.gov.br/emater/node/187`

### IV.3 Modelagem das Regras de Recomendação

A modelagem das regras de recomendação baseou-se no conteúdo técnico do Manual de Calagem e Adubação para o Estado do Rio de Janeiro, publicado pela Embrapa em 2013 [EMBRAPA Solos, 2013]. Esse manual apresenta diretrizes objetivas para o manejo da fertilidade do solo em função das características químicas do solo e das exigências nutricionais das culturas. A partir dele, foram extraídas regras formais referentes à necessidade de calagem, adubação fosfatada, potássica, nitrogenada e aplicação de micronutrientes.

Em vez de codificar diretamente essas regras no motor de inferência, optou-se por armazená-las em arquivos JSON estruturados, o qual chamamos de "base de conhecimento". Essa abordagem permite que o sistema mantenha uma separação clara entre o motor de inferência e a base de conhecimento, facilitando futuras atualizações, customizações regionais e manutenção do sistema. Cada regra no JSON contém: os critérios de ativação (como limites de pH, teor de fósforo, etc.), a recomendação associada e os metadados adicionais.

A estrutura modular em JSON também permite que técnicos ou especialistas atualizem ou insiram novas regras de forma simples, sem necessidade de reprogramar o núcleo do sistema. Isso torna o sistema mais flexível e adaptável a diferentes contextos produtivos, inclusive com potencial de expansão para outros estados ou condições edafoclimáticas.

A Figura IV.5 apresenta a estrutura modular adotada para a modelagem das regras de recomendação. O diagrama destaca a separação entre a base de conhecimento e o motor de inferência, permitindo que as regras sejam atualizadas ou expandidas sem alterar o código do sistema.

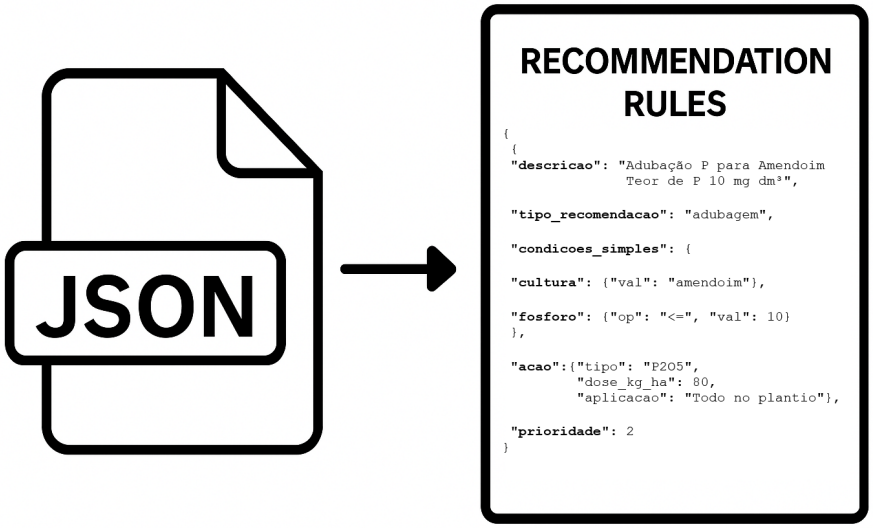



Figura IV.5: Modelagem das regras em formato JSON.

Na etapa de inferência, o sistema carrega dinamicamente o conjunto de regras do arquivo JSON e avalia cada uma delas com base nos dados de entrada do usuário (como análise do solo, do clima

e do histórico de produtividade). Quando os critérios definidos em uma regra são atendidos, a recomendação correspondente é registrada como válida para aquele cenário.

Embora o sistema utilize diversas fontes de dados, como produtividade agrícola, características climáticas e análise do solo, a integração direta desses dados ao conjunto de regras de recomendação não foi realizada na presente versão. Em vez disso, o sistema foi estruturado para apresentar esses dados como contexto informativo no início do relatório gerado para o produtor.

### IV.4 Integração entre Dados e Regras

O sistema consulta diferentes fontes: produtividade agrícola, clima e análise de solo. Porém, nesta versão, esses dados não entram diretamente no motor de inferência. Eles são apresentados como contexto nas seções iniciais do relatório de recomendações gerado pelo sistema.

O fluxo é o seguinte: a partir da cidade informada pelo usuário, o sistema recupera (i) um resumo estatístico da produtividade local de anos anteriores (projeto ASPA), (ii) a caracterização climática da região com base em séries históricas do INMET (temperatura média, precipitação acumulada e umidade relativa) e (iii) a previsão climática, baseado na latitude e longitude do município informado, geradas pela API da Embrapa. Os blocos de produtividade regional e clima oferecem ao produtor uma visão do ambiente produtivo onde sua propriedade está inserida, conforme pode ser verificado na figura IV.6.

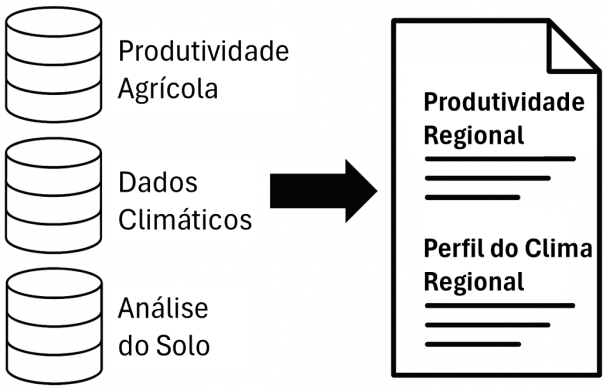



Figura IV.6: Integração entre Dados e Regras.

As recomendações técnicas são, então, geradas com base na análise do solo e nas regras codificadas no sistema. Ou seja, os dados de produtividade e de clima servem de referência contextual ao leitor, mas não alteram as regras de decisão nesta entrega.

Essa separação entre contexto e inferência facilita a escalabilidade: em versões futuras, os dados de produtividade e de clima poderão ser incorporados ao processo decisório do motor (por exemplo, como variáveis de entrada, limiares ou ajustes de recomendação), mantendo o desenho modular.

### IV.5 Implementação do Motor de Inferência

O motor de inferência do sistema foi implementado com a biblioteca PyKnow [Werneck, 2018], uma ferramenta desenvolvida em Python e fortemente inspirada no clássico sistema CLIPS [Gary Riley, 2024]. O PyKnow permite a construção de sistemas especialistas de forma estruturada, utilizando conceitos como fatos, regras e mecanismos de encadeamento direto (*forward chaining*), integrando-se de forma transparente ao restante da aplicação desenvolvida em Python.

As regras de recomendação, extraídas do manual da Embrapa, foram previamente estruturadas em arquivos no formato JSON, o que possibilita uma separação clara entre a base de conhecimento agronômico e a lógica de inferência. Durante a inicialização do sistema, essas regras são carregadas em memória e convertidas em objetos e condições manipuláveis pelo PyKnow, preservando a flexibilidade e a extensibilidade da solução e permitindo a atualização das regras sem a necessidade de alterações na estrutura do código.

A Figura IV.7 apresenta uma visão esquemática da implementação do motor de inferência, destacando os principais componentes envolvidos no processo de raciocínio automatizado. O diagrama ilustra o fluxo de entrada dos fatos, o mecanismo de avaliação das regras e a geração das recomendações, evidenciando a interação entre a base de conhecimento, o motor de inferência e o módulo responsável pela consolidação dos resultados.

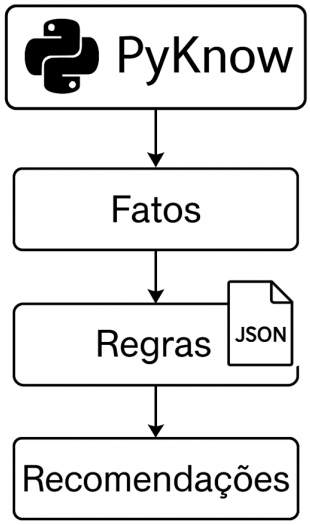



Figura IV.7: Visão esquemática da implementação do motor de inferência baseado em regras, evidenciando a inserção de fatos, a avaliação das regras e a geração das recomendações.

O fluxo de execução do motor de inferência segue três etapas principais. Inicialmente, os dados fornecidos pelo usuário, como análise de solo, cultura selecionada e município, são transformados em fatos inseridos no ambiente do PyKnow. Em seguida, o motor de inferência avalia esses fatos em relação às regras carregadas, disparando aquelas cujas condições são satisfeitas e gerando as recomendações correspondentes. Por fim, as recomendações produzidas são coletadas, organizadas

e apresentadas ao usuário na forma de um relatório técnico interpretável.

Essa abordagem contribui para a modularidade, a transparência e a rastreabilidade do sistema, assegurando que o processo de raciocínio permaneça compreensível tanto para especialistas quanto para agricultores interessados em entender a lógica subjacente às recomendações fornecidas.

## IV.6 Geração das Recomendações

A geração das recomendações constitui a etapa final do processo de inferência do sistema. Após a inserção dos dados de entrada e a ativação das regras relevantes pelo motor de inferência, as saídas são organizadas em um relatório estruturado e de fácil interpretação, voltado a pequenos produtores rurais e técnicos agrícolas.

A Figura IV.8 ilustra, de forma esquemática, o processo de geração e organização das recomendações produzidas pelo sistema. O diagrama evidencia a transformação das saídas do motor de inferência em um relatório técnico estruturado, destacando a separação das informações em blocos contextuais, preditivos e prescritivos, de modo a facilitar a compreensão e a aplicação prática das orientações fornecidas ao usuário.

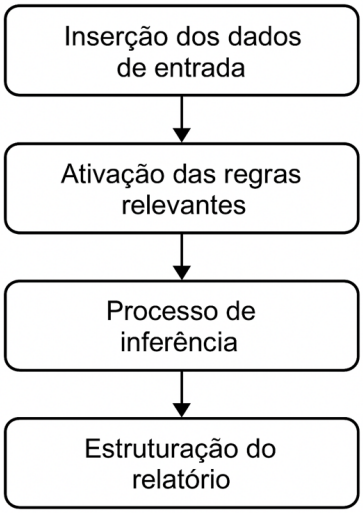



Figura IV.8: Visão esquemática da geração e organização das recomendações no relatório final do sistema.

O relatório gerado contém três partes principais:

1. Seção contextual: Esta seção apresenta, de forma resumida, uma análise da produtividade agrícola da região (com base nos dados da EMATER-Rio) e a caracterização climática da localidade (com base nos dados históricos do INMET). Esses tópicos visam oferecer ao usuário um panorama do ambiente de cultivo, reforçando a fundamentação das recomendações a seguir.

2. Seção previsão climática: Esta seção fornece uma previsão climática de curto prazo para a localidade selecionada, com horizonte de até 10 dias, obtida a partir da API Climapi da

Embrapa. As informações incluem variáveis meteorológicas relevantes para o planejamento agrícola, como precipitação acumulada, temperatura máxima e mínima, umidade relativa e velocidade do vento. A previsão visa apoiar decisões imediatas, especialmente quanto ao manejo do solo, ao planejamento da adubação e à definição da janela ideal para o plantio ou para o controle de pragas. Dessa forma, o sistema oferece não apenas recomendações baseadas em dados históricos, mas também considera as condições climáticas futuras, agregando valor e robustez às orientações técnicas apresentadas.

3. Seção de recomendações técnicas: Nesta parte, são listadas as recomendações geradas pelo sistema com base na análise química do solo e nas regras processadas pelo motor de inferência PyKnow. As recomendações são divididas por categoria:

    - Cultura recomendada: quando aplicável, com base na similaridade edafoclimática e no desempenho produtivo local;
    - Calagem: necessidade de correção da acidez do solo e dose recomendada de calcário;
    - Adubação: doses sugeridas de fósforo, potássio, nitrogênio e micronutrientes;
    - Controle de pragas: orientações específicas sobre produtos e culturas para a praga, bem como orientações de aplicação.

Cada recomendação apresentada no relatório é acompanhada de justificativas técnicas fundamentadas nas condições de entrada e nas regras que a originaram, o que contribui para a transparência do processo decisório e fortalece a confiabilidade do sistema perante o usuário. O relatório é gerado em formato digital, podendo ser exportado em PDF ou HTML, conforme a configuração do sistema, permitindo sua impressão ou armazenamento para consulta posterior. Essa etapa conclui o fluxo de processamento e materializa a entrega de uma ferramenta prática de apoio à decisão para o produtor rural.

## IV.7 Metodologia de Avaliação: Coeficiente Kappa de Cohen

Para avaliar o grau de concordância entre as recomendações geradas pelo sistema proposto e as fornecidas por especialistas em agronomia, foi utilizado o coeficiente Kappa de Cohen [Cohen, 1960]. Este índice é amplamente empregado em estudos de validação, pois permite quantificar a concordância entre dois avaliadores, eliminando o efeito do acaso.

O coeficiente Kappa ($\kappa$) é definido pela seguinte equação:

$$\kappa = \frac{p_o - p_e}{1 - p_e}$$

onde:

- $p_o$ representa a proporção de concordância observada, calculada a partir da soma dos casos em que ambos os avaliadores (no caso, sistema e especialista) emitiram a mesma classificação;
- $p_e$ corresponde à proporção de concordância esperada ao acaso, estimada a partir das distribuições marginais das categorias atribuídas por cada avaliador.

O valor de $\kappa$ varia entre $-1$ e 1, sendo que:

- valores próximos a 0 indicam ausência de concordância além do acaso;
- valores negativos sugerem discordância sistemática;
- valores positivos mais elevados indicam maiores níveis de concordância.

Conforme a interpretação proposta por Landis and Koch [1977], valores de $\kappa$ entre 0,41 e 0,60 indicam concordância moderada, entre 0,61 e 0,80 indicam concordância substancial e valores acima de 0,81 indicam concordância quase perfeita. Embora essa escala seja amplamente utilizada, ressalta-se que sua aplicação deve ser contextualizada, considerando a natureza dos dados e os objetivos do estudo.

Além do cálculo do coeficiente de Kappa simples, em situações em que as categorias apresentam caráter ordinal (por exemplo, níveis de recomendação classificados como "Baixo", "Médio" e "Alto"), foi utilizado o Kappa ponderado (*Weighted Kappa*) [Cohen, 1968]. Nesta variação, os desacordos são penalizados de forma diferenciada, atribuindo-se pesos menores a divergências próximas e maiores a divergências distantes, o que proporciona uma avaliação mais realista do desempenho do sistema.

Assim, a aplicação do coeficiente Kappa de Cohen permitiu não apenas verificar o nível de concordância global entre as recomendações geradas automaticamente e as emitidas pelos especialistas, mas também fornecer uma medida estatística que incorpora o efeito do acaso e possibilita comparações mais consistentes entre diferentes cenários experimentais.

### IV.8 Construção e Avaliação dos Cenários de Teste

Para a validação do sistema de recomendação agrícola, foi elaborado um conjunto de cenários experimentais que representam diferentes condições. O objetivo da construção desses cenários é simular situações reais enfrentadas por pequenos produtores rurais, a fim de avaliar a capacidade do sistema de fornecer recomendações consistentes e adequadas.

Foram construídos 180 cenários de teste a partir de dados de análises de solo disponibilizados pela Embrapa, por meio do banco de dados BDSolos, especificamente para o Estado do Rio de Janeiro. O conjunto recebeu tratamento (remoção de duplicatas, padronização de unidades e de intervalos plausíveis) e georreferenciamento, garantindo a aderência espacial aos pontos amostrados. A seleção foi estratificada por município e por classes de solo/atributos críticos (pH, textura, teores

de Ca, Mg, K, P e $Al^{3+}$), convertidos para as medidas utilizadas no Manual de Adubagem e Calagem do Estado do RJ, de modo a cobrir múltiplos municípios e refletir a variabilidade edáfica do estado. A este conjunto, foi adicionada a variável cultura, retirada com base na verificação de cultivo local já existente na região, com base nos dados de produtividade agrícola, disponibilizados pela EMATER. Cada cenário está ancorado em um ponto (ou agregado local) real do BDSolos e recebeu um identificador único; todo o conjunto foi congelado antes da avaliação para assegurar reprodutibilidade.

A Tabela IV.1 apresenta alguns exemplos de cenários utilizados. A lista completa dos cenários utilizados pode ser encontrada como material suplementar no Apêndice A.

Tabela IV.1: Amostra dos cenários de teste realizados

| **Uso Atual** | **Município** | **Classe de Textura** | **pH ($H_2O$)** | **Cálcio (Ca) ($cmol_c\ dm^{-3}$)** | **Magnésio (Mg) ($cmol_c\ dm^{-3}$)** | **Potássio (K) ($cmol_c\ dm^{-3}$)** | **Alumínio ($Al^{3+}$) ($cmol_c\ dm^{-3}$)** | **Fósforo (P) (mg $kg^{-1}$)** | **Cultura** |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem | Araruama | Muito argilosa (argila pesada) | 4,9 | 4,5 | 4,6 | 0,1 | 0 | 1 | Cana-de-açúcar |
| Pomar de citrus e pastagem. | Araruama | Franco-argilo-arenosa | 5,4 | 0,9 | 0,5 | 0,05 | 0 | 1 | Mandioca |
| Pomar de citrus e pastagem. | Araruama | Argilo-arenosa | 5,8 | 1 | 0,5 | 0,03 | 0 | 1 | Quiabo |
| Pastagem plantada. | Araruama | Argilo-siltosa | 4,5 | 2 | 0,8 | 0,08 | 49 | 4 | Abóbora, abobrinha e moranga |
| Cítricas | Araruama | Franco-arenosa | 4,8 | 2 | 0,2 | 0,06 | 4 | 2 | Feijão-mauá |
| Pastagem natural. | Araruama | Muito argilosa (argila pesada) | 4,9 | 4,5 | 4,6 | 0,1 | 0 | 1 | Batata-doce |
| Pastagem plantada (brachiaria). | Araruama | Areia-franca | 5 | 1,4 | 0,2 | 0,15 | 0 | 4 | Coco |
| Nenhum. | Araruama | Franco-arenosa | 5,2 | 2,5 | 0,4 | 0,06 | 4 | 1 | Maracujá |
| Nenhum. | Araruama | Argilo-arenosa | 4,8 | 1,3 | 1,5 | 0,13 | 21 | 1 | Melancia e melão |
| Nenum. | Araruama | Franco-arenosa | 5 | 2,8 | 5,4 | 0,07 | 0 | 4 | Milho |
| Nenum. | Araruama | Franco-argilo-arenosa | 5,9 | 3,2 | 7,2 | 0,03 | 1 | 1 | Sorgo granífero |
| Pastagem de colonião. | Araruama | Franco-arenosa | 5,5 | 4,8 | 1,9 | 0,35 | 0 | 4 | Soja |
| cultura de citros. | Cabo Frio | Franco-argilo-arenosa | 4,6 | 0,3 | 0,2 | 0,05 | 1 | 2 | Milho |
| pastagem plantada de capim-colonião. | Cabo Frio | Areia | 8 | 1,9 | 0,3 | 0,04 | 0 | 10 | Cítricas |
| pastagem. | Cabo Frio | Muito argilosa (argila pesada) | 7,4 | 21 | 16,1 | 0,51 | 0 | 3 | Mandioca |
| banana, cana, aipim e guandu. | Cabo Frio | Franco-argilosa | 6,8 | 19,7 | 9,9 | 0,13 | 0 | 7 | Banana |
| pomar de citrus | Cabo Frio | Franco-argilo-arenosa | 4,8 | 1 | 0,2 | 0,5 | 0,2 | $< 1$ | Coco |
| cultura de citros. | Cabo Frio | Franco-argilo-arenosa | 4,6 | 0,3 | 0,2 | 0,05 | 1 | 2 | Abóbora, abobrinha e moranga |
| Citricultura. | Cabo Frio | Franco-argilo-arenosa | 5,5 | 1,4 | 0,3 | 0,05 | 0,1 | 1 | Alface |
| área de cultura abandonada. | Cabo Frio | Franco-arenosa | 6,3 | 1,7 | 0,3 | 0,04 | 0 | 1 | Quiabo |
| culturas de mandioca, banana e cana-de-açúcar. | Cabo Frio | Areia | 6,7 | 0,8 | 0,1 | 0,04 | 0,1 | 7 | Goiaba |

Em seguida, o conjunto de cenários foi submetido a especialistas em agronomia, que emitiram suas recomendações de forma independente, sem acesso prévio às recomendações do sistema, e também foram respondidos, manualmente, conforme recomendação do Manual de Adubagem e Calagem. Esse processo de cegamento foi adotado para assegurar imparcialidade na comparação. Nos casos em que houve mais de um especialista envolvido, foram registrados todos os julgamentos, o que possibilitou a análise tanto do nível de concordância entre os especialistas quanto do entre o sistema e cada avaliador.

Após a coleta das recomendações humanas e a resposta por meio de consulta ao Manual, o sistema foi executado em todos os cenários definidos, gerando a saída correspondente. Os resultados

foram então organizados em uma matriz de confusão, que permite visualizar o grau de concordância e de divergência entre as recomendações. A partir dessa matriz, foram aplicadas as métricas estatísticas de avaliação, destacando-se o coeficiente Kappa de Cohen, conforme descrito na seção anterior.

Essa estratégia experimental possibilita uma análise abrangente da qualidade das recomendações, não apenas em termos de concordância global, mas também por meio da estratificação dos resultados em subgrupos de interesse, como diferentes culturas, regiões ou faixas de pH do solo. Dessa forma, torna-se viável identificar em quais condições o sistema apresenta maior aderência às recomendações técnicas e em quais situações ainda demanda ajustes.

## IV.9 Considerações Finais da Metodologia

A metodologia adotada nesta dissertação foi cuidadosamente estruturada para viabilizar o desenvolvimento de um sistema de recomendação agrícola inteligente, orientado às necessidades de pequenos produtores rurais e fundamentado em conhecimento técnico validado. A abordagem híbrida, combinando dados empíricos, regras agronômicas e técnicas de inferência lógica, permitiu a construção de uma solução transparente, modular e adaptável à realidade edafoclimática do estado do Rio de Janeiro.

Cada etapa do processo metodológico contribuiu diretamente para a robustez do sistema, desde a coleta e organização das bases de dados, passando pela modelagem das regras de recomendação com base em fontes oficiais, até a implementação do motor de inferência com PyKnow, totalmente integrado ao ecossistema Python. A geração automatizada de relatórios em HTML proporcionou uma forma simples, porém funcional, de apresentar os resultados ao usuário final.

# Capítulo V Aspectos de Implementação e Ambiente Experimental

O desenvolvimento e a avaliação do sistema de recomendação agrícola proposto nesta dissertação envolveram não apenas a implementação do motor de inferência, mas também a construção de uma base de dados consolidada, uma das principais contribuições deste trabalho. Esse processo exigiu a integração de múltiplas fontes de dados confiáveis, abrangendo aspectos edáficos, climáticos, produtivos e técnico-científicos, provenientes de instituições como a Embrapa, o INMET e a EMATER-Rio, além de literatura técnica especializada. A avaliação experimental teve como objetivo verificar se, a partir dessa base de dados estruturada, as recomendações geradas pelo sistema eram consistentes, práticas e tecnicamente corretas. Para isso, foram elaborados cenários simulados com base em dados reais, representativos das condições edafoclimáticas e produtivas do estado do Rio de Janeiro. Os resultados foram submetidos à análise de profissionais das áreas de solos e agricultura, com ampla experiência em extensão rural, fertilidade do solo e manejo de culturas, com o objetivo de validar tanto a coerência das inferências quanto a aplicabilidade das recomendações no contexto agrícola fluminense.

## V.1 Dados Meteorológicos

Os dados meteorológicos utilizados no sistema de recomendação foram obtidos a partir da rede de sensores do Instituto Nacional de Meteorologia (INMET)[1][2], com foco específico nas estações localizadas no estado do Rio de Janeiro. Esses dados são fundamentais para caracterizar o clima das diferentes regiões agrícolas do estado, permitindo que o sistema adapte suas recomendações às condições ambientais locais.

As informações extraídas incluem variáveis como temperatura média, máxima e mínima, umidade relativa do ar, precipitação pluviométrica, pressão atmosférica, velocidade do vento, entre outros indicadores climáticos. Tais variáveis são coletadas diariamente pelas estações meteorológicas automáticas e convencionais do INMET, o que possibilita análises temporais e espaciais consistentes.

Antes de serem integrados ao sistema, os dados meteorológicos passaram por um tratamento inicial. Esse processo incluiu a remoção de registros inexistentes ou inconsistentes (valores nulos

[1] https://portal.inmet.gov.br
[2] https://portal.inmet.gov.br/dadoshistoricos

ou fora de padrão) e a unificação de todas as medições das diferentes estações do estado do Rio de Janeiro em uma base única, estruturada e padronizada. Essa base consolidada permitiu uma análise mais eficiente dos dados e a associação correta entre as regiões agrícolas e seus respectivos perfis climáticos.

No contexto deste trabalho, os dados meteorológicos foram utilizados para duas finalidades principais. Primeiramente, para compor o perfil climático das regiões de cultivo, auxiliando na escolha de culturas mais adaptadas às condições locais. Em segundo lugar, para gerar recomendações relacionadas ao manejo agrícola, como o planejamento do ciclo de calagem e a recomendação de práticas de manejo de nitrogênio, que são fortemente influenciadas por fatores como a temperatura e o regime de chuvas. Podemos verificar nas Figuras V.1 e V.2 o volume de chuva na região serrana, separado por ano e mês, assim como a visualização da série temporal do volume de chuva daquela região.

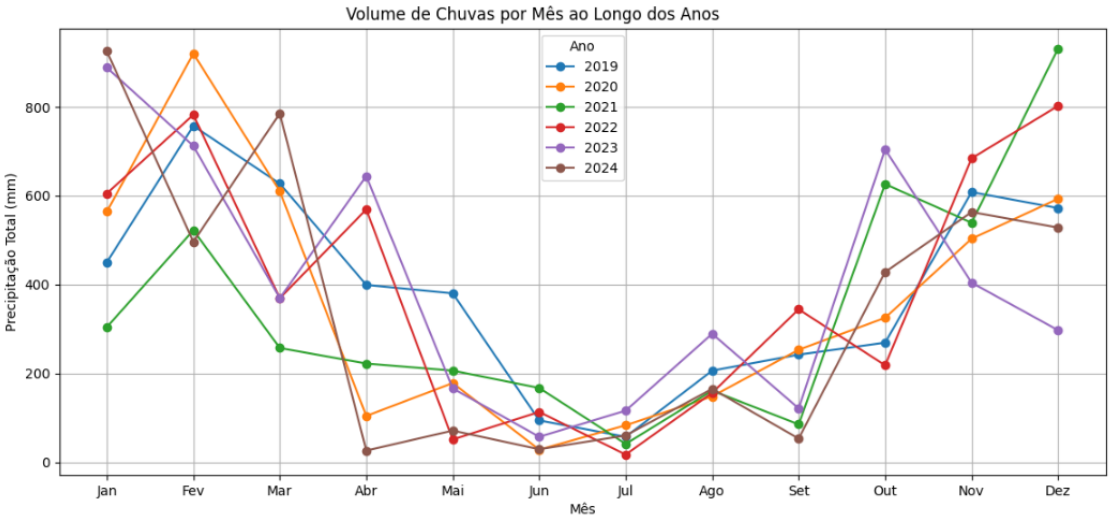



Figura V.1: Volume de chuvas da região serrana, separado por mês do ano, nos últimos 6 anos. Fonte: O próprio autor.

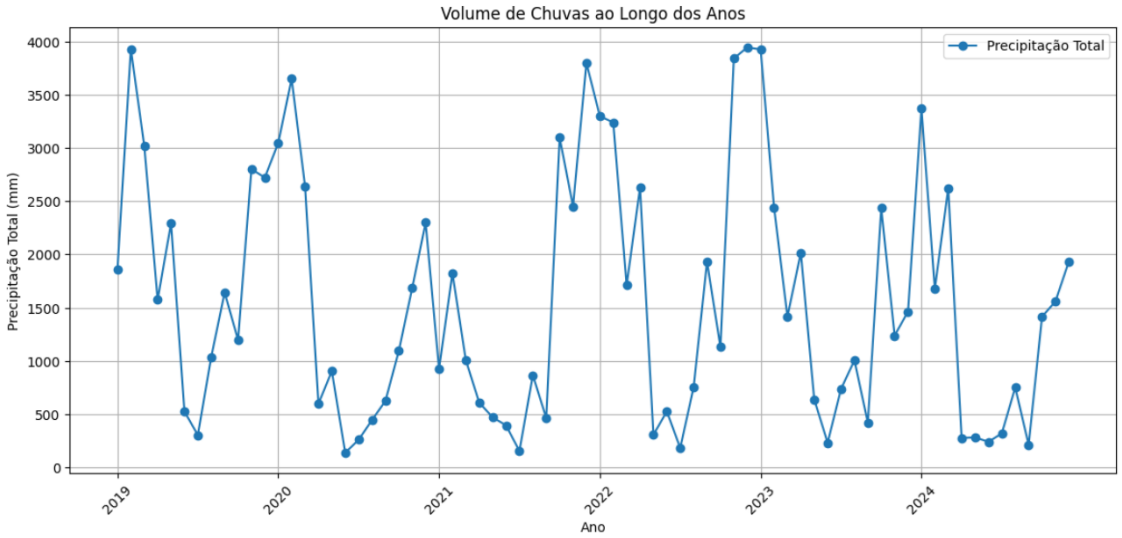



Figura V.2: Volume de chuvas da região serrana, separado por mês do ano, nos últimos 6 anos. Fonte: O próprio autor.

A Tabela V.1 apresenta um resumo estatístico da base de dados. Essa base contém um total de 26 variáveis, coletadas a partir de 833.696 observações, sem registros ausentes, o que garante alta qualidade e completude dos dados. O conjunto ocupa aproximadamente 171,7 MiB de memória, com tamanho médio de 216 bytes por registro. Em relação aos tipos de variáveis, observa-se predominância de variáveis numéricas (19), além de variáveis categóricas (6) e de uma variável temporal (DateTime), que representa o instante da medição. Essas características constituem uma base adequada para análises climáticas históricas regionais e para a contextualização das recomendações agrícolas geradas pelo sistema.

Tabela V.1: Resumo estatístico da base de dados meteorológicos do INMET

| **Descrição** | **Valor** |
|---|---|
| **Estatísticas do Conjunto de Dados** | |
| Número de variáveis | 26 |
| Número de observações | 833.696 |
| Células ausentes | 0 |
| Percentual de células ausentes | 0,0% |
| Tamanho total na memória | 171,7 MiB |
| Tamanho médio por registro | 216,0 B |
| **Tipos de Variáveis** | |
| Variáveis do tipo DateTime | 1 |
| Variáveis categóricas | 6 |
| Variáveis numéricas | 19 |

A Tabela V.2 apresenta uma amostra da base de dados meteorológicos obtida do INMET, com registros da estação de Seropédica (RJ) no dia 1º de janeiro de 2018. A tabela contém variáveis meteorológicas horárias, como temperatura do ar, umidade relativa, precipitação, pressão atmosférica, direção e velocidade do vento. Essas informações são fundamentais para a caracterização

climática da região, permitindo análises históricas e subsidiando a contextualização das recomendações agronômicas geradas pelo sistema. Os dados são precisos, registrados automaticamente por sensores e fornecem uma base confiável para avaliações climáticas locais.

Tabela V.2: Amostra da base de dados meteorológicos do INMET

| Data | Hora | Precip. | Temp. (°C) | Umidade (%) | Vento (m/s) | Estação | UF | Código |
|---|---|---|---|---|---|---|---|---|
| 01/01/2018 | 00:00 | 0.0 | 25.4 | 74.0 | 1.2 | Seropédica | RJ | A601 |
| 01/01/2018 | 01:00 | 0.0 | 25.7 | 71.0 | 1.4 | Seropédica | RJ | A601 |
| 01/01/2018 | 02:00 | 0.0 | 26.3 | 65.0 | 1.4 | Seropédica | RJ | A601 |
| 01/01/2018 | 03:00 | 0.0 | 26.1 | 66.0 | 2.7 | Seropédica | RJ | A601 |
| 01/01/2018 | 04:00 | 0.0 | 25.5 | 70.0 | 2.8 | Seropédica | RJ | A601 |
| 01/01/2018 | 05:00 | 0.0 | 25.6 | 69.0 | 2.8 | Seropédica | RJ | A601 |
| 01/01/2018 | 06:00 | 0.0 | 25.4 | 70.0 | 2.9 | Seropédica | RJ | A601 |
| 01/01/2018 | 07:00 | 0.0 | 24.6 | 75.0 | 1.8 | Seropédica | RJ | A601 |
| 01/01/2018 | 08:00 | 0.0 | 24.6 | 74.0 | 1.6 | Seropédica | RJ | A601 |
| 01/01/2018 | 09:00 | 0.0 | 25.4 | 73.0 | 0.4 | Seropédica | RJ | A601 |

## V.2 Dados de Solo

Para compor o componente edáfico do sistema de recomendação, foram utilizados dados oriundos do BDSolos (Banco de Dados de Perfis de Solo do Brasil), mantido pela Embrapa. Essa base de dados reúne informações detalhadas sobre perfis de solo coletados em todo o território nacional, sendo uma das fontes mais abrangentes e qualificadas sobre as características físicas, químicas e morfológicas dos solos brasileiros.

O BDSolos disponibiliza informações como textura, teor de argila, matéria orgânica, pH, capacidade de troca catiônica (CTC), saturação por bases, alumínio trocável, profundidade dos horizontes do solo, entre outros atributos. Essas variáveis são importantes para a definição da aptidão agrícola de uma área e, consequentemente, para a elaboração de recomendações técnicas de calagem, adubação e de escolha de culturas mais compatíveis com o tipo de solo.

A Tabela V.3 apresenta um panorama estatístico da base de dados de solo legada da Embrapa (BDSolos). O conjunto é composto por 267 variáveis distribuídas em mais de 32 mil registros, ocupando aproximadamente 65,5 MB de memória. Entretanto, um aspecto crítico é a elevada taxa de ausência de dados: cerca de 69,9% das células da base estão vazias, o que reforça a importância das etapas de tratamento realizadas durante o trabalho.

Tabela V.3: Resumo estatístico da base de dados de solo legado da Embrapa (BDSolos)

| Descrição | Valor |
|---|---|
| **Estatísticas do Conjunto de Dados** | |
| Número de variáveis | 267 |
| Número de observações | 32.147 |
| Células ausentes | 6.001.831 |
| Percentual de células ausentes | 69,9% |
| Tamanho total na memória | 65,5 MB |
| Tamanho médio por registro | 2,1 KB |
| **Tipos de Variáveis** | |
| Variáveis de texto | 80 |
| Variáveis categóricas | 97 |
| Variáveis numéricas | 85 |
| Variáveis booleanas | 5 |
| Variáveis sem tipo definido | 36 |

As Figuras V.3 e V.4 apresentam a distribuição dos dados faltantes na base original do BDSolos. Observa-se um crescimento acentuado da proporção de valores ausentes à medida que se avança para determinados grupos de atributos, até atingir um patamar elevado de ausência, caracterizando um cenário de alta esparsidade. Esse comportamento indica a existência de um conjunto significativo de variáveis com baixo preenchimento, pouco informativas ou inconsistentes ao longo da base. Diante desse padrão, tornou-se necessário adotar procedimentos rigorosos de pré-processamento, incluindo a filtragem de colunas com elevado percentual de valores ausentes e a padronização das variáveis remanescentes, de modo a garantir a qualidade, a consistência e a viabilidade analítica dos dados utilizados nas etapas subsequentes do sistema de recomendação.

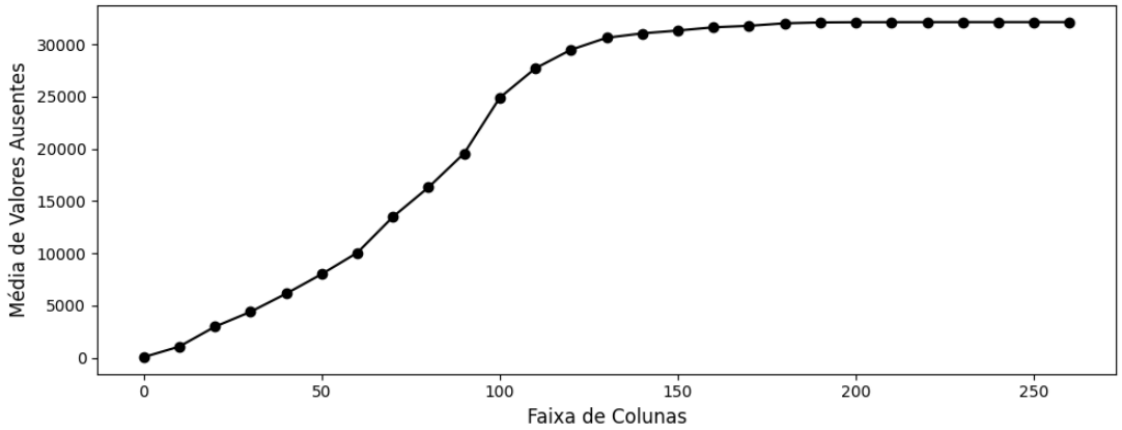



Figura V.3: Média dos valores ausentes por faixa de colunas na base BDSolos. Observa-se crescimento acentuado das ausências até estabilizar-se em um patamar elevado, evidenciando alta esparsidade e um grande conjunto de atributos com baixo preenchimento; esse padrão motivou a filtragem de colunas e a padronização.

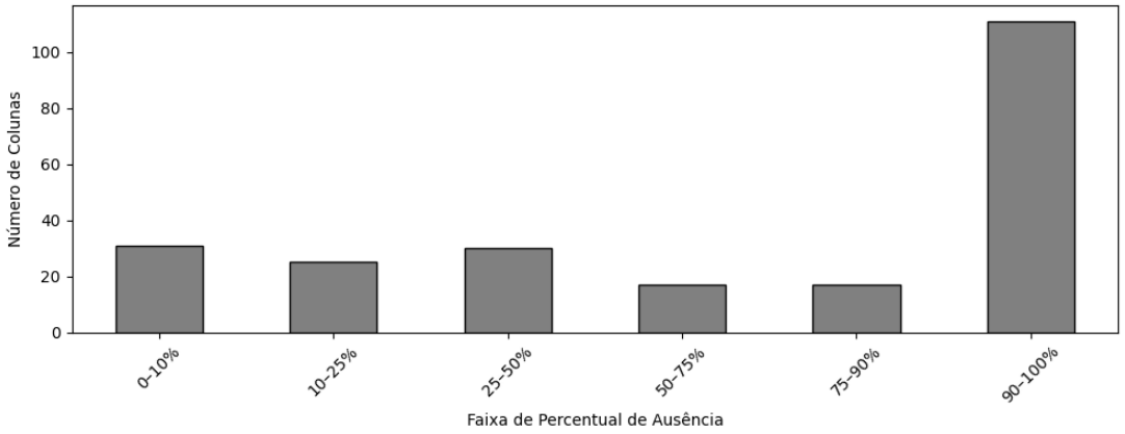



Figura V.4: Distribuição das colunas por faixa de percentual de ausência na BDSolos. Nota-se forte concentração no intervalo de 90–100% de dados faltantes, superando amplamente as demais faixas, enquanto poucas colunas têm ausência inferior a 50%. Esse padrão de esparsidade levou à eliminação ou ao agrupamento de atributos com baixo preenchimento.

No entanto, dada a complexidade, a heterogeneidade e a alta taxa de ausência de dados na base BDSolos, no contexto deste trabalho, foi realizado um processo completo de extração, transformação e carga (ETL) dos dados de solo. Esse processo teve como objetivo tratar, padronizar e estruturar os dados de forma mais adequada às necessidades operacionais do sistema de recomendação. A Figura V.5 apresenta a lógica adotada no processo.

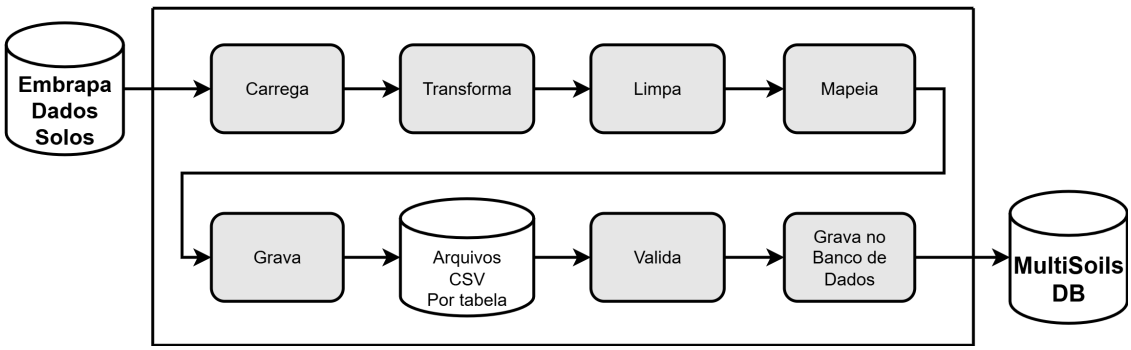



Figura V.5: Pipeline de ETL dos dados de solo da Embrapa Solos (BDSolos). O fluxo superior executa a ingestão, transformação, limpeza e mapeamento dos dados para o esquema-alvo; em seguida, os dados normalizados são gravados em *CSV* por tabela. No fluxo inferior, os arquivos são validados e então carregados no banco de dados, garantindo padronização e consistência antes de abastecer o sistema de recomendação.

O processo de integração dos dados legados ao sistema foi conduzido por meio da construção de um pipeline de ETL, desenvolvido em Python. A escolha dessa linguagem se deu não apenas pela ampla adoção na comunidade científica, mas também pelo ecossistema robusto de bibliotecas especializadas na manipulação, análise e integração de dados. Além disso, favoreceu a modularidade e a escalabilidade do projeto, possibilitando sua ampliação futura.

A arquitetura do processo ETL foi estruturada em quatro etapas principais. A primeira etapa, extração, consistiu na coleta dos dados públicos disponibilizados pela Embrapa Solos [EMBRAPA

Solos, 2024], organizados em arquivos CSV por unidade federativa. Cada arquivo foi obtido por meio de consultas filtradas manualmente no portal do BDSolos, com o estado (UF) como critério obrigatório. Como os arquivos extraídos não continham dicionário de dados nem documentação de metadados, foi necessária uma análise exploratória detalhada utilizando a biblioteca YData Profiling[3], que gerou relatórios sobre a distribuição de valores, categorias, formatos e a ausência de dados. Essa análise foi complementada pela avaliação de um especialista em solos, que identificou a escala adequada dos atributos.

Na etapa de transformação, os dados passaram por procedimentos de limpeza, normalização e padronização, incluindo o tratamento de valores ausentes, a remoção de duplicatas, a conversão de unidades e a uniformização de formatos. Um dos principais desafios foi padronizar colunas textuais com variações de grafia e sinônimos, o que foi resolvido com o uso da biblioteca FuzzyWuzzy, que aplica algoritmos de similaridade textual. Com base nos resultados, foram criadas funções de mapeamento para unificar categorias equivalentes, assegurando coesão semântica. A transformação também reorganizou os campos conforme o modelo relacional, separando os dados em tipos: morfológicos, físicos, químicos e de localização.

A validação combinou testes automatizados e revisão manual. Foram verificadas a integridade referencial, a consistência entre atributos dependentes e amostras dos dados foram inspecionadas visualmente. Todas as alterações foram registradas em um log versionado, assegurando a rastreabilidade. Para garantir a qualidade técnica, amostras representativas foram avaliadas por agrônomos, confirmando a conformidade com a lógica agronômica e com os padrões técnicos dos dados de solo.

Por fim, os dados padronizados foram organizados em arquivos intermediários no formato CSV e, posteriormente, inseridos no repositório central, estruturado sobre o banco de dados PostgreSQL[4]. A carga foi realizada com o auxílio da biblioteca SQLAlchemy[5], que permitiu a inserção eficiente e segura dos dados em tabelas normalizadas. A adoção de um banco relacional robusto garante a escalabilidade da plataforma e facilita a integração com sistemas de recomendação, ferramentas de análise e interfaces geoespaciais.

Como resultado, a base inicial de 32.148 registros foi reduzida para 16.181 entradas válidas, após a exclusão de 15.967 registros que não atendiam aos critérios de qualidade e georreferenciamento. A base final foi organizada em cinco categorias principais: observações gerais, descrições morfológicas, análises físicas, análises químicas e ataques sulfúricos, armazenadas em tabelas relacionais específicas no PostgreSQL. A tabela V.4 apresenta os resultados obtidos. A consolidação permitiu eliminar duplicidades, corrigir formatações inadequadas e garantir integridade semântica entre atributos similares.

[3]https://docs.profiling.ydata.ai
[4]https://www.postgresql.org
[5]https://www.sqlalchemy.org

Tabela V.4: Resultado dos registros afetados pelo ETL dos dados de solo.

| **Dados de Origem** | **Quantidade** |
|---|---|
| Número de colunas | 266 |
| Registros encontrados | 32.147 |
| Registros excluídos | 15.966 |
| Registros mantidos | 16.181 |
| **Dados de Destino** | **Quantidade** |
| Registros de observações | 4.088 |
| Registros de descrição morfológica | 16.181 |
| Registros ataque sulfúrico | 13.701 |
| Registros análise física | 15.384 |
| Registros análise química | 15.605 |

A partir da consolidação, os dados de solo passaram a ser acessados de forma otimizada pelo sistema de recomendação, permitindo consultas por localização geográfica e por atributos específicos de fertilidade e de manejo. No âmbito do sistema, os dados são utilizados de duas formas principais: (i) quando há análise de solo fornecida diretamente pelo usuário, essa informação é priorizada no processo de recomendação; e (ii) quando não há análise local disponível, o sistema recorre aos dados consolidados, considerando os perfis de solo mais próximos da propriedade rural em questão.

Além disso, a integração dos dados possibilitou a construção de uma base edafoclimática, cruzando informações de solo com variáveis meteorológicas das regiões. Isso ampliou significativamente a capacidade do sistema de gerar recomendações mais robustas e contextualizadas, considerando não apenas os perfis químicos e físicos dos solos, mas também as condições ambientais e climáticas locais.

## V.3 Dados de Produtividade Rural

Outra base de dados importante para a construção do sistema de recomendação é proveniente da Empresa de Assistência Técnica e Extensão Rural do Estado do Rio de Janeiro (EMATER-Rio), no âmbito do projeto ASPA, sigla de Acompanhamento Sistemático da Produtividade Agrícola. Este projeto disponibiliza dados consolidados dos anos de 2021, 2022 e 2023, com previsão de lançamento dos dados referentes ao ano de 2024 em 2025.

Os dados do ASPA fornecem informações valiosas sobre a realidade produtiva do estado, incluindo variáveis como tipo de cultura cultivada, produtividade (em toneladas por hectare), faturamento bruto, volume colhido (em toneladas), preço de comercialização e município de origem. Esse conjunto de informações permite uma visão abrangente da dinâmica agrícola local, o que é fundamental para calibrar o sistema com base no desempenho real das culturas em diferentes regiões.

Assim como os dados meteorológicos, os dados do projeto ASPA também passaram por um

processo de tratamento inicial. Esse processo envolveu a padronização dos nomes das culturas e dos municípios, a verificação e a correção de possíveis inconsistências nos registros e a unificação dos dados de três anos em uma base única. Essa integração permitiu ao sistema trabalhar com séries históricas de produtividade, possibilitando a identificação de tendências e padrões regionais ao longo do tempo.

As Figuras V.6 e V.7 apresentam uma análise comparativa da produção colhida e do faturamento bruto por cultura, entre 2021 e 2023. Essa visualização destaca as culturas mais representativas do ponto de vista econômico e produtivo, fornecendo insumos importantes para a priorização das recomendações. Já a Figura V.8 exibe um mapa temático que ilustra, por município, o volume total colhido no mesmo período. Esse mapeamento espacial evidencia as regiões com maior expressão agrícola, reforçando a importância de considerar a produção local nas recomendações do sistema.

Os dados da EMATER-Rio são utilizados no sistema para reforçar as recomendações com base na produção local. Por exemplo, uma cultura que apresenta bom desempenho produtivo e econômico em determinada cidade pode ser priorizada nas sugestões feitas aos produtores da mesma região, respeitando a similaridade climática e edáfica. Dessa forma, o sistema alia o conhecimento técnico às evidências empíricas da realidade agrícola fluminense.

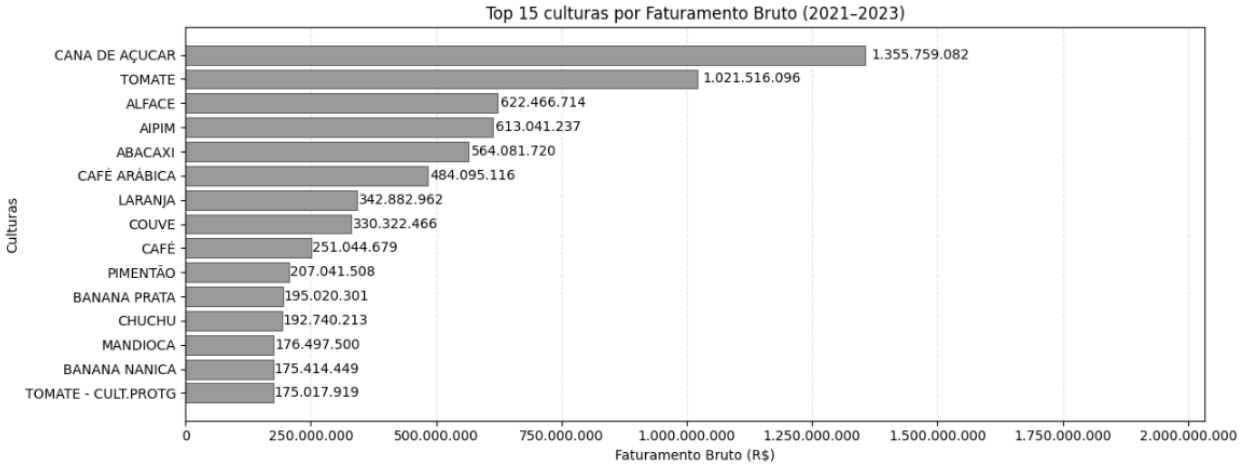



Figura V.6: Gráfico comparativo do faturamento bruto por cultura cultivada entre 2021 e 2023.

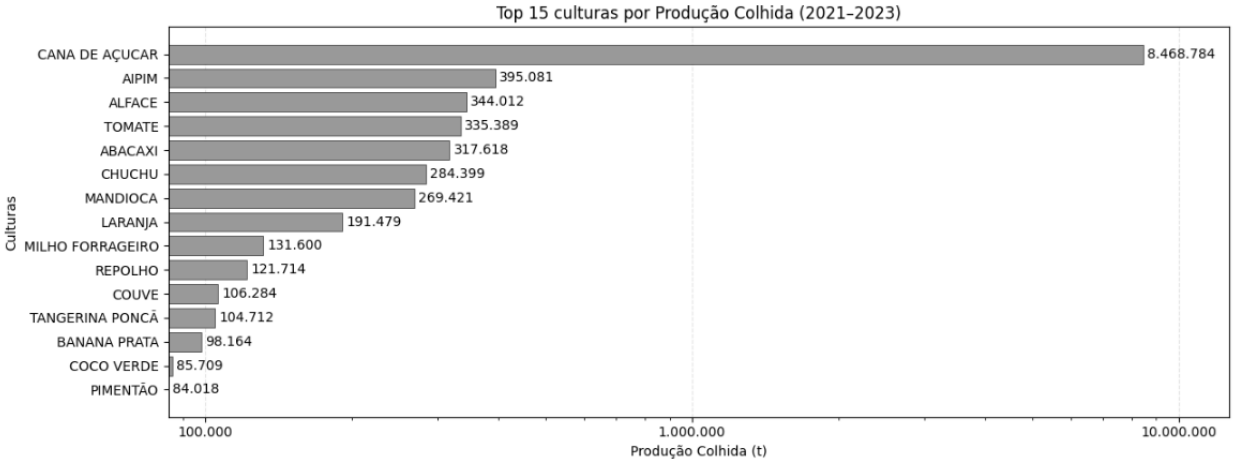



Figura V.7: Gráfico comparativo da produção colhida, em toneladas, por cultura cultivada entre 2021 e 2023.

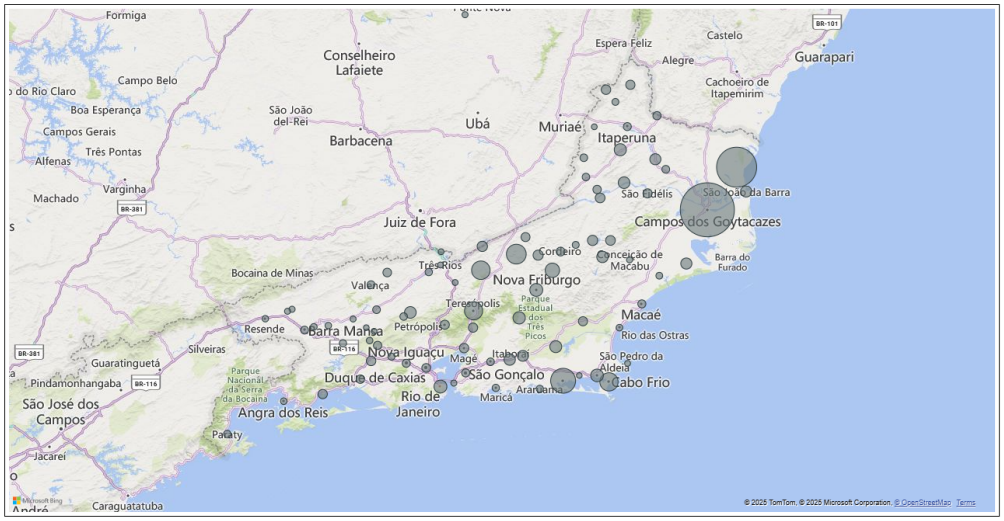



Figura V.8: Mapa do volume colhido dos anos 2021 a 2023.

A Tabela V.5 apresenta as estatísticas da base de dados. A base é composta por 3.204 observações distribuídas em 11 variáveis, sem registros ausentes nem linhas duplicadas, o que garante alta integridade dos dados. O conjunto ocupa 1,0 MiB de memória e apresenta um tamanho médio de 333 bytes por registro. Em relação à tipologia das variáveis, a base contém majoritariamente atributos numéricos (6), além de variáveis categóricas (3) e variáveis de texto livre (2), como nomes de culturas e municípios. Esses dados foram fundamentais para oferecer uma visão histórica da produtividade agrícola nas diferentes regiões do estado do Rio de Janeiro, subsidiando a contextualização das recomendações geradas pelo sistema.

Tabela V.5: Resumo estatístico da base de dados da EMATER-Rio (Projeto ASPA)

| Descrição | Valor |
|---|---|
| **Estatísticas do Conjunto de Dados** | |
| Número de variáveis | 11 |
| Número de observações | 3.204 |
| Células ausentes | 0 |
| Percentual de células ausentes | 0,0% |
| Linhas duplicadas | 0 |
| Percentual de linhas duplicadas | 0,0% |
| Tamanho total na memória | 1,0 MiB |
| Tamanho médio por registro | 333,0 B |
| **Tipos de Variáveis** | |
| Variáveis categóricas | 3 |
| Variáveis de texto | 2 |
| Variáveis numéricas | 6 |

A Tabela V.6 apresenta uma amostra da base de dados, com foco no município de Araruama em 2021. A amostra inclui diferentes culturas cultivadas na região, como cana-de-açúcar, tangerina, coco verde, melancia, aipim e laranja. Para cada cultura, estão informados o número de produtores, a produção total colhida, a área colhida, o preço médio por quilo, a produtividade (em toneladas por hectare) e o faturamento bruto estimado. Esses dados permitem compreender o desempenho econômico e produtivo das culturas no nível municipal, sendo utilizados no sistema para compor a análise contextual e apoiar decisões sobre recomendações agrícolas regionais.

Tabela V.6: Amostra da base de dados da EMATER-Rio

| Ano | Estado | Região | Município | Cultura | Produtores | Produção (kg) | Área (ha) | Preço (R$) | Produtiv. (t/ha) | Faturamento (R$) |
|---|---|---|---|---|---|---|---|---|---|---|
| 2021 | RJ | CENTRO | Araruama | CANA-DE-AÇÚCAR | 1 | 147783.0 | 3056.0 | 0.155717 | 48.36 | 23012280.0 |
| 2021 | RJ | CENTRO | Araruama | TANGERINA PONCÃ | 25 | 3065.0 | 125.0 | 1.383361 | 24.52 | 4240000.0 |
| 2021 | RJ | CENTRO | Araruama | COCO VERDE | 14 | 1377.0 | 60.0 | 1.834677 | 22.95 | 2526350.0 |
| 2021 | RJ | CENTRO | Araruama | LIMÃO | 45 | 6583.0 | 300.0 | 1.384551 | 21.94 | 9114500.0 |
| 2021 | RJ | CENTRO | Araruama | MELANCIA | 5 | 50.0 | 2.5 | 1.090000 | 20.00 | 54500.0 |
| 2021 | RJ | CENTRO | Araruama | TANGERINA | 10 | 201.0 | 13.0 | 1.376119 | 15.46 | 276600.0 |
| 2021 | RJ | CENTRO | Araruama | ABOBORA | 24 | 393.5 | 25.7 | 1.396315 | 15.31 | 549450.0 |
| 2021 | RJ | CENTRO | Araruama | BATATA DOCE | 12 | 82.0 | 5.5 | 1.691463 | 14.91 | 138700.0 |
| 2021 | RJ | CENTRO | Araruama | AIPIM | 88 | 1667.0 | 114.5 | 1.391962 | 14.56 | 2320400.0 |
| 2021 | RJ | CENTRO | Araruama | LARANJA | 155 | 23289.4 | 1677.0 | 1.562367 | 13.89 | 36386580.0 |

## V.4 Acesso à Previsão Climática via API da Embrapa (ClimAPI)

Visando incorporar informações climáticas atualizadas à recomendação agrícola, utilizou-se o serviço web ClimAPI[6], desenvolvido pela Embrapa Agricultura Digital[7]. Esta API RESTful fornece previsões meteorológicas de curto prazo (até 10 dias) para todo o território nacional, baseadas no modelo GFS (Global Forecast System) da NOAA[8], com atualizações a cada 6 horas. O acesso às previsões é feito por meio de coordenadas geográficas (latitude e longitude), o que permite obter valores estimados com alta resolução espacial, diretamente relacionados à localização do usuário.

[6]https://api.cnptia.embrapa.br/climapi/v1
[7]https://www.agroapi.cnptia.embrapa.br/portal
[8]https://www.ncei.noaa.gov/products/weather-climate-models/global-forecast

A API foi utilizada para coletar diversas variáveis principais. A Tabela V.7 apresenta as variáveis meteorológicas disponibilizadas pela API ClimAPI. Essas variáveis abrangem informações como temperatura máxima e mínima, umidade relativa, precipitação, radiação solar, velocidade do vento, cobertura de nuvens, entre outras. Cada variável possui uma unidade de medida específica e, em alguns casos, requer conversão para unidades usuais, na prática agrícola, como a conversão de temperatura de Kelvin para Celsius. A diversidade de variáveis permite uma análise detalhada das condições climáticas futuras, o que permite utilizá-las para gerar previsões contextualizadas e mais precisas no apoio à tomada de decisão agrícola.

Tabela V.7: Variáveis climáticas disponíveis na API ClimAPI

| **Nome** | **Descrição** | **Unidade Original** | **Conversão (se aplicável)** |
|---|---|---|---|
| `tmax2m` | Temperatura máxima a 2m | K | °C = K - 273.15 |
| `tmin2m` | Temperatura mínima a 2m | K | °C = K - 273.15 |
| `apcpsfc` | Precipitação total na superfície | $kg/m^2$ | – |
| `rh2m` | Umidade relativa a 2m | % | – |
| `gustsfc` | Velocidade de rajadas de vento na superfície | m/s | – |
| `pevprsfc` | Taxa de evaporação potencial na superfície | $W/m^2$ | mm/6h = $W/m^2 \times 0.0088128$ |
| `dswrfsfc` | Fluxo de radiação de onda curta descendente | $W/m^2$ | – |
| `sunsdsfc` | Duração do brilho solar | s | – |
| `soill0_10cm` | Umidade do solo (0–10 cm) | proporção | – |
| `hcdchcll` | Cobertura de nuvens altas | % | – |

O fluxo de acesso à API ClimAPI da Embrapa é estruturado em etapas progressivas, que vão desde a verificação da disponibilidade do serviço até a obtenção de previsões climáticas específicas por variável, data e localização geográfica. Inicialmente, realiza-se uma requisição para verificar o status da API, garantindo que o serviço esteja operacional. Em seguida, o usuário pode consultar as variáveis meteorológicas disponíveis, recuperar as datas associadas a cada uma e, por fim, acessar as previsões com base em parâmetros detalhados. Esses *endpoints*, com suas respectivas descrições e formatos de requisição, estão organizados na Tabela V.8, permitindo uma visão clara da sequência lógica de chamadas necessárias para a integração dos dados climáticos ao sistema.

Tabela V.8: Endpoints da API ClimAPI da Embrapa

| **Descrição** | **Endpoint** |
|---|---|
| Verificação do status da API | `GET https://api.cnptia.embrapa.br/climapi/v1/health` |
| Consulta das variáveis disponíveis | `GET https://api.cnptia.embrapa.br/climapi/v1/ncep-gfs` |
| Datas disponíveis para uma variável (ex.: temperatura máxima) | `GET https://api.cnptia.embrapa.br/climapi/ncep-gfs/{variavel}` |
| Consulta de previsões por data, variável e localização | `GET https://api.cnptia.embrapa.br/climapi/v1/ncep-gfs/{variavel}/{data}/{longitude}/{latitude}` |

As variáveis mais relevantes para a recomendação agrícola e incluídas nos relatórios foram:

- **tmax2m**: Temperatura máxima diária (°C)
- **tmin2m**: Temperatura mínima diária (°C)

- **apcpsfc**: Precipitação diária acumulada (mm)

A incorporação dessa API ao sistema permitiu enriquecer os relatórios de recomendação com previsões climáticas atualizadas, ampliando a contextualização das sugestões fornecidas ao produtor.

## V.5 Base de Regras

O último componente essencial da base de conhecimento do sistema é o Manual de Calagem e Adubação para o Estado do Rio de Janeiro, publicado pela Embrapa em 2013. Este documento técnico reúne orientações específicas para o manejo da fertilidade do solo em diferentes contextos agrícolas do estado, considerando suas condições edafoclimáticas, culturas predominantes e tipos de solo.

O manual serve como principal fonte para a formulação das regras implementadas no motor de inferência do sistema de recomendação. Ele apresenta critérios técnicos para recomendação de calagem, com base no cálcio (Ca), no magnésio (Mg), na acidez do solo (pH) e no alumínio ($Al^{3+}$), além de tabelas e fórmulas para cálculo das quantidades ideais de corretivos e fertilizantes, conforme a análise química do solo e a exigência das culturas.

Com base nessas diretrizes, foram extraídas e formalizadas regras específicas que consideram, por exemplo, o nível crítico de fósforo, potássio e cálcio, a necessidade de enxofre ou de micronutrientes, e os níveis adequados de saturação de bases para diferentes culturas. As regras foram organizadas de forma lógica e implementadas em um motor de inferência baseado em CLIPS, o que permite ao sistema gerar recomendações automatizadas, transparentes e adaptadas ao contexto de cada propriedade.

Além de embasar tecnicamente o raciocínio do sistema, o manual também garante aderência às boas práticas agronômicas recomendadas para o estado, promovendo a segurança técnica das orientações emitidas aos produtores.

### V.5.1 Exemplo de Regra de Cultura

Esta regra define quando a cultura do amendoim não deve ser recomendada, com base em condições de solo relacionadas à textura e à drenagem. A seguir, descrevem-se os campos do JSON e o fluxo de avaliação exatamente conforme especificado.

```
{
    "descricao": "Cultura não recomendada - Amendoim em solo argiloso ou encharcado",
    "tipo_recomendacao": "cultura",
    "grupos_condicoes": [
      {
        "tipo": "OR",
```

```
        "condicoes": {
          "textura": {"op": "==", "val": "argiloso"},
          "drenagem": {"op": "==", "val": "encharcado"}
        }
      }
    ],
    "acao": {
      "nome": "Não recomendado",
      "motivo": "Solos argilosos ou mal drenados inviáveis para Amendoim"
    },
    "prioridade": 3
},
```

O campo `"descricao"` registra a finalidade da regra: bloquear a cultura de amendoim quando o solo é argiloso ou há encharcamento.

Em `"tipo_recomendacao"` consta `"cultura"`, indicando que o resultado esperado é uma decisão sobre a viabilidade da cultura (recomendar ou não recomendar), e não uma prescrição de insumos ou de operações.

O array `"grupos_condicoes"` reúne os grupos lógicos a serem testados. No caso presente há um único grupo com:

- `"tipo": "OR"` — o grupo é verdadeiro se pelo menos uma das condições listadas for verdadeira.
- `"condicoes"` — objeto com os predicados a avaliar:
  - `"textura": {"op": "==", "val": "argiloso"}` — a condição é satisfeita quando o valor de entrada de textura é igual a `argiloso`.
  - `"drenagem": {"op": "==", "val": "encharcado"}` — a condição é satisfeita quando o valor de entrada de drenagem é igual a `encharcado`.

Como o tipo do grupo é `OR`, basta que uma das duas condições seja satisfeita para que o grupo resulte verdadeiro.

O objeto `"acao"` define o que retornar quando as condições forem atendidas:

- `"nome": "Não recomendado"` — indica que a cultura não deve ser proposta ao usuário.
- `"motivo": "Solos argilosos ou mal drenados inviáveis para Amendoim"` — justificativa a ser exibida ou registrada junto da decisão.

O campo `"prioridade":3` posiciona a regra na ordem de execução do motor. Essa prioridade é usada para resolver conflitos e determinar em que momento o bloqueio da cultura deve ser aplicado em relação a outras regras. O fluxo de avaliação é descrito abaixo:

1. Ler os valores de entrada correspondentes a `textura` e `drenagem`.
2. Avaliar o grupo lógico com `tipo = OR`:
   (a) Verificar se `textura == argiloso`.
   (b) Verificar se `drenagem == encharcado`.
   (c) Se ao menos um dos dois testes for verdadeiro, o grupo é verdadeiro.
3. Se o grupo for verdadeiro, a regra dispara e retorna a `acao` especificada juntamente com a `prioridade`.
4. Se o grupo for falso, a regra não se aplica e o motor segue para outras regras pertinentes.

As entradas mínimas para esta regra são os atributos categóricos `textura` e `drenagem`. A saída, quando a regra dispara, é uma decisão de não recomendar a cultura, acompanhada do motivo e da prioridade informados no JSON.

### V.5.2 Exemplo de Regra para Adubação

Esta regra visa orientar a adubação fosfatada quando a cultura é amendoim e o teor de fósforo no solo é menor ou igual a 10 mg $dm^{-3}$. A seguir, descrevem-se os componentes e o fluxo de avaliação.

```
{
    "descricao": "Adubação P para Amendoim - Teor de P  10 mg dm³",
    "tipo_recomendacao": "adubagem",
    "condicoes_simples": {
      "cultura": {"val": "amendoim"},
      "fosforo": {"op": "<=", "val": 10}
    },
    "acao": {"tipo": "P2O5", "dose_kg_ha": 80, "aplicacao": "Todo no plantio"},
    "prioridade": 2
},
```

O campo `"descricao"` documenta a finalidade da regra: adubação de fósforo para amendoim quando o teor de P é baixo (até 10 mg $dm^{-3}$). Esta informação é textual e serve para rastreabilidade e leitura humana.

O campo `"tipo_recomendacao"` está definido como `"adubagem"`, indicando que o resultado esperado é uma prescrição de insumo (e não a escolha/banimento de cultura ou a operação mecânica).

O objeto `"condicoes_simples"` concentra os predicados que devem ser verdadeiros para a regra disparar:

- `"cultura": {"val": "amendoim"}` restringe o escopo; a regra é avaliada como verdadeira somente quando a cultura-alvo informada na entrada é amendoim.
- `"fosforo": {"op": «=", "val": 10}` estabelece o limiar de fósforo no solo; o teste lógico compara o valor numérico de P fornecido na entrada com o valor 10, aceitando casos em que P seja menor *ou* igual a esse limite. A unidade de P é mg $dm^{-3}$, conforme indicado na descrição da regra.

O objeto `"acao"` define o que deve ser recomendado quando as condições são satisfeitas:

- `"tipo": "P2O5"` indica que a dose está expressa em pentóxido de fósforo.
- `"dose_kg_ha": 80` indica a quantidade a aplicar por hectare.
- `"aplicacao": "Todo no plantio"` define o momento de aplicação como integral no plantio, sem parcelamento.

O campo `"prioridade": 2` posiciona esta regra na fila de execução do motor. Em mecanismos em que prioridades menores significam maior precedência, esta regra é avaliada antes de regras de prioridade mais alta (por exemplo, 3, 4, ...) e depois de regras de prioridade 1. A prioridade orienta a resolução de conflitos quando múltiplas regras poderiam resultar em recomendações distintas para o mesmo insumo ou operação.

O processamento segue uma sequência simples:

1. Ler a cultura informada na entrada e verificar se é amendoim.
2. Ler o valor de fósforo em mg $dm^{-3}$ e avaliar o predicado $P \leq 10$.
3. Se ambos os testes forem verdadeiros, a regra dispara e retorna a ação de adubação definida em `"acao"` juntamente com a prioridade 2.
4. Se qualquer teste for falso, a regra não se aplica e o motor segue para outras regras pertinentes.

As entradas mínimas para esta regra são: cultura (valor categórico) e teor de fósforo do solo em mg $dm^{-3}$. A saída, quando a regra dispara, é uma prescrição de $P_2O_5$ de 80 kg $ha^{-1}$, com aplicação total no plantio, etiquetada com prioridade 2 para composição com as demais recomendações do sistema.

### V.5.3 Exemplo de Regra de Calagem

Esta regra determina quando não há necessidade de calagem para a cultura do café, considerando o teor de alumínio trocável e a soma de cálcio e magnésio no solo. A seguir, descrevem-se os campos do JSON e o fluxo de avaliação exatamente conforme especificado.

```
{
    "descricao": "calagem desnecessária para café - al < 0.3 e ca + mg  2.5 cmolc/dm³",
    "tipo_recomendacao": "calagem",
    "condicoes_simples":
                        {
                         "cultura": {"val": "café"},
                         "aluminio": {"op": "<", "val": 0.3},
                         "calcio_magnesio": {"op": ">=", "val": 2.5}
                         },
    "acao": {
              "necessario": false,
              "dose_ton_ha": 0,
              "prnt_recomendado": 0,
              "produto": "calcário dolomítico",
              "epoca": "antes do plantio"},
    "prioridade": 2
},
```

O campo `"descricao"` registra a finalidade: calagem desnecessária para café quando `Al` é menor que 0,3 $\text{cmol}_c\ \text{dm}^{-3}$ e `Ca + Mg` é maior ou igual a 2,5 $\text{cmol}_c\ \text{dm}^{-3}$.

Em `"tipo_recomendacao"` consta `"calagem"`, indicando que o resultado esperado é uma decisão sobre a necessidade de aplicação de calcário.

O objeto `"condicoes_simples"` reúne os predicados que devem ser verdadeiros para a regra disparar:

- `"cultura": {"val": "café"}` restringe a aplicação à cultura do café.
- `"aluminio": {"op": «", "val": 0.3}` verifica se o alumínio trocável é menor que 0,3 $\text{cmol}_c\ \text{dm}^{-3}$.
- `"calcio_magnesio": {"op": »=", "val": 2.5}` verifica se a soma de cálcio e magnésio é maior ou igual a 2,5 $\text{cmol}_c\ \text{dm}^{-3}$.

Todas as condições listadas devem ser satisfeitas para que a regra seja considerada verdadeira.

O objeto `"acao"` define o que retornar quando as condições forem atendidas:

- `"necessario":false` indica que a calagem não é necessária.

- `"dose_ton_ha":0` estabelece dose de calcário igual a zero.
- `"prnt_recomendado":0` indica que não há exigência de PRNT nesta situação.
- `"produto":"Calcário dolomítico"` registra o produto padrão associado ao módulo de calagem.
- `"epoca":"Antes do plantio"` indica a época de referência usada pelo sistema para esta decisão.

O campo `"prioridade":2` posiciona a regra na ordem de execução do motor, servindo para resolver conflitos e definir quando aplicar esta decisão em relação a outras regras de manejo. O fluxo de avaliação pode ser verificado abaixo:

1. Ler a cultura informada e verificar se é `café`.
2. Ler o valor de alumínio trocável ($\text{cmol}_c\ \text{dm}^{-3}$) e avaliar o predicado $\text{Al} < 0{,}3$.
3. Ler a soma `Ca + Mg` ($\text{cmol}_c\ \text{dm}^{-3}$) e avaliar o predicado $(\text{Ca} + \text{Mg}) \geq 2{,}5$.
4. Se todos os testes forem verdadeiros, a regra dispara e retorna a `acao` especificada juntamente com a `prioridade`.
5. Se algum teste for falso, a regra não se aplica e o motor segue para outras regras pertinentes.

As entradas mínimas para esta regra são: cultura (categórica), alumínio trocável em $\text{cmol}_c\ \text{dm}^{-3}$ e soma de cálcio e magnésio em $\text{cmol}_c\ \text{dm}^{-3}$. A saída, quando a regra dispara, é a indicação de calagem desnecessária com dose de 0 t $\text{ha}^{-1}$, PRNT recomendado igual a 0, produto e época informados no JSON, etiquetada com prioridade 2.

## V.6 Considerações das Bases de Dados

A integração das diferentes bases de dados apresentadas neste capítulo foi fundamental para a construção de um sistema de recomendação agrícola robusto, confiável e contextualizado à realidade dos pequenos produtores do estado do Rio de Janeiro. Cada fonte contribuiu com um aspecto específico do processo decisório: os dados meteorológicos permitiram caracterizar o ambiente climático; os dados de produtividade forneceram evidências práticas do desempenho das culturas em diferentes regiões; os dados de solo possibilitaram compreender a aptidão edáfica das áreas analisadas; e, por fim, o manual técnico da Embrapa orientou a formulação das regras de recomendação aplicadas pelo motor de inferência. A combinação dessas fontes permitiu ao sistema oferecer recomendações técnicas personalizadas, fundamentadas tanto em conhecimento científico quanto em dados empíricos regionais.

## V.7 Arquitetura Tecnológica e Ferramentas

A solução foi construída em Python por combinar simplicidade sintática, ampla legibilidade e um ecossistema maduro para ciência de dados e automação, o que encurta a curva de desenvolvimento e facilita a manutenção. A inferência baseada em regras utiliza o PyKnow (um motor inspirado no CLIPS, integrado ao ecossistema Python) com encadeamento direto (*forward chaining*), permitindo declarar fatos e regras de forma transparente e rastreável: cada recomendação fica vinculada às condições que a ativaram, o que favorece auditoria e ajustes finos. O conhecimento agronômico é versionado em arquivos JSON, separando o conteúdo (condições, ações e metadados, como cultura e fonte técnica) do mecanismo de execução; com isso, atualizar ou acrescentar regras não exige refatoração do código, apenas revisão de conteúdo, o que reduz atrito operacional e o risco de regressão. A camada de dados emprega Pandas e NumPy para limpeza, padronização de unidades e junções entre fontes meteorológicas, de solo e de produtividade, garantindo que a lógica de regras receba tabelas consistentes e documentadas (por exemplo, evitando ambiguidades entre $\mathrm{cmol_c}, \mathrm{dm}^{-3}$ e $\mathrm{mg}, \mathrm{kg}^{-1}$). As saídas são geradas em HTML e gravadas em arquivos `.html`, possibilitando visualização imediata no navegador, impressão e compartilhamento digital sem dependências pesadas; quando necessário, a mesma estrutura é compatível com ferramentas como o PDFkit para exportação em PDF. O desenvolvimento ocorreu em ambiente local com Visual Studio Code, Git e Jupyter Notebooks durante a exploração inicial, o que favorece a reprodutibilidade (histórico de commits, diffs de regras JSON, notebooks com evidências) e a colaboração entre a equipe técnica e os especialistas de domínio.

## V.8 Execução dos Cenários de Teste

Para a validação do sistema de recomendação agrícola, foi elaborado um conjunto de cenários experimentais que representam diferentes condições, conforme apresentado na seção IV.8.

As recomendações geradas foram avaliadas por profissionais especializados em solos e agricultura, que revisaram os resultados com base nos critérios técnicos do Manual de Calagem e Adubação da Embrapa-RJ (2013) e em sua própria experiência prática em campo. A validação teve como foco:

- A coerência entre os dados de entrada e as recomendações emitidas;
- A correção das doses sugeridas de calagem e adubação;
- A clareza, a objetividade e a aplicabilidade prática das recomendações no contexto do pequeno produtor.

O parecer dos profissionais indicou que as recomendações estavam em conformidade com os parâmetros técnicos esperados e que o sistema pode servir como ferramenta complementar para apoio à

decisão agronômica, especialmente em ambientes de assistência técnica.

## V.9 Limitações Observadas

Durante os testes, foram identificadas algumas limitações relevantes, como a ausência de integração direta entre os dados climáticos e de produtividade com as regras de inferência, limitando a personalização mais profunda das recomendações.

O sistema depende da inserção manual da análise química do solo, o que pode restringir o uso entre produtores que não têm acesso a essa informação.

O PyKnow, embora eficaz e simples, pode apresentar limitações de desempenho em contextos com grande volume de regras ou com múltiplos ciclos inferenciais complexos.

Tais limitações não comprometem o funcionamento atual do sistema, mas apontam direções promissoras para evolução futura, como a integração com bancos de dados online, a introdução de lógica fuzzy para lidar com incertezas e o uso de aprendizado de máquina para complementar o sistema especialista.

# Capítulo VI Resultados

Este capítulo apresenta os resultados da validação do sistema de recomendação agrícola, conforme o protocolo descrito nos Capítulos IV e V. Foram avaliados 180 cenários de teste, conforme detalhamento descrito na seção IV.8. As saídas do sistema (*adubação* e *calagem*) foram comparadas a duas referências: (i) especialistas e (ii) resposta manual pautada no Manual de Adubação e Calagem.

Os especialistas que compuseram a referência humana são profissionais com atuação direta em pesquisa e assistência técnica em fertilidade do solo e manejo de nutrientes, incluindo pesquisadores, engenheiros de solos e engenheiros agrônomos com experiência em recomendação de adubação e calagem para condições edafoclimáticas do estado do Rio de Janeiro. Todos os avaliadores foram cegados em relação às respostas geradas pelo sistema, de modo a garantir independência na emissão dos pareceres e conferir maior robustez à comparação entre as recomendações automatizadas e o julgamento técnico especializado.

## VI.1 Protocolo de Avaliação

Cada um dos 180 cenários foi congelado antes da execução do sistema, garantindo que as entradas permanecessem idênticas para todas as comparações. Para cada cenário, coletaram-se as saídas do motor de inferência para as decisões de *Adubação* (aplicar ou não aplicar) e *Calagem* (necessária ou desnecessária) e essas saídas foram confrontadas com as duas referências humanas: especialistas cegados e cálculo manual baseado no *Manual de Adubação e Calagem*.

As decisões foram avaliadas como problemas binários, isto é, *Aplicar* vs. *Não aplicar* no caso da adubação e *Necessária* vs. *Desnecessária* no caso da calagem. A partir dessas comparações, foram construídas matrizes de confusão e calculadas as métricas de desempenho descritas na Seção VI.3. Em seguida, os resultados globais foram sintetizados em termos de acurácia, precisão, revocação (sensibilidade), F1-Score e coeficiente Kappa de Cohen.

## VI.2 Hipóteses e Critérios de Aceitação

Para tornar mais clara a interpretação dos resultados, explicitam-se as hipóteses estatísticas que orientam a avaliação do sistema. As metas mínimas refletem patamares usuais de qualidade em

sistemas de recomendação determinísticos para manejo de solo.

**H1 (Adubação)**: A acurácia do sistema na decisão *Aplicar vs. Não aplicar* é *superior a 90%.*

$H_0$: Acurácia $\leq$ 0,90 vs. $H_a$: Acurácia $>$ 0,90.

**H2 (Calagem)**: A acurácia do sistema na decisão *Necessária vs. Desnecessária* é *superior a 90%.*

$H_0$: Acurácia $\leq$ 0,90 vs. $H_a$: Acurácia $>$ 0,90.

**H3 (Adubação)**: A concordância além do acaso (*Kappa de Cohen*) é *pelo menos substancial.*

$H_0$: $\kappa \leq 0{,}80$ vs. $H_a$: $\kappa > 0{,}80$.

**H4 (Calagem)**: A concordância além do acaso (*Kappa de Cohen*) é *pelo menos substancial.*

$H_0$: $\kappa \leq 0{,}80$ vs. $H_a$: $\kappa > 0{,}80$.

*Racional:* 90% é a meta mínima de acurácia operacional adotada no estudo para decisões binárias; $\kappa = 0{,}80$ marca o início da faixa de *concordância substancial* na interpretação usual da métrica [Landis and Koch, 1977].

### VI.3 Métricas de Avaliação

A avaliação do desempenho do sistema de recomendação foi realizada a partir de métricas derivadas da matriz de confusão, que organiza os resultados da predição em quatro categorias principais. Os verdadeiros positivos (TP) correspondem às situações em que a recomendação emitida pelo sistema está correta e coincide com o julgamento do especialista. Os verdadeiros negativos (TN) representam os casos em que o sistema corretamente identifica que determinada recomendação não deve ser aplicada. Os falsos positivos (FP) referem-se às situações em que o sistema recomenda uma ação inadequada, configurando um erro por excesso. Por fim, os falsos negativos (FN) ocorrem quando o sistema deixa de emitir uma recomendação necessária, resultando em um erro por omissão. A partir dessas quantidades, é possível calcular diferentes métricas que sintetizam o desempenho geral do modelo.

A **acurácia** expressa a proporção de classificações corretas realizadas pelo sistema, combinando acertos positivos e negativos:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN}.$$

A **precisão** quantifica o quanto das recomendações positivas emitidas pelo sistema correspondem realmente a decisões corretas, sendo útil para analisar erros por excesso:

$$\text{Precisão} = \frac{TP}{TP + FP}.$$

A sensibilidade ou **revocação** (Recall) mede a capacidade do sistema de identificar corretamente

todos os casos que deveriam receber recomendação, enfatizando erros por omissão:

$$\text{Revocação} = \frac{TP}{TP + FN}.$$

O **F1-Score** combina precisão e revocação em uma média harmônica, equilibrando ambas as perspectivas e evitando interpretações enviesadas por métricas isoladas:

$$F1 = 2 \cdot \frac{\text{Precisão} \cdot \text{Revocação}}{\text{Precisão} + \text{Revocação}}.$$

Além dessas métricas clássicas, emprega-se também o coeficiente **Kappa de Cohen**, que avalia o grau de concordância entre o sistema e o especialista descontando o efeito do acordo ao acaso. Diferentemente da acurácia simples, o Kappa penaliza situações em que um alto desempenho aparente pode ser explicado apenas pela distribuição desigual das classes. As definições detalhadas e o procedimento de cálculo encontram-se na Seção VI.7.

A interpretação das métricas de avaliação adotadas neste estudo deve ser realizada à luz do contexto agronômico e do objetivo principal do sistema de recomendação. Diferentemente de problemas clássicos de classificação supervisionada, nos quais existe uma verdade previamente rotulada, as decisões de adubação e calagem envolvem julgamentos técnicos baseados em limiares normativos, margens de tolerância e interpretação especializada dos dados de solo. Assim, a avaliação realizada neste trabalho não busca estabelecer a corretude absoluta das recomendações, mas sim analisar o grau de alinhamento entre as decisões geradas pelo sistema e aquelas emitidas por especialistas humanos, bem como sua aderência ao conhecimento formalizado no Manual de Adubação e Calagem.

Nesse contexto, as métricas derivadas da matriz de confusão assumem significados distintos. Um falso positivo ocorre quando o sistema recomenda uma prática que o especialista não indicaria, enquanto um falso negativo representa a ausência de recomendação em um cenário no qual o especialista considera a prática necessária. Do ponto de vista agronômico, esses dois tipos de erro possuem impactos diferentes. Em geral, falsos negativos tendem a ser mais críticos, pois podem resultar na omissão de práticas corretivas essenciais, como a calagem em solos ácidos ou a adubação em condições de deficiência nutricional, comprometendo a produtividade e a sustentabilidade do sistema produtivo. Falsos positivos, por sua vez, embora indesejáveis, tendem a gerar impactos menos severos, estando mais associados a custos adicionais ou a aplicações conservadoras, desde que respeitados os limites técnicos e ambientais.

Essa assimetria justifica a ênfase dada a métricas como a revocação, especialmente no caso da calagem, na qual a revocação igual a 1,0 indica que o sistema não deixou de recomendar a prática em nenhum dos casos em que a referência humana a considerou necessária. Ao mesmo tempo, a precisão elevada observada em ambas as decisões demonstra que o sistema raramente recomenda

práticas quando elas não são indicadas pelos especialistas, evidenciando um equilíbrio adequado entre cautela e cobertura.

Além disso, a utilização do coeficiente Kappa de Cohen complementa a análise ao descontar o efeito do acordo ao acaso, permitindo avaliar a concordância real entre o sistema e os especialistas. Dessa forma, o conjunto de métricas adotado fornece uma visão abrangente do desempenho do sistema, não apenas em termos de acerto bruto, mas principalmente quanto à consistência e ao alinhamento com o julgamento técnico humano. Esse enfoque é particularmente adequado para sistemas de recomendação baseados em regras agronômicas, nos quais a transparência, a interpretabilidade e a aderência ao conhecimento especializado são tão relevantes quanto a maximização de métricas tradicionais de classificação.

### VI.4 Procedimento de Teste de Hipóteses

Para as hipóteses baseadas em acurácia (H1 e H2), utilizou-se o teste de proporção unilateral (*binomial exato* ou aproximação normal com correção de continuidade) para verificar se a proporção de acertos do sistema é maior que 0,90. Intervalos de confiança de 95% foram estimados pelo método de Wilson, a fim de fornecer uma faixa de incerteza mais estável para proporções próximas de 0 ou 1.

Para as hipóteses baseadas no coeficiente Kappa de Cohen (H3 e H4), empregou-se a aproximação normal para $\kappa$ com variância assintótica, conforme proposto por Fleiss, testando-se $H_0 : \kappa \leq 0{,}80$ contra $H_a : \kappa > 0{,}80$ por meio de estatística-$z$ e intervalos de confiança de 95%. Essa abordagem permite avaliar se a concordância observada pode ser interpretada como substancial ou superior mesmo após o desconto do acordo esperado ao acaso.

### VI.5 Resultados dos Testes (Síntese)

Com base nas matrizes de confusão obtidas e nas métricas calculadas, tem-se a seguinte síntese dos testes de hipóteses:

- **Adubação**: acurácia igual a 0,989 (178 acertos em 180 cenários). O teste unilateral contra 0,90 resultou em $p < 0{,}001$, o que leva à **aceitação de H1**. O coeficiente Kappa foi aproximadamente 0,894, e o teste contra 0,80 também resultou em $p < 0{,}001$, implicando **aceitação de H3**.

- **Calagem**: acurácia igual a 0,967 (174 acertos em 180 cenários). O teste unilateral contra 0,90 também resultou em $p < 0{,}001$, levando à **aceitação de H2**. O coeficiente Kappa foi aproximadamente 0,918, com $p < 0{,}001$ para o teste contra 0,80, implicando **aceitação de H4**.

Esses resultados confirmam desempenho elevado, com acurácias próximas de 100% e concordância substancial a quase perfeita com a referência humana, coerentes com as análises detalhadas apresentadas nas seções seguintes.

### VI.6 Cálculo das Métricas: Acurácia, Precisão, Revocação e F1

As decisões de *Adubação* e *Calagem* foram avaliadas como problemas binários. Para cada cenário, definiu-se a seguinte matriz de confusão $2 \times 2$ (Sistema nas linhas; Referência nas colunas):

| | Ref: Positivo | Ref: Negativo |
|---|---|---|
| Sis: Positivo | $TP$ | $FP$ |
| Sis: Negativo | $FN$ | $TN$ |

$$N = TP + FP + FN + TN.$$

#### Adubação

Para a decisão *Aplicar* vs. *Não aplicar*, a matriz observada ($N = 180$) foi:

| | Ref: Aplica | Ref: Não aplica |
|---|---|---|
| Sis: Aplica | 169 | 0 |
| Sis: Não aplica | 2 | 9 |

A partir dessa matriz, obtêm-se:

$$\text{Acurácia} = \frac{169 + 9}{180} = 0{,}989, \quad \text{Precisão} = \frac{169}{169 + 0} = 1,$$

$$\text{Revocação} = \frac{169}{169 + 2} = 0{,}988, \quad F1 = \frac{2 \cdot 1 \cdot 0{,}988}{1 + 0{,}988} = 0{,}994.$$

#### Calagem

Para a decisão *Necessária* vs. *Desnecessária*, a matriz observada ($N = 180$) foi:

| | Ref: Necessária | Ref: Desnecessária |
|---|---|---|
| Sis: Necessária | 126 | 6 |
| Sis: Desnecessária | 0 | 48 |

Os valores resultantes são:

$$\text{Acurácia} = \frac{126 + 48}{180} = 0{,}967, \quad \text{Precisão} = \frac{126}{126 + 6} = 0{,}955,$$

$$\text{Revocação} = \frac{126}{126+0} = 1, \quad F1 = \frac{2 \cdot 0{,}955 \cdot 1}{0{,}955+1} = 0{,}977.$$

As métricas próximas de 1,0 (ou 100%) indicam alto desempenho. Em particular, a revocação elevada mostra baixa taxa de falsos negativos (raramente o sistema deixa de recomendar quando a referência recomendaria), enquanto a precisão elevada mostra baixa taxa de falsos positivos (raramente o sistema recomenda quando a referência não recomendaria). O F1 resume esse equilíbrio.

## VI.7 Cálculo do Kappa de Cohen

O coeficiente de Kappa de Cohen ($\kappa$) foi utilizado para quantificar a concordância entre as decisões do sistema e a referência humana, além do acaso, nas macrolinhas de decisão **Adubação** (aplicar vs. não aplicar) e **Calagem** (necessária vs. desnecessária). Em ambos os casos, tratam-se de variáveis categóricas binárias.

### Definições e Fórmulas

Para cada matriz de confusão, com total $N = TP + FP + FN + TN$, a proporção de acordo observado é dada por:

$$P_o = \frac{TP + TN}{N}.$$

As proporções marginais para o sistema ($S$) e a referência ($R$) são:

$$p_+^{(S)} = \frac{TP + FP}{N}, \quad p_-^{(S)} = \frac{FN + TN}{N},$$

$$p_+^{(R)} = \frac{TP + FN}{N}, \quad p_-^{(R)} = \frac{FP + TN}{N}.$$

O acordo esperado ao acaso é calculado por:

$$P_e = p_+^{(S)}\, p_+^{(R)} + p_-^{(S)}\, p_-^{(R)},$$

e o coeficiente Kappa é então:

$$\kappa = \frac{P_o - P_e}{1 - P_e}.$$

### Adubação

Utilizando a matriz de adubação:

| | Ref: Aplica | Ref: Não aplica |
|---|---|---|
| Sis: Aplica | 169 | 0 |
| Sis: Não aplica | 2 | 9 |

$(N = 180)$,

obtêm-se:

$$P_o = \frac{169+9}{180} = 0{,}9889, \quad p_+^{(S)} = \frac{169+0}{180} = 0{,}9389, \quad p_+^{(R)} = \frac{169+2}{180} = 0{,}9500,$$

$$p_-^{(S)} = \frac{2+9}{180} = 0{,}0611, \quad p_-^{(R)} = \frac{0+9}{180} = 0{,}0500,$$

$$P_e = 0{,}9389 \cdot 0{,}9500 + 0{,}0611 \cdot 0{,}0500 = 0{,}8950,$$

e, por fim,

$$\kappa = \frac{0{,}9889 - 0{,}8950}{1 - 0{,}8950} = 0{,}8942.$$

**Calagem**

Para a calagem:

| | Ref: Necessária | Ref: Desnecessária |
|---|---|---|
| Sis: Necessária | 126 | 6 |
| Sis: Desnecessária | 0 | 48 |

$(N = 180)$,

obtêm-se:

$$P_o = \frac{126+48}{180} = 0{,}9667, \quad p_+^{(S)} = \frac{126+6}{180} = 0{,}7333, \quad p_+^{(R)} = \frac{126+0}{180} = 0{,}7000,$$

$$p_-^{(S)} = \frac{0+48}{180} = 0{,}2667, \quad p_-^{(R)} = \frac{6+48}{180} = 0{,}3000,$$

$$P_e = 0{,}7333 \cdot 0{,}7000 + 0{,}2667 \cdot 0{,}3000 = 0{,}5933,$$

e

$$\kappa = \frac{0{,}9667 - 0{,}5933}{1 - 0{,}5933} = 0{,}9180.$$

Em ambos os casos, os valores de $\kappa$ situam-se na faixa de 0,89–0,92, indicando concordância *substancial* a *quase perfeita* entre o sistema e a referência, segundo a interpretação clássica de Landis and Koch [1977].

## VI.8 Resultados Globais

Cabe destacar que o sistema de recomendação desenvolvido consiste em uma implementação algorítmica determinística das regras contidas no *Manual de Adubação e Calagem*. Dessa forma, a comparação direta entre o sistema e o manual resulta, por construção, em concordância perfeita, não acrescentando informação relevante do ponto de vista experimental. Assim, a avaliação dos

resultados concentra-se na comparação entre as recomendações geradas pelo sistema e o julgamento dos especialistas humanos, o que equivale, conceitualmente, à análise da concordância entre os especialistas e o próprio manual.

A Tabela VI.1 apresenta os resultados globais agregados para os 180 cenários avaliados, considerando as decisões de adubação e calagem. Observa-se desempenho elevado em ambas as macrolinhas de decisão, com acurácia superior a 96% e coeficientes Kappa de Cohen situados na faixa de concordância substancial a quase perfeita. Esses resultados indicam forte alinhamento entre o conhecimento técnico formalizado nas regras e a prática especializada adotada pelos avaliadores humanos.

Tabela VI.1: Resultados globais consolidados da concordância entre o sistema (manual algorítmico) e especialistas em 180 cenários.

| **Decisão** | **Acurácia** | **Precisão** | **Revocação** | **F1** | **Kappa de Cohen** | **n** |
|---|---|---|---|---|---|---|
| Adubação | 0,989 | 1,000 | 0,988 | 0,994 | 0,894 | 180 |
| Calagem | 0,967 | 0,955 | 1,000 | 0,977 | 0,918 | 180 |

As divergências residuais observadas concentram-se principalmente em cenários de fronteira, nos quais os valores de atributos como pH, alumínio trocável, fósforo disponível ou a soma de Ca+Mg situam-se próximos aos limiares definidos pelas regras de decisão. Nesses casos, pequenas variações nos dados de entrada podem levar a interpretações distintas entre o sistema e os especialistas, o que é consistente com a natureza determinística dos limiares adotados e com a sensibilidade do julgamento técnico humano.

### VI.9 Resultados por Tipo de Recomendação

A desagregação dos resultados por macroclasse de decisão evidencia comportamento consistente entre adubação e calagem, conforme apresentado na Tabela VI.1. No caso da adubação, o sistema apresentou elevada precisão e revocação, indicando baixa incidência tanto de falsos positivos quanto de falsos negativos, com divergências concentradas em cenários com teores de fósforo próximos aos valores limítrofes de decisão.

Para a calagem, observa-se revocação igual a 1,0, evidenciando que o sistema não deixou de recomendar a prática em nenhum dos casos em que a referência humana a considerou necessária. As discordâncias residuais ocorreram majoritariamente em situações em que indicadores de acidez, como alumínio trocável e a soma de Ca+Mg, encontravam-se muito próximos às fronteiras estabelecidas pelas regras, o que reforça a coerência dos resultados com a lógica agronômica subjacente e com a variabilidade inerente às análises de solo.

### VI.10 Desempenho e Robustez Computacional

O tempo médio para processar um cenário (motor de regras mais formatação do relatório) foi de aproximadamente **0,4 s** em ambiente local, utilizando Python e PyKnow. Não foram observadas falhas de execução nos 180 cenários após o congelamento dos dados de entrada, o que sugere robustez operacional da implementação no contexto experimental considerado.

### VI.11 Ameaças à Validade

Algumas ameaças à validade dos resultados merecem destaque. Em primeiro lugar, mesmo entre especialistas há variação residual de julgamento, tratada por meio do coeficiente Kappa, mas ainda assim presente nas comparações. Em segundo lugar, valores de atributos próximos aos limiares de decisão amplificam divergências, tanto pela natureza discreta das regras quanto pela própria imprecisão inerente às medidas laboratoriais e aos processos de amostragem de solo. Em terceiro lugar, quanto à generalização, embora os cenários cubram múltiplos municípios do estado do Rio de Janeiro, o desempenho em outras regiões dependerá da disponibilidade e da qualidade dos dados locais, bem como da adequada parametrização das regras e faixas de recomendação para outras condições edafoclimáticas.

### VI.12 Síntese dos Resultados

Em síntese, o sistema apresentou acurácia global superior a 96% e coeficientes Kappa entre aproximadamente 0,89 e 0,92 nas decisões de adubação e calagem, quando comparado tanto a especialistas quanto ao manual de referência. As divergências remanescentes concentram-se em cenários de fronteira, nos quais pequenas variações em atributos de solo podem levar a decisões distintas, o que é coerente com a natureza determinística do motor de regras. Esses resultados sustentam a viabilidade do uso do sistema como apoio à decisão técnica em contextos com dados de solo georreferenciados e regras de recomendação explicitadas.

### VI.13 Relatório Gerado

Um exemplo de relatório completo, com as recomendações produzidas pelo sistema, encontra-se no Apêndice B. O relatório ilustrativo refere-se ao município de Sumidouro e contém duas seções principais: uma seção contextual, com gráficos e análises resumidas sobre produtividade e clima, e uma seção técnica, com recomendações específicas extraídas pelo motor de inferência. Todas as recomendações são acompanhadas de justificativas técnicas, fundamentadas nas regras ativadas e nos dados de entrada fornecidos, de modo a favorecer a interpretabilidade e a transparência das decisões geradas pelo sistema.

# Capítulo VII Considerações Finais

Os desafios enfrentados pela agricultura brasileira, especialmente entre pequenos e médios produtores, envolvem a necessidade de conciliar produtividade, sustentabilidade e uso racional de insumos em um cenário de grande variabilidade edafoclimática. A tomada de decisão sobre práticas, como a escolha de culturas, adubação e calagem, exige o cruzamento de informações de solo, clima e manejo, o que muitas vezes ultrapassa a capacidade de análise técnica disponível no campo. Essa realidade evidencia uma lacuna entre o conhecimento agronômico consolidado nas instituições de pesquisa e sua aplicação prática nas propriedades rurais, o que motiva o desenvolvimento de soluções tecnológicas capazes de traduzir o conhecimento científico em recomendações acessíveis e contextualizadas.

Diante desse cenário, esta dissertação abordou o desenvolvimento de um sistema de recomendação agrícola híbrido, explicável e orientado a dados regionais, com o objetivo de apoiar a agricultura familiar e contribuir para a democratização da agricultura digital. A solução proposta combina um motor de inferência baseado em regras explícitas com dados padronizados de solo e de clima, permitindo gerar recomendações técnicas fundamentadas em fontes oficiais, como o Manual de Adubagem e Calagem para o Estado do Rio de Janeiro. A metodologia empregada integra a engenharia do conhecimento, técnicas de ciência de dados e validação experimental com especialistas, assegurando a consistência e a interpretabilidade dos resultados.

Os experimentos conduzidos demonstraram que o sistema atinge elevada concordância com especialistas humanos e com as recomendações oficiais, apresentando desempenho consistente em múltiplos municípios e cenários edafoclimáticos distintos. A arquitetura híbrida mostrou-se eficaz na representação do raciocínio agronômico e na reprodutibilidade das decisões técnicas, evidenciando o potencial do sistema como ferramenta prática de apoio à tomada de decisão. Embora existam limitações relacionadas à sensibilidade dos limiares analíticos e à cobertura das bases regionais, o arcabouço proposto é sólido e extensível, oferecendo suporte a futuras expansões geográficas, aprimoramentos lógicos e a integração de componentes preditivos.

De forma mais ampla, este trabalho reforça a relevância da inteligência artificial explicável e dos sistemas de recomendação como instrumentos para promover uma agricultura mais sustentável, transparente e inclusiva. A explicabilidade da solução proposta decorre do uso de um motor de inferência baseado em regras explícitas, extraídas de normas técnicas consolidadas, no qual cada recomendação gerada pode ser diretamente associada às condições de entrada que a dispararam e

às regras agronômicas correspondentes. Essa característica permite que o usuário compreenda não apenas o que foi recomendado, mas também por que determinada decisão foi tomada, favorecendo a confiança, a validação técnica e a adoção prática das orientações no campo. Ao aproximar o conhecimento técnico formalizado das práticas cotidianas dos produtores, a solução contribui para a redução de custos, o uso mais eficiente de insumos e a preservação dos recursos naturais, alinhando-se aos Objetivos de Desenvolvimento Sustentável (ODS 2, 9 e 12).

## VII.1 Trabalhos Futuros

A continuidade desta pesquisa envolve múltiplas frentes de aprimoramento. Em primeiro lugar, prevê-se o refinamento progressivo das regras de inferência, incorporando faixas de transição e mecanismos de histerese que representem melhor os gradientes entre classes agronômicas, reduzindo a rigidez dos limiares e ampliando a fidelidade das recomendações. Também se planeja a adoção de abordagens de aprendizado ativo (*active learning*) sobre os casos residuais, nos quais o sistema e os especialistas divergem. Essa estratégia permitirá priorizar os cenários mais informativos para o ajuste das regras, acelerando a evolução do sistema e tornando-o cada vez mais alinhado à prática agrícola.

Outra linha promissora é a incorporação da quantificação de incertezas, com a anexação de intervalos de confiança ou escores de robustez às recomendações geradas. Isso permitirá que o usuário compreenda o grau de confiabilidade de cada inferência, orientando o planejamento de análises complementares em campo. Em paralelo, pretende-se expandir a aplicação do sistema para outras regiões do país, avaliando sua robustez sob diferentes condições edafoclimáticas, protocolos laboratoriais e padrões de manejo. Esse processo de escalonamento contribuirá para consolidar uma plataforma nacional de apoio à decisão agrícola baseada em conhecimento e dados abertos.

Uma perspectiva de evolução natural é a integração de modelos climáticos preditivos e índices agrometeorológicos, como a evapotranspiração de referência (ETo) e o balanço hídrico, de modo a tornar as recomendações sensíveis ao tempo e às janelas ideais de plantio. A interface do sistema também deve evoluir para formatos interativos e explicáveis, com trilhas de justificativas (why/why not) que facilitem o uso por técnicos de extensão rural e produtores. Tais avanços reforçarão o papel do sistema como tecnologia de fronteira para a sustentabilidade agrícola, combinando ciência de dados, inteligência artificial e governança da informação para fortalecer a agricultura familiar e o uso responsável dos recursos naturais.

Embora esta dissertação apresente o fluxo completo de extração, transformação e carregamento dos dados do BDSolos para a plataforma MultiSoils, conforme ilustrado na Figura V.5, o sistema de recomendação desenvolvido não utilizou o MultiSoils como repositório operacional nesta versão inicial. O MultiSoils constitui um ambiente significativamente mais adequado para hospedar sis-

temas de recomendação agrícola baseados em conhecimento, pois foi concebido para atuar como um sistema especialista orientado à organização e padronização de dados de solo. A plataforma oferece um conjunto robusto de mecanismos de governança, incluindo metadados estruturados, padronização de atributos físico-químicos, integração nativa com fontes institucionais e mecanismos de validação e versionamento. Sua arquitetura favorece a consistência e a rastreabilidade das informações, permitindo que análises laboratoriais, dados meteorológicos e características edáficas sejam unificados em um mesmo modelo conceitual, criando um ambiente altamente propício para aplicações inferenciais e preditivas.

Nesse sentido, a integração plena do sistema de recomendação com o MultiSoils configura-se como uma evolução natural e desejável deste trabalho. Ao migrar o repositório de dados para a plataforma, o sistema passará a operar sobre uma camada unificada, semanticamente enriquecida e preparada para expansão, o que permitirá recomendações mais contextualizadas e precisas, além de facilitar a incorporação de novos conjuntos de dados e de indicadores derivados. A utilização do MultiSoils também reforça o alinhamento desta pesquisa com as diretrizes contemporâneas da agricultura digital, que exigem ambientes de dados organizados, interoperáveis e capazes de sustentar aplicações computacionais avançadas.

## Referências

Adomavicius, G. and Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6):734–749.

Adomavicius, G. and Tuzhilin, A. (2011). *Context-Aware Recommender Systems*, pages 217–253. Springer US, Boston, MA.

Agegnehu, G., Amede, T., Desta, G., Erkossa, T., Legesse, G., Gashaw, T., Van Rooyen, A., Harawa, R., Degefu, T., Mekonnen, K., et al. (2023). Improving fertilizer response of crop yield through liming and targeting to landscape positions in tropical agricultural soils. *Heliyon*, 9(6).

Almulla, M. A. (2025). A novel clips-based medical expert system for migraine diagnosis and treatment recommendation. *Kuwait Journal of Science*, 52.

Alves, E. R., Oliveira, M. F., Costa, R. N., and Vieira, C. A. (2020). Efeito da utilização de assistência técnica sobre a renda de produtores familiares do brasil no ano de 2014. *Revista de Economia e Sociologia Rural*, 58(1):1–18.

Banerjee, G., Sarkar, U., and Ghosh, I. (2021). A fuzzy logic-based crop recommendation system. *Advances in Intelligent Systems and Computing*, 1255:57–69.

Bazire, M. and Brézillon, P. (2005). Understanding context before using it. In *Proceedings of the 5th International Conference on Modeling and Using Context*, CONTEXT'05, page 29–40, Berlin, Heidelberg. Springer-Verlag.

Bechar, A. and Vigneault, C. (2016). Agricultural robots for field operations: Concepts and components. *Biosystems Engineering*, 149:94–111.

Bin, L., Shahzad, M., Khan, H., Bashir, M. M., Ullah, A., and Siddique, M. (2023). Sustainable smart agriculture farming for cotton crop: A fuzzy logic rule based methodology. *Sustainability (Switzerland)*, 15.

Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46:109–132.

Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4):331–370.

Burke, R. (2007). *Hybrid Web Recommender Systems*, pages 377–408. Springer Berlin Heidelberg, Berlin, Heidelberg.

Carlsen, L. and Bruggemann, R. (2022). The 17 united nations' sustainable development goals: A status by 2020. *International Journal of Sustainable Development & World Ecology*, 29(3):219–229.

Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1):37–46.

Cohen, J. (1968). Weighted kappa: Nominal scale agreement with provision for scaled disagreement or partial credit. *Psychological Bulletin*, 70(4):213–220.

Corno, F., Russis, L. D., and Roffarello, A. M. (2019). Recrules: Recommending if-then rules for end-user development. *ACM Transactions on Intelligent Systems and Technology*, 10.

Deldjoo, Y., Schedl, M., Cremonesi, P., and Pasi, G. (2020). Recommender systems leveraging multimedia content. *ACM Comput. Surv.*, 53(5).

Diniz, A. F. (2016). Variabilidade climática e sua influência na produtividade agrícola: estudo de caso no estado de são paulo. Master's thesis, Universidade de São Paulo, São Paulo.

EMATER-Rio (2024). Acompanhamento sistemático da produtividade agrícola - aspa. `https://www.emater.rj.gov.br`. Base de dados interna fornecida pela EMATER-Rio, com registros de produtividade agrícola por município no estado do Rio de Janeiro para os anos de 2021 a 2023.

EMBRAPA Solos (2013). *Manual de calagem e adubação do Estado do Rio de Janeiro.* LUIZ RODRIGUES FREIRE, Rio de Janeiro, RJ, 1º edition. Produtividade vegetal e fertilidade do solo; Principais classes de solo do Estado do Rio de Janeiro; Fertilidade do solo; Análise química de amostras de terra; Adubos e corretivos; Aplicação de adubos; Uso e manejo da matéria orgânica para fins de fertilidade do solo; Insumos biológicos; Manejo da fertilidade do solo na agricultura orgânica; Cultivo protegido; Cultivo hidropônico; Critérios econômicos relacionados com a seleção de adubos e corretivos; Recomendações gerais; Recomendações de adubos, corretivos e de manejo da matéria orgânica para as principais culturas do Estado do Rio de Janeiro.

EMBRAPA Solos (2024). Banco de Dados de Solos do Brasil - BDSolos. `https://www.bdsolos.cnptia.embrapa.br/consulta_publica.html`. Base nacional de perfis de solos contendo informações químicas, físicas e morfológicas de amostras coletadas em diversas regiões do Brasil.

Fountas, S., Carli, G., Sørensen, C. A. G., Tsiropoulos, Z., Cavalaris, C., Vatsanidou, A., Liakos, V., Canavari, M., Wiebensohn, J., and Tisserye, B. (2015). Farm management information systems: Current situation and future perspectives. *Computers and Electronics in Agriculture*, 115:40–50.

Freire, L. R., Balieiro, F. C., Zonta, E., Anjos, L. H. C. d., Pereira, M. G., and Lima, E. P. d. (2013). *Manual de Calagem e Adubação do Estado do Rio de Janeiro*. Embrapa; Universidade Federal Rural do Rio de Janeiro, Brasília, DF; Seropédica, RJ.

Friedman-Hill, E. (2003). *Jess in Action: Java Rule-Based Systems*. Manning Publications.

Gary Riley (2024). *CLIPS Reference Manual*. NASA - Johnson Space Center, version 6.4 edition. Sistema de produção baseado em regras para construção de sistemas especialistas.

Gebremariam, B. M., Aboye, G. T., Dessalegn, A. A., and Simegn, G. L. (2024). Rule-based expert system for the diagnosis of maternal complications during pregnancy: For low resource settings. *Digital Health*, 10.

Giarratano, J. C. and Riley, G. D. (2005). *Expert Systems: Principles and Programming*. Brooks/-Cole Publishing Co., USA.

Grant, M. J. and Booth, A. (2009). A typology of reviews: an analysis of 14 review types and associated methodologies. *Health Information & Libraries Journal*, 26(2):91–108.

Guan, C., Qin, S., Ling, W., and Ding, G. (2016). Apparel recommendation system evolution: an empirical review. *International Journal of Clothing Science and Technology*, 28(6):854–879.

Hansen, J. W. (2005). Integrating seasonal climate prediction and agricultural models for insights into agricultural practice. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 360(1463):2037–2047.

Hariri, N., Mobasher, B., and Burke, R. (2012). Context-aware music recommendation based on latenttopic sequential patterns. In *Proceedings of the Sixth ACM Conference on Recommender Systems*, RecSys '12, page 131–138, New York, NY, USA. Association for Computing Machinery.

He, X., Liao, L., Zhang, H., Nie, L., Hu, X., and Chua, T.-S. (2017). Neural collaborative filtering. In *Proceedings of the 26th International Conference on World Wide Web (WWW)*, pages 173–182.

Hinojosa, C., García, F., López, J., and Pérez, M. (2023). Agrotic: Bridging the gap between farmers, agronomists, and merchants through smartphones and machine learning. *arXiv preprint arXiv:2305.12418*.

Hundal, G. S., Laux, C. M., Buckmaster, D., Sutton, M. J., and Langemeier, M. (2023). Exploring barriers to the adoption of internet of things-based precision agriculture practices. *Agriculture*, 13(1):163.

Instituto Nacional de Meteorologia (INMET) (2025). Banco de dados meteorológicos para ensino e pesquisa. `https://portal.inmet.gov.br/dadoshistoricos/`. Dados horários e diários das estações meteorológicas automáticas do INMET distribuídas em todo o território nacional, incluindo temperatura, umidade, precipitação, pressão atmosférica e vento.

Jannach, D., Zanker, M., Felfernig, A., and Friedrich, G. (2011). *Recommender Systems: An Introduction*. Cambridge University Press.

Kamilaris, A. and Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147:70–90.

Khalil, H. A., Hossain, M. S., Rosamah, E., Azli, N., Saddon, N., Davoudpoura, Y., Islam, M. N., and Dungani, R. (2015). The role of soil properties and it's interaction towards quality plant fiber: A review. *Renewable and Sustainable Energy Reviews*, 43:1006–1015.

Koren, Y. and Bell, R. (2015). Advances in collaborative filtering. pages 77–118.

Landis, J. R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1):159–174.

Lops, P., de Gemmis, M., and Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. pages 73–105.

Lu, J., Wu, D., Mao, M., Wang, W., and Zhang, G. (2015). Recommender system application developments: a survey. *Decision support systems*, 74:12–32.

Luger, G. F. (2008). *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*. Addison-Wesley Publishing Company, USA, 6th edition.

Madhumathi, R., Arumuganathan, T., and Shruthi, R. (2022). Soil nutrient detection and recommendation using iot and fuzzy logic. *Computer Systems Science and Engineering*, 43:455–469.

Manoharan, G., Durai, S., Rajesh, G. A., and Ashtikar, S. P. (2023). A study on the application of expert systems as a support system for business decisions: A literature review. *Artificial Intelligence and Knowledge Processing*, pages 279–289.

Martinelli, L. A., Naylor, R., Vitousek, P. M., and Moutinho, P. (2010). Agriculture in brazil: impacts, costs, and opportunities for a sustainable future. *Current Opinion in Environmental Sustainability*, 2(5-6):431–438.

Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill, Inc., USA, 1 edition.

Narayana, P. and Saxena, S. (2023). Online crop doctor using machine learning and deep learning. In *Proceedings of the 2nd International Conference on Applied Artificial Intelligence and Computing, ICAAIC 2023*, pages 1653–1659. Institute of Electrical and Electronics Engineers Inc.

OpenL Tablets (2024). OpenL Tablets: Business Rules and Decision Tables. https://openl-tablets.org/. Acesso em: Junho 2024.

Papadopoulos, P., Soflano, M., Chaudy, Y., Adejo, W., and Connolly, T. M. (2022). A systematic review of technologies and standards used in the development of rule-based clinical decision support systems. *Health and Technology*, 12(4):713–727.

Pazzani, M. J. and Billsus, D. (2007). Content-based recommendation systems. *The Adaptive Web*, 4321:325–341.

Proctor, M., Neale, M., and Frandsen, M. (2012). *Drools Developer's Cookbook*. Packt Publishing.

Pudumalar, S., Ramanujam, E., Rajashree, R., Kavya, C., Kiruthika, T., and Nisha, J. (2017). Crop recommendation system for precision agriculture. In *2016 8th International Conference on Advanced Computing, ICoAC 2016*, page 32 – 36.

Raveena, S. and Surendran, R. (2023). Hybridized rule-based recommendation system for sustainable and synthetic fertilizers in coffee plantation. In *2023 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies, 3ICT 2023*, pages 242–248. Institute of Electrical and Electronics Engineers Inc.

Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., and Riedl, J. (1994). Grouplens: An open architecture for collaborative filtering of netnews. In *Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work*, pages 175–186.

Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B. (2011). *Recommender Systems Handbook*. Springer.

Riley, G. (1994). Clips: The c language integrated production system. In *Dual-Use Space Technology Transfer Conference and Exhibition, Volume 2*.

Riley, G. (2006). *CLIPS Reference Manual*. NASA Johnson Space Center. Acesso em: Junho 2024.

Riley, G. (2024). CLIPS: A Tool for Building Expert Systems. `https://www.clipsrules.net`. Acesso em: Junho 2024.

Russell, S. and Norvig, P. (2009). *Artificial Intelligence: A Modern Approach*. Prentice Hall Press, USA, 3rd edition.

Sarwar, B., Karypis, G., Konstan, J., and Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. In *Proceedings of the 10th International Conference on World Wide Web*, pages 285–295.

Schemberger, E. S., Fontana, F. S., Johann, J. A., and de Souza, E. G. (2017). Data mining for the assessment of management areas in precision agriculture. *Engenharia Agrícola*, 37(1):185–193.

Shah, F. and Wu, W. (2019). Soil and crop management strategies to ensure higher crop productivity within sustainable environments. *Sustainability*, 11(5):1485.

Sharma, K., Mandal, B., and Venkateswarlu, B. (2012). Soil quality and productivity improvement under rainfed conditions–indian perspectives. *Resource management for sustainable agriculture*, pages 203–230.

Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., and Jiang, P. (2019). Bert4rec: Sequential recommendation with bidirectional encoder representations from transformer. In *Proceedings of the 28th ACM international conference on information and knowledge management*, pages 1441–1450.

Thorat, P. B., Goudar, R. M., and Barve, S. (2015). Survey on collaborative filtering, content-based filtering and hybrid recommendation system. *International Journal of Computer Applications*, 110(4).

Werneck, R. (2018). Pyknow: Expert systems for python. `https://github.com/buguroo/pyknow`. Biblioteca Python para construção de sistemas especialistas baseada em regras, inspirada no CLIPS.

Wolfert, S., Ge, L., Verdouw, C., and Bogaardt, M. (2017). Big data in smart farming – a review. *Agricultural Systems*, 153:69–80.

Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., and Yu, P. S. (2021). A comprehensive survey on graph neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, 32(1):4–24.

Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.

Zhai, Y., Wang, L., Gu, X., Zhao, X., and Liu, J. (2021). Inovações na agricultura orgânica: revisão sistemática e perspectivas futuras. *Revista de Economia e Sociologia Rural*, 59(3):1–20.

Zhang, N., Wang, M., and Wang, N. (2002). Precision agriculture – a worldwide overview. *Computers and Electronics in Agriculture*, 36(2-3):113–132.

Zhang, S., Yao, L., Sun, A., and Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1).

# Apêndice A - Cenários de Teste

Tabela A.1: Amostra dos cenários de teste realizados

| **Uso Atual** | **Município** | **Classe de Textura** | **pH ($H_2O$)** | **Cálcio (cmolc/kg)** | **Magnésio (Mg)** | **Potássio (cmolc/kg) (K)** | **Alumínio ($Al^{3+}$)** | **Fósforo (mg/kg) (P)** | **Cultura** |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem | Araruama | Muito argilosa (argila pesada) | 4,9 | 4,5 | 4,6 | 0,1 | 0 | 1 | Cana-de-açúcar |
| Pomar de citrus e pastagem. | Araruama | Franco-argilo-arenosa | 5,4 | 0,9 | 0,5 | 0,05 | 0 | 1 | Mandioca |
| Pomar de citrus e pastagem. | Araruama | Argilo-arenosa | 5,8 | 1 | 0,5 | 0,03 | 0 | 1 | Quiabo |
| Pastagem plantada. | Araruama | Argilo-siltosa | 4,5 | 2 | 0,8 | 0,08 | 49 | 4 | Abóbora, abobrinha e moranga |
| Cítricas | Araruama | Franco-arenosa | 4,8 | 2 | 0,2 | 0,06 | 4 | 2 | Feijão-mauá |
| Pastagem natural. | Araruama | Muito argilosa (argila pesada) | 4,9 | 4,5 | 4,6 | 0,1 | 0 | 1 | Batata-doce |
| Pastagem plantada (brachiaria). | Araruama | Areia-franca | 5 | 1,4 | 0,2 | 0,15 | 0 | 4 | Coco |
| Nenhum. | Araruama | Franco-arenosa | 5,2 | 2,5 | 0,4 | 0,06 | 4 | 1 | Maracujá |
| Nenhum. | Araruama | Argilo-arenosa | 4,8 | 1,3 | 1,5 | 0,13 | 21 | 1 | Melancia e melão |
| Nenum. | Araruama | Franco-arenosa | 5 | 2,8 | 5,4 | 0,07 | 0 | 4 | Milho |
| Nenum. | Araruama | Franco-argilo-arenosa | 5,9 | 3,2 | 7,2 | 0,03 | 1 | 1 | Sorgo granífero |
| Pastagem de colonião. | Araruama | Franco-arenosa | 5,5 | 4,8 | 1,9 | 0,35 | 0 | 4 | Soja |
| cultura de citros. | Cabo Frio | Franco-argilo-arenosa | 4,6 | 0,3 | 0,2 | 0,05 | 1 | 2 | Milho |
| pastagem plantada de capim-colonião. | Cabo Frio | Areia | 8 | 1,9 | 0,3 | 0,04 | 0 | 10 | Cítricas |
| pastagem. | Cabo Frio | Muito argilosa (argila pesada) | 7,4 | 21 | 16,1 | 0,51 | 0 | 3 | Mandioca |
| banana, cana, aipim e guandu. | Cabo Frio | Franco-argilosa | 6,8 | 19,7 | 9,9 | 0,13 | 0 | 7 | Banana |
| pomar de citrus | Cabo Frio | Franco-argilo-arenosa | 4,8 | 1 | 0,2 | 0,5 | 0,2 | $< 1$ | Coco |
| cultura de citros. | Cabo Frio | Franco-argilo-arenosa | 4,6 | 0,3 | 0,2 | 0,05 | 1 | 2 | Abóbora, abobrinha e moranga |
| Citricultura. | Cabo Frio | Franco-argilo-arenosa | 5,5 | 1,4 | 0,3 | 0,05 | 0,1 | 1 | Alface |
| área de cultura abandonada. | Cabo Frio | Franco-arenosa | 6,3 | 1,7 | 0,3 | 0,04 | 0 | 1 | Quiabo |
| culturas de mandioca, banana e cana-de-açúcar. | Cabo Frio | Areia | 6,7 | 0,8 | 0,1 | 0,04 | 0,1 | 7 | Goiaba |
| Pastagem plantada de capim-colonião. | Cabo Frio | Areia | 8 | 1,9 | 0,3 | 0,04 | 0 | 10 | Milho |
| Pastagem plantada de brachiaria. | Cabo Frio | Argilo-arenosa | 8,1 | 14,6 | 5,6 | 0,12 | 0 | 3 | Capineiras e bancos de proteínas |
| Pastagem natural. (criação extensiva) | Cabo Frio | Areia-franca | 7,5 | 4,1 | 1,8 | 0,04 | 0 | 3 | Amendoim |
| Pastagem plantada de braquiária. | Cabo Frio | Muito argilosa (argila pesada) | 6,4 | 21,4 | 14,2 | 0,32 | 0 | 2 | Maxixe |
| Cultura de cana-de-açúcar. | Cabo Frio | Argila | 6,5 | 15 | 5,4 | 0,38 | 0 | 2 | Abóbora, abobrinha e moranga |
| Pastagem plantada de braquiária | Cabo Frio | Argila | 7,3 | 12,9 | 8,3 | 0,17 | 0 | 3 | Cana-de-açúcar |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| Uso Atual | Município | Classe de Textura | pH ($H_2O$) | Cálcio (cmolc/kg) | Magnésio (Mg) | Potássio (cmolc/kg) (K) | Alumínio ($Al^{3+}$) | Fósforo (mg/kg) (P) | Cultura |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem. | Cabo Frio | Muito argilosa (argila pesada) | 7,4 | 21 | 16,1 | 0,51 | 0 | 3 | Berinjela,jiló e pimentão |
| Pastagem natural. | Cabo Frio | Franco-argilo-arenosa | 5,6 | 2,5 | 3,5 | 0,08 | 4 | 4 | Inhame |
| Área de loteamento e pastagem. | Cabo Frio | Areia-franca | 5,4 | 0,9 | 1,2 | 0,12 | 0 | 5 | Melancia e melão |
| Área recém-gradeada e plantada com arroz. | Cabo Frio | Argila | 4,6 | 9,7 | 2 | 0,28 | 10 | 10 | Quiabo |
| Pastagem plantada. | Cabo Frio | Franca | 3,4 | 8,7 | 2 | 0,13 | 69 | 1 | Feijão |
| Área preparada para plantio de arroz. | Cabo Frio | Franco-argilosa | 4,9 | 11,9 | 5,1 | 0,35 | 1 | 4 | Brócolos, couve, couve-flor e repolho |
| Pastagem. | Cabo Frio | Franco-argilosa | 5,3 | 4,3 | 0,9 | 0,31 | 2 | 2 | Arroz |
| Culturas demandioca, banana e cana-de-açúcar. | Cabo Frio | Areia | 6,7 | 0,8 | 0,1 | 0,04 | 9 | 7 | Brócolos, couve, couve-flor e repolho |
| Pastagem plantada. | Cabo Frio | Argilo-arenosa | 4,9 | 1,2 | 0,3 | 0,4 | 11 | 1 | Banana |
| Pastagem. | Cabo Frio | Muito argilosa (argila pesada) | 7,4 | 21 | 16,1 | 0,51 | 0 | 3 | Mandioca |
| Área de cultura abandonada. | Cabo Frio | Franco-arenosa | 6,3 | 1,7 | 0,3 | 0,04 | 0 | 1 | Soja |
| Pastagem plantada de Brachiaria. | Cabo Frio | Muito argilosa (argila pesada) | 6,4 | 21,4 | 14,2 | 0,32 | 0 | 2 | Abóbora, abobrinha e moranga |
| Pastagem plantada de brachiária. | Cabo Frio | Argila | 7,3 | 12,9 | 8,3 | 0,17 | 0 | 3 | Maracujá |
| Banana prata | Cachoeiras de Macacu | Franco-argilo-arenosa | 5 | 2 | 0,3 | 0,13 | 0,4 | 1 | Goiaba |
| Sem uso. | Cachoeiras de Macacu | Franco-argilo-arenosa | 4,4 | 0,8 | 0,3 | 0,21 | 1,6 | 2 | Banana |
| Pastagem de capim-colonião. | Cambuci | Franco-argilosa | 7,1 | 2,2 | 2,8 | 0,06 | 0 | 1 | Pimenta |
| Não constatado. | Cambuci | Franco-argilo-arenosa | 5,9 | 6,9 | 2,2 | 0,3 | 0 | 2 | Pepino |
| Cultura de cana-de-açúcar e pastagem. | Campos dos Goytacazes | Franco-arenosa | 5,4 | 0,8 | 0,3 | 0,02 | 0,2 | $< 1$ | Berinjela,jiló e pimentão |
| Nenhum. | Campos dos Goytacazes | Argila | 7,1 | 7,8 | 9,4 | 1,07 | 0 | 161 | Cana-de-açúcar |
| Nenhum. | Campos dos Goytacazes | Muito argilosa (argila pesada) | 4,8 | 3 | 2,9 | 0,24 | 4,1 | 8 | Abacaxi |
| Nenhum. | Campos dos Goytacazes | Muito argilosa (argila pesada) | 4,6 | 1,4 | 1,8 | 0,05 | 6,3 | 3 | Coco |
| Cana-de-açúcar. | Campos dos Goytacazes | Argilo-siltosa | 6,6 | 13 | 3,6 | 0,38 | 0 | 182 | Soja |
| Pastagem. | Campos dos Goytacazes | Orgânica | 3,7 | 20,3 | 12,2 | 0,07 | 4,7 | 2 | Cana-de-açúcar |
| Cana-de-açúcar. | Campos dos Goytacazes | Franco-arenosa | 5,3 | 4,2 | 1 | 0,11 | 0,1 | 9 | Abóbora, abobrinha e moranga |
| Pastagem natural | Campos dos Goytacazes | Argilo-siltosa | 4,4 | 1,3 | 0,8 | 2,1 | 9,5 | 3 | Feijão |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| **Uso Atual** | **Município** | **Classe de Textura** | **pH ($H_2O$)** | **Cálcio (cmolc/kg)** | **Magnésio (Mg)** | **Potássio (cmolc/kg) (K)** | **Alumínio ($Al^{3+}$)** | **Fósforo (mg/kg) (P)** | **Cultura** |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem natural. | Cantagalo | Franco-argilo-arenosa | 6,5 | 3,5 | 0,3 | 0,15 | 0 | 1 | Alface |
| Não constatado. | Cantagalo | Franco-argilo-arenosa | 6,5 | 6,7 | 0,4 | 0,06 | 0 | 1 | Arroz |
| Pastagem. | Cantagalo | Franco-arenosa | 6,4 | 2 | 0,2 | 0,05 | 2,3 | -1 | Tomate |
| Pastagem natural. | Cantagalo | Franco-arenosa cascalhenta | 6,8 | 3,3 | 0,6 | 0,52 | 0 | 4 | Quiabo |
| Pastagem natural e cultura de banana. | Cantagalo | Franco-argilo-arenosa | 6,4 | 4,7 | 0,9 | 0,24 | 0 | -1 | Feijão |
| Pastagem natural. | Cantagalo | Franco-arenosa | 5,8 | 1,6 | 0,4 | 0,07 | 0 | -1 | Abóbora, abobrinha e moranga |
| Pastagem. | Cantagalo | Muito argilosa (argila pesada) | 6,9 | 13,2 | 3,3 | 0,11 | 0 | -1 | Berinjela,jiló e pimentão |
| Não constatado. | Cantagalo | Franco-argilo-arenosa | 5,2 | 1 | 0,2 | 0,15 | 0,3 | 2 | Berinjela,jiló e pimentão |
| Pastagem. | Cantagalo | Argila | 5,8 | 2,5 | 0,3 | 0,07 | 0 | -1 | Brócolos, couve, couve-flor e repolho |
| Pastagem natural. | Cantagalo | Argila | 5,5 | 3,3 | 0,5 | 0,1 | 0,7 | -1 | Beterraba e cenoura |
| Pastagem. | Cantagalo | Franco-argilo-arenosa | 5,7 | 2,9 | 0,2 | 0,19 | 0,1 | -1 | Batata-doce |
| Pastagem | Cantagalo | Franco-arenosa | 6,2 | 4,1 | 0,8 | 0,35 | 0 | 27 | Banana |
| Pastagem. | Cardoso Moreira | Franco-arenosa | 5,7 | 2,3 | 1,4 | 0,45 | 0 | 119 | Milho |
| pastagem plantada. | Casimiro de Abreu | Argila | 5,8 | 1,7 | 1,1 | 0,33 | 0 | 1 | Inhame |
| Cana-de-açúcar. | Casimiro de Abreu | Franco-arenosa | 4,8 | 1,4 | 0,2 | 0,32 | 33 | 8 | Abóbora, abobrinha e moranga |
| Pastagem plantada. | Casimiro de Abreu | Muito argilosa (argila pesada) | 3,9 | 1 | 1,8 | 0,07 | 61 | 10 | Milho |
| Pastagem plantada. | Casimiro de Abreu | Argila | 5,8 | 1,7 | 1,1 | 0,33 | 1 | 1 | Mandioca |
| Pomar de cítricas. | Casimiro de Abreu | Franco-argilo-arenosa | 4,8 | 1 | 0,2 | 0,5 | 14 | 1 | Banana |
| Cultura de cana-de-açúcar. | Casimiro de Abreu | Argila | 6,5 | 15 | 5,4 | 0,38 | 0 | 2 | Cana-de-açúcar |
| Pastagem natural. | Casimiro de Abreu | Argila | 3,7 | 1,1 | 0,2 | 0,1 | 89 | 30 | Feijão |
| Pastagem. | Cordeiro | Argila | 7 | 12,1 | 3,2 | 0,05 | 0 | 3 | Tomate |
| Não constatado. | Cordeiro | Franco-argilosa | 6,2 | 7,5 | 0,8 | 0,09 | 0 | 2 | Caqui |
| Pastagem. | Cordeiro | Franco-argilo-arenosa | 5,3 | 1,6 | 0,1 | 0,05 | 1 | -1 | Berinjela,jiló e pimentão |
| Pastagem. | Cordeiro | Argila | 6,3 | 4 | 0,3 | 0,05 | 0 | 1 | Maracujá |
| Área recém arada. | Duas Barras | Argila | 5,1 | 1,3 | 0,2 | 0,34 | 0,6 | 1 | café |
| Pastagem. | Duas Barras | Argila | 5,5 | 4,2 | 0,2 | 0,11 | 0,1 | -1 | Tomate |
| Pastagem. | Duas Barras | Argila | 5,1 | 2,6 | 0,1 | 0,23 | 1,2 | 2 | Berinjela,jiló e pimentão |
| Pastagem. | Itaboraí | Areia-franca | 4,8 | 0 | 0,5 | 0,03 | 0,4 | 1 | Banana |
| Pastagem. | Itaboraí | Franco-arenosa | 4,4 | 0 | 0,1 | 0,02 | 1,2 | 1 | Manga |
| Pastagem plantada (brachiária) | Itaboraí | Franco-argilo-arenosa | 5,3 | 3,2 | 3,5 | 0,47 | 0,4 | 4 | Coco |
| Culturas de milho, arroz e mamão. | Itaboraí | Franco-arenosa | 4,7 | 0,9 | 0,2 | 0,04 | 0,3 | 2 | Quiabo |
| Área de loteamento. | Itaguaí | Franco-argilo-arenoso m. cascalhenta | 5 | 1 | 0,1 | 0,03 | 0,4 | $< 0,5$ | Coco |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| Uso Atual | Município | Classe de Textura | pH ($H_2O$) | Cálcio (cmolc/kg) | Magnésio (Mg) | Potássio (cmolc/kg) (K) | Alumínio ($Al^{3+}$) | Fósforo (mg/kg) (P) | Cultura |
|---|---|---|---|---|---|---|---|---|---|
| | Itaguaí | Franco-argilo-arenosa | 5 | 1 | 0,1 | 0,03 | 0,4 | 0,5 | Banana |
| Mineração de calcário. | Italva | Muito argilosa (argila pesada) | 8 | 32,8 | 4,4 | 0,19 | 0 | 11 | Tomate |
| Área recém arada. | Italva | Argila | 6,4 | 10,9 | 5,8 | 0,24 | 0 | 3 | Berinjela,jiló e pimentão |
| Não constatado. | Itaocara | Franco-argilo-arenosa | 5,9 | 4,4 | 1,2 | 0,11 | 0 | 2 | Quiabo |
| Não constatado. | Itaocara | Franco-argilo-arenosa | 6 | 2,6 | 0,8 | 0,07 | 0 | 1 | Berinjela,jiló e pimentão |
| Pastagem. | Itaperuna | Muito argilosa (argila pesada) | 6,7 | 4 | 6,7 | 0,05 | 0 | 1 | Tomate |
| Pastagem. | Itaperuna | Argila | 7,6 | 11,8 | 2,7 | 0,17 | 0 | 2 | Berinjela,jiló e pimentão |
| Pastagem. | Itaperuna | Argila | 7,7 | 11,6 | 3,7 | 0,65 | 0 | 3 | Abóbora, abobrinha e moranga |
| Pastagem. | Itaperuna | Argila | 4,9 | 11,1 | 4,1 | 0,44 | 0 | 10 | Milho |
| Pastagem. | Itaperuna | Franco-argilo-arenosa com cascalho | 5,8 | 3,8 | 0,9 | 0,06 | 0,1 | 3 | Pepino |
| Pastagem de capim-gordura. | Itaperuna | Franco-arenosa | 5,9 | 1,2 | 0,4 | 0,04 | 0,4 | 9 | Berinjela,jiló e pimentão |
| Pastagem natural. | Itaperuna | Argila | 6,5 | 4,7 | 3,7 | 0,06 | 0 | -1 | Quiabo |
| Pastagem. | Itaperuna | Franco-argilo-arenosa | 6,1 | 7,7 | 2,6 | 0,15 | 0 | 6 | Café |
| Pastagem nativa. | Itaperuna | Franco-argilosa | 6 | 1,5 | 0,4 | 0,01 | 0 | -1 | Banana |
| Pastagem. | Laje do Muriaé | Franco-argilo-arenosa | 5,5 | 1,3 | 0,5 | 0,08 | 0,2 | -1 | Banana |
| Pastagem natural | Macaé | Franco-argilosa | 5,5 | 0,8 | 0,2 | 0,04 | 2,1 | 7 | Soja |
| Pastagem natural. | Macaé | Franco-arenosa | 5,8 | 3,3 | 0,4 | 0,22 | 0 | 22 | Arroz |
| Pastagem natural. | Macaé | Franco-argilo-arenosa | 5,8 | 1,7 | 0,2 | 0,24 | 0,2 | 2 | Feijão |
| Pastagem. | Macuco | Franco-argilo-arenosa | 4,6 | 0,7 | 0 | 0,06 | 2,5 | 1 | Caqui |
| Pastagem. | Macuco | Franco-argilosa | 4,6 | 0,5 | 0 | 0,05 | 3,4 | 1 | Milho |
| Psatagem natural. | Magé | Franco-arenosa | 5,4 | 0,9 | 0,1 | 0,37 | 0,2 | 5 | Batata-doce |
| Pastagens. | Miracema | Argila | 4,9 | 0,6 | 0,6 | 0,17 | 1,6 | 1 | Tomate |
| Pastagem. | Miracema | Argila | 4,9 | 0,6 | 0,6 | 0,17 | 1,6 | 1 | Quiabo |
| Pastagem de capim-gordura e reflorestamento com pinheiro. | Nova Friburgo | Argila | 4,5 | 1,2 | 0,3 | 0,04 | 3,5 | 6 | Alface |
| Pastagem natural. | Nova Friburgo | Argila | 5 | 1,2 | 0,1 | 0,1 | 1,5 | 10 | Tomate |
| Pousio de 5 a 6 meses, sendo anteriormente cultivado com mandioca | Nova Friburgo | Franco-argilo-arenosa | 4,6 | 1,2 | 0,5 | 0,09 | 1,4 | 49 | Brócolos, couve, couve-flor e repolho |
| Pousio (capoeira) | Paty do Alferes | Argila | 5,7 | 0,3 | 0,7 | 0,03 | 0,6 | 1 | Brócolos, couve, couve-flor e repolho |
| Pastagem | Paty do Alferes | Argilo-arenosa | 5,4 | 0,7 | 0,8 | 0,61 | 0,1 | 2 | Maracujá |
| pousio (capoeira) | Paty do Alferes | Argilo-arenosa | 5,1 | 0,9 | 0,2 | 0,04 | 0 | 1 | Tomate |
| Pastagem, pomar. | Paty do Alferes | Argila | 5,7 | 2,2 | 1 | 0,53 | 0 | 17 | Abóbora, abobrinha e moranga |
| RESERVA FLORESTAL | Paty do Alferes | Argilo-arenosa | 4,4 | 0,7 | 9,7 | 0,1 | 1,1 | 2 | Banana |
| Pastagem | Paty do Alferes | Argilo-arenosa | 5,7 | 1,2 | 0,8 | 0,24 | 0 | 24 | Mamão |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| **Uso Atual** | **Município** | **Classe de Textura** | **pH ($H_2O$)** | **Cálcio (cmolc/kg)** | **Magnésio (Mg)** | **Potássio (cmolc/kg) (K)** | **Alumínio ($Al^{3+}$)** | **Fósforo (mg/kg) (P)** | **Cultura** |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem | Paty do Alferes | Franco-argilo-arenosa | 5,4 | 1,6 | 0,5 | 0,16 | 0 | 1 | Berinjela,jiló e pimentão |
| Pastagem | Paty do Alferes | Franco-argilo-arenosa | 5,4 | 1,2 | 0,6 | 0,59 | 0,5 | 90 | Maxixe |
| Pastagem. | Paty do Alferes | Argilo-arenosa | 4,8 | 0,9 | 1,2 | 0,03 | 0,4 | 1 | Brócolos, couve, couve-flor e repolho |
| Pastagem. | Paty do Alferes | Franco-argilo-arenosa | 4,9 | 0,6 | 0,6 | 0,27 | 1,3 | 2 | Pepino |
| Pastagem. | Paty do Alferes | Argila | 4,8 | 0,2 | 0,2 | 0,09 | 1 | 1 | Alface |
| Pastagem | Paty do Alferes | Argila | 5,3 | 1,2 | 1,1 | 0,05 | 0,3 | 2 | Caqui |
| olericultura | Paty do Alferes | Argila | 4,5 | 0,6 | 0,6 | 0,23 | 0,5 | 11 | Chuchu |
| Olericultura. | Paty do Alferes | Argila | 4,5 | 0,7 | 0,6 | 0,1 | 0,2 | 2 | Mandioca |
| Pastagem | Paty do Alferes | Franco-arenosa | 5,7 | 0,7 | 0,8 | 0,09 | 0,1 | 4 | Feijão |
| Pastagem de capim gordura. | Paty do Alferes | Franco-argilo-arenosa | 5,6 | 1,3 | 0,5 | 0,16 | 0 | 1 | Cebola |
| Pastagem | Paty do Alferes | Franco-arenosa | 4,8 | 0,8 | 0,6 | 0,31 | 0,2 | 2 | Abacate |
| Olerícolas e pastagem. | Paty do Alferes | Franco-argilo-arenosa | 5,4 | 2,7 | 0,8 | 0,12 | 0 | 43 | Goiaba |
| Pastagem. | Paty do Alferes | Franco-argilo-arenosa | 4,9 | 1,5 | 0,4 | 0,08 | 0,3 | 6 | Manga |
| capoeira. | Petrópolis | Argila | 4,9 | 0,1 | 0,9 | 0,42 | 1,1 | 1 | Brócolos, couve, couve-flor e repolho |
| Capoeira. | Petrópolis | Argila | 4,9 | 0,1 | 0,9 | 0,42 | 1,1 | 1 | Alface |
| Nenhum. | Piraí | Argila | 4,6 | 1,3 | 0,2 | 0,1 | 0,7 | $< 0,5$ | Banana |
|  | Piraí | Argila | 4,6 | 1,3 | 0,2 | 0,1 | 0,7 | 0,5 | Mandioca |
| Pastagem de capim-murubu. | Rio de Janeiro | Franco-argilo-arenosa | 5,7 | 2,1 | 2,6 | 0,11 | 0,3 | 1 | Chuchu |
| Reserva florestal. | Rio de Janeiro | Franco-argilo-arenosa | 4,4 | 0,6 | 0,6 | 0,32 | 30 | 3 | Coco |
| Pastagem. | Santo Antônio de Pádua | Argilo-arenosa | 5,3 | 1,1 | 1,8 | 0,06 | 0,2 | 1 | Tomate |
| Pastagem de capim-gordura. | Santo Antônio de Pádua | Franco-argilo-arenosa | 7,3 | 3,8 | 1,6 | 0,07 | 0 | 2 | Berinjela,jiló e pimentão |
| Pastagem. | Santo Antônio de Pádua | Franco-argilo-arenosa | 5,4 | 0,6 | 0,7 | 0,04 | 0,2 | 1 | Quiabo |
| Não constatado | Santo Antônio de Pádua | Franco-argilo-arenosa | 6 | 5,9 | 1,3 | 0,19 | 0 | 2 | Banana |
| Pastagem natural. | Santo Antônio de Pádua | Franco-arenosa | 6,6 | 2,2 | 0,5 | 0,11 | 0 | 2 | Coco |
| Pastagem natural. | Santo Antônio de Pádua | Franco-arenosa | 5,9 | 2,3 | 1,2 | 0,06 | 0,1 | 1 | Abóbora, abobrinha e moranga |
| Não constatado. | Santo Antônio de Pádua | Argila | 6,4 | 3,2 | 0,4 | 0,33 | 0 | 10 | Pepino |
| Pastagem. | Santo Antônio de Pádua | Franco-arenosa | 6,9 | 2 | 1,2 | 0,32 | 0 | 12 | Milho |
| Pastagem natural. | Santo Antônio de Pádua | Franco-arenosa | 5,9 | 2,3 | 1,2 | 0,06 | 0,1 | 1 | Beterraba e cenoura |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| Uso Atual | Município | Classe de Textura | pH ($H_2O$) | Cálcio (cmolc/kg) | Magnésio (Mg) | Potássio (cmolc/kg) (K) | Alumínio ($Al^{3+}$) | Fósforo (mg/kg) (P) | Cultura |
|---|---|---|---|---|---|---|---|---|---|
| Cultura de milho | São Fidélis | Franco-argilo-arenosa | 5,2 | 1,8 | 0,2 | 0,02 | 0 | 1 | Tomate |
| não constatado | São Fidélis | Argilo-arenosa | 5 | 2,1 | 0,4 | 0,04 | 0 | 1 | Quiabo |
| pastagem natural | São Fidélis | Franco-argilo-arenosa | 5,7 | 3,6 | 1,8 | 0,07 | 0 | 1 | Berinjela,jiló e pimentão |
| pastagem natural | São Fidélis | Argila | 5,2 | 6,2 | 2 | 0,12 | 1,2 | 7 | Pepino |
| Pastagem. | São Fidélis | Franco-argilo-arenosa | 5,1 | 3,2 | 0,2 | 0,07 | 0 | 2 | Manga |
| Pastagem natural. | São Fidélis | Franco-arenosa | 6,2 | 3,9 | 0,4 | 0,26 | 0 | 3 | Cana-de-açúcar |
| Pastagem plantada. | São João da Barra | Muito argilosa (argila pesada) | 5,8 | 28,8 | 5 | 0,12 | 0 | 1 | Abacaxi |
| Pastagem natural. | São João da Barra | Franco-argilo-arenosa | 5,1 | 2 | 0,3 | 0,18 | 0,1 | 7 | Coco |
| pastagem natural. | São Pedro da Aldeia | Franco-argilo-arenosa | 5,2 | 5,5 | 8,3 | 0,18 | 0,6 | 1 | Cana-de-açúcar |
| não constatado. | São Pedro da Aldeia | Franco-argilo-arenosa | 5,4 | 3,7 | 3,8 | 0,02 | 0,4 | 1 | Mandioca |
| não constatado. | São Pedro da Aldeia | Areia-franca | 6,7 | 1,4 | 0,9 | 0,06 | 0 | 4 | Coco |
| nãos constatado. | São Pedro da Aldeia | Franco-argilo-arenosa | 7,5 | 4,9 | 5,7 | 0,05 | 0 | 1 | Banana |
| nãos constatado. | São Pedro da Aldeia | Franco-arenosa | 7,6 | 2,8 | 2,7 | 0,04 | 0 | 1 | Quiabo |
| Nenhum. | São Pedro da Aldeia | Franco-arenosa | 7,6 | 2,8 | 2,7 | 0,04 | 0 | 1 | Maxixe |
| Nenhum. | São Pedro da Aldeia | Franco-argilo-arenosa | 7,5 | 4,9 | 5,7 | 0,05 | 0 | 1 | Batata-doce |
| Pastagem natural. | São Pedro da Aldeia | Franco-siltosa | 4,4 | 33,3 | 14,8 | 0,17 | 1 | 2 | Batata-inglesa |
| Loteamento. | São Pedro da Aldeia | Areia-franca | 5,3 | 1,1 | 0,7 | 0,24 | 0 | 12 | Manga |
| Pastagem de colonião. | São Pedro da Aldeia | Franco-argilo-arenoso m. cascalhenta | 4,9 | 2 | 0,3 | 0,11 | 4 | 1 | Mandioquinha-salsa |
| Pastagem de colonião. | São Pedro da Aldeia | Muito argilosa com cascalho | 5,2 | 1,6 | 0,5 | 0,02 | 12 | 1 | Maxixe |
| Pastagem natural. | São Pedro da Aldeia | Argila | 5,7 | 15,2 | 8,6 | 0,15 | 1 | 3 | Feijão-de-vagem |
| Pastagem natural. | São Pedro da Aldeia | Franco-argilo-arenosa | 5,2 | 5,5 | 8,3 | 0,18 | 4 | 1 | Pepino |
| Nenhum. | São Pedro da Aldeia | Franco-argilo-arenosa | 7,5 | 4,9 | 5,7 | 0,05 | 0 | 1 | Abacaxi |
| Pastagem natural. | São Sebastião do Alto | Franco-argilosa | 6,4 | 20,5 | 4,5 | 0,28 | 0 | 6 | Tomate |
| Pastagem. | São Sebastião do Alto | Franco-argilo-arenosa | 5,5 | 2,7 | 1,1 | 2,8 | 0 | 4 | Quiabo |
| Pastagem. | São Sebastião do Alto | Argilo-arenosa | 6,3 | 2,7 | 1,1 | 3,8 | 0 | 3 | Berinjela,jiló e pimentão |
| Pastagem. | Sapucaia | Argila | 6,7 | 5,7 | 1,7 | 0,16 | 0 | -1 | Chuchu |
| Não constatado. | Sapucaia | Franco-argilosa | 5,1 | 1,6 | 0,3 | 0,12 | 0,5 | -0,5 | Brócolos, couve, couve-flor e repolho |
| Pastagem. | Sapucaia | Franco-arenosa | 5,7 | 2,5 | 0,2 | 0,08 | 0,3 | 26 | Pepino |
| Nenhum. | Saquarema | Argila | 4,7 | 2,2 | 1,7 | 0,08 | 2 | 2 | Banana |
| Reflorestamento de eucalipto. | Saquarema | Franco-argilo-arenosa | 5 | 2,3 | 0,2 | 0,26 | 17 | 4 | Coco |
| pastagem de capim colonião. | Seropédica | Argila | 4,7 | 1,4 | 0,5 | 0,04 | 0,6 | 1 | Mandioca |
| pastagem de capim colonião. | Seropédica | Franco-argilo-arenosa | 5,1 | 1,1 | 1 | 0,06 | 0,3 | 1 | Banana |
| pastagem de capim colonião. | Seropédica | Argilo-arenosa | 5,1 | 1,1 | 0,8 | 0,04 | 0,2 | 1 | Quiabo |
| Área de loteamento. | Seropédica | Franco-argilo-arenosa | 5 | 1 | 0,1 | 0,03 | 0,4 | 0,5 | Alface |
| pastagem plantada. | Silva Jardim | Franca | 4,8 | 0,6 | 0,6 | 0,08 | 1,9 | 2 | Mandioca |
| Pastagem plantada. | Silva Jardim | Franco-arenosa | 6,3 | 1,9 | 0,6 | 0,13 | 0 | 3 | Milho |
| Pastagem plantada. | Silva Jardim | Franco-argilosa | 4,4 | 1,2 | 0,7 | 0,2 | 53 | 2 | Inhame |

*Continua na próxima página.*

*Continuação da Tabela A.1.*

| **Uso Atual** | **Município** | **Classe de Textura** | **pH ($H_2O$)** | **Cálcio (cmolc/kg)** | **Magnésio (Mg)** | **Potássio (cmolc/kg) (K)** | **Alumínio ($Al^{3+}$)** | **Fósforo (mg/kg) (P)** | **Cultura** |
|---|---|---|---|---|---|---|---|---|---|
| Pastagem plantada | Silva Jardim | Franca | 4,8 | 0,6 | 0,6 | 0,08 | 59 | 2 | Abacate |
| Pastagem plantada. | Silva Jardim | Franco-arenosa | 5,1 | 0,5 | 0,8 | 0,13 | 30 | 7 | Goiaba |
| Pastagem de colonião. | Silva Jardim | Argilo-siltosa | 4,4 | 1,6 | 0,5 | 0,13 | 62 | 12 | Coco |
| Cultura de batatas. | Teresópolis | Argila | 5,5 | 1,9 | 0,2 | 0,26 | 0 | 1 | Batata-inglesa |
| Não constatado. | Teresópolis | Franco-arenosa cascalhenta | 5,6 | 1,7 | 0,2 | 0,2 | 0,4 | 56 | Alface |

# Apêndice B - Recomendações do Sistema

Trabalho Acadêmico de Dissertação de Mestrado em Ciências da Computação
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET-RJ)
André Luiz Coutinho Merlo, Diego Brandão

Este relatório foi desenvolvido como parte da dissertação de mestrado em Ciências da Computação do CEFET-RJ, com o objetivo de explorar técnicas de análise de dados e modelagem computacional para fornecer recomendações agrícolas baseadas em dados históricos e climáticos. O trabalho visa contribuir para o avanço do conhecimento na área de ciência de dados aplicada à agricultura, utilizando métodos estatísticos, algoritmos de aprendizado de máquina e ferramentas de visualização de dados. As recomendações apresentadas neste relatório são geradas a partir de modelos computacionais e análises de dados, e não devem ser interpretadas como prescrições definitivas ou conselhos profissionais. Elas são propostas com base em dados disponíveis e técnicas computacionais, mas não consideram todos os fatores práticos, econômicos, ambientais ou logísticos que podem influenciar decisões agrícolas. Portanto, o autor e o CEFET-RJ não se responsabilizam por quaisquer consequências decorrentes da aplicação direta ou indireta das informações e recomendações contidas neste documento. Este trabalho é de natureza acadêmica e tem como principal objetivo explorar o potencial da ciência de dados e da computação para apoiar a tomada de decisões no setor agrícola. Agradecemos a todos os envolvidos pelo apoio e colaboração durante o desenvolvimento desta pesquisa.

# Relatório de Recomendações Agrícolas Gerais para a Cidade de Nova Friburgo

Este relatório apresenta recomendações agrícolas estratégicas para o município de Nova Friburgo, com base em análises de produtividade e condições climáticas regionais. Os dados de produtividade por cultura foram obtidos do projeto Acompanhamento Sistemático da Produção Agrícola (ASPA), desenvolvido pela EMATER-Rio, abrangendo os anos de 2021 a 2023, e fornecem insights valiosos sobre o desempenho das principais culturas na região. Complementando essas informações, os dados climáticos históricos, coletados pelas estações de medição do INMET no estado do Rio de Janeiro, permitiram uma avaliação detalhada das condições de temperatura, precipitação, umidade e pressão atmosférica. A combinação dessas fontes possibilita recomendações personalizadas, visando maximizar a produtividade, reduzir riscos climáticos e otimizar o uso dos recursos agrícolas em Nova Friburgo.

A recomendação deste relatório está baseada nos dados agrícolas da região **SERRANA**, que inclui as seguintes cidades: Bom Jardim, Cantagalo, Carmo, Cordeiro, Duas Barras, Macuco, Nova Friburgo, Santa Maria Madalena, Sapucaia, Sumidouro, São José do Vale do Rio Preto, São Sebastião do Alto, Teresópolis, Trajano de Morais

## 1. Recomendação por Produtividade

A recomendação baseada em produtividade destaca as culturas agrícolas mais eficientes em relação ao rendimento por área plantada. Esse indicador mede a quantidade média produzida em toneladas por hectare, permitindo identificar quais culturas apresentam maior retorno produtivo por unidade de terra utilizada, o que é essencial para otimizar o uso dos recursos agrícolas e aumentar a eficiência produtiva.

| CULTURAS | PRODUTIVIDADE |
|---|---|
| TOMATE CEREJA | 85.11 |
| CANA FORRAGEIRA | 69.96 |

| CULTURAS | PRODUTIVIDADE |
|---|---|
| CHUCHU | 61.33 |
| TOMATE | 59.02 |
| ALFACE - CULT. PROTG | 56.36 |
| COUVE | 53.32 |
| PEPINO | 47.83 |
| REPOLHO | 46.45 |
| RÚCULA - CULT. PROTG | 39.71 |
| MILHO FORRAGEIRO | 38.94 |
| ESPINAFRE | 34.83 |
| SALSA | 33.27 |
| VAGEM FRANCESA | 32.80 |
| MORANGO | 32.57 |
| CHICÓRIA | 29.66 |
| COUVE FLOR | 27.99 |
| BERINJELA | 27.27 |
| GOIABA | 26.24 |
| ALHO PORRÓ | 25.95 |
| PIMENTÃO | 25.49 |
| MANDIOCA | 25.00 |
| CENOURA | 24.27 |
| ALFACE | 22.72 |
| JILÓ | 22.48 |
| CAQUI | 22.47 |
| AGRIÃO | 22.22 |
| BETERRABA | 22.18 |
| TANGERINA PONCÃ | 21.85 |
| NABO | 20.85 |
| BROCOLOS | 20.40 |
| BERTALHA | 19.65 |
| INHAME | 17.74 |
| VAGEM | 17.22 |
| LIMÃO | 17.01 |
| ABOBRINHA | 16.79 |
| AIPIM | 16.17 |
| ABACATE | 16.16 |
| QUIABO | 16.00 |
| MANGA | 15.33 |
| MARACUJÁ | 15.10 |

| CULTURAS | PRODUTIVIDADE |
|---|---|
| COENTRO | 14.54 |
| BATATA | 14.43 |
| CEBOLINHA | 14.37 |
| ABOBORA | 14.34 |
| LARANJA | 14.21 |
| BATATA DOCE | 13.77 |
| BANANA NANICA | 12.54 |
| FIGO | 12.06 |
| PITAIA | 12.00 |
| RÚCULA | 11.90 |
| BANANA PRATA | 11.31 |
| MAXIXE | 8.83 |
| ERVILHA | 8.42 |
| PESSEGO | 8.18 |
| MILHO VERDE | 7.99 |
| UVA | 5.97 |
| LIXIA | 4.10 |
| ARROZ | 3.48 |
| MILHO | 2.85 |
| CAFÉ | 1.69 |
| CAFÉ CONILON | 1.15 |
| FEIJÃO | 1.10 |

## 2. Recomendação por Faturamento Bruto

Para otimizar a rentabilidade agrícola em cada região, é essencial priorizar culturas com maior faturamento bruto médio, considerando fatores como clima, solo e demanda de mercado. Essa abordagem permite identificar as atividades mais lucrativas por área, direcionando investimentos para opções que ofereçam melhor retorno financeiro. Por exemplo, em regiões com alta produtividade e logística eficiente, culturas como soja, milho ou café podem ser recomendadas devido ao seu alto valor de mercado, enquanto em áreas com condições específicas, fruticultura ou horticultura de alto valor agregado podem ser mais vantajosas. Ao alinhar a escolha das culturas ao potencial econômico regional, os produtores podem maximizar seus ganhos e reduzir riscos, garantindo uma agricultura mais sustentável e competitiva.

| CULTURAS | FATURAMENTOBRUTO |
|---|---|
| ALFACE | 197.974.260,67 |
| TOMATE | 180.583.538,33 |
| COUVE | 94.095.613,33 |
| CHUCHU | 54.516.116,67 |
| COUVE FLOR | 41.974.502,43 |

| CULTURAS | FATURAMENTOBRUTO |
|---|---|
| BROCOLOS | 40.718.382,83 |
| REPOLHO | 39.217.160,27 |
| BANANA NANICA | 37.551.714,03 |
| TANGERINA PONCÃ | 37.220.484,50 |
| CAFÉ | 37.102.699,33 |
| PIMENTÃO | 33.449.481,00 |
| MORANGO | 29.728.583,33 |
| JILÓ | 27.517.350,40 |
| VAGEM | 25.884.640,00 |
| BANANA PRATA | 24.277.535,33 |
| CAQUI | 24.251.655,00 |
| PEPINO | 22.855.072,00 |
| BERINJELA | 22.735.779,00 |
| CEBOLINHA | 21.752.496,00 |
| COENTRO | 19.847.394,00 |
| ABOBRINHA | 17.478.028,87 |
| INHAME | 17.230.221,67 |
| AIPIM | 16.422.493,90 |
| ERVILHA | 13.502.244,13 |
| SALSA | 13.287.256,67 |
| ALFACE - CULT. PROTG | 9.453.641,20 |
| AGRIÃO | 9.111.963,00 |
| ESPINAFRE | 8.132.805,00 |
| QUIABO | 7.421.333,17 |
| MILHO FORRAGEIRO | 7.026.255,33 |
| RÚCULA - CULT. PROTG | 6.131.456,67 |
| BATATA DOCE | 5.654.906,33 |
| GOIABA | 5.187.420,00 |
| CHICÓRIA | 4.560.665,70 |
| MARACUJÁ | 4.462.331,00 |
| TOMATE CEREJA | 3.659.221,33 |
| BETERRABA | 3.134.426,30 |
| CENOURA | 2.692.534,33 |
| ABOBORA | 2.245.867,33 |
| ALHO PORRÓ | 1.810.066,67 |
| LIMÃO | 1.799.457,67 |
| RÚCULA | 1.504.595,00 |
| VAGEM FRANCESA | 1.466.375,67 |

| CULTURAS | FATURAMENTOBRUTO |
|---|---|
| FEIJÃO | 962.403,50 |
| MILHO VERDE | 847.358,50 |
| MAXIXE | 823.076,67 |
| LARANJA | 594.405,00 |
| BATATA | 569.933,33 |
| CANA FORRAGEIRA | 539.232,17 |
| MILHO | 499.066,07 |
| BERTALHA | 486.500,00 |
| ARROZ | 312.283,33 |
| LIXIA | 234.083,33 |
| NABO | 189.150,00 |
| UVA | 176.333,33 |
| ABACATE | 118.700,00 |
| CAFÉ CONILON | 60.585,00 |
| PITAIA | 57.000,00 |
| FIGO | 45.330,00 |
| MANDIOCA | 34.375,00 |
| MANGA | 17.000,00 |
| PESSEGO | 16.081,67 |

## 3. Recomendação por Produção Colhida

A seleção de culturas com maior volume médio colhido por região é fundamental para atender demandas de abastecimento interno, exportação ou agroindústria, priorizando eficiência produtiva e escala. Essa análise identifica as culturas mais adaptadas às condições edafoclimáticas de cada local, garantindo altas produtividades e menor risco de perdas. Por exemplo, em regiões com alta fertilidade e disponibilidade hídrica, culturas como cana-de-açúcar, milho ou mandioca podem ser recomendadas devido ao seu elevado rendimento por hectare, enquanto em áreas com restrições específicas, opções como feijão ou sorgo podem oferecer melhor desempenho. Ao focar no potencial produtivo, os agricultores podem otimizar o uso da terra, reduzir custos e fortalecer a segurança alimentar, alinhando produção às necessidades do mercado.

| CULTURAS | PRODUCAOCOLHIDA |
|---|---|
| ALFACE | 110211.45 |
| CHUCHU | 85777.78 |
| TOMATE | 60356.25 |
| REPOLHO | 37998.95 |
| COUVE | 30536.00 |
| TANGERINA PONCÃ | 28377.97 |
| COUVE FLOR | 24697.36 |
| PEPINO | 19857.63 |

| CULTURAS | PRODUCAOCOLHIDA |
|---|---|
| BANANA NANICA | 18190.07 |
| BROCOLOS | 16704.37 |
| MILHO FORRAGEIRO | 15891.97 |
| BERINJELA | 14702.22 |
| ABOBRINHA | 14505.04 |
| PIMENTÃO | 14279.34 |
| JILÓ | 13107.69 |
| CAQUI | 12006.50 |
| VAGEM | 10326.40 |
| BANANA PRATA | 10162.00 |
| AIPIM | 9267.12 |
| INHAME | 8133.43 |
| ESPINAFRE | 6482.36 |
| CEBOLINHA | 5882.38 |
| SALSA | 4832.05 |
| ALFACE - CULT. PROTG | 4365.12 |
| COENTRO | 4140.57 |
| AGRIÃO | 3981.66 |
| BATATA DOCE | 3835.12 |
| CANA FORRAGEIRA | 3044.49 |
| QUIABO | 2951.14 |
| CAFÉ | 2708.52 |
| CHICÓRIA | 2627.97 |
| MORANGO | 1964.70 |
| GOIABA | 1866.53 |
| RÚCULA - CULT. PROTG | 1767.62 |
| ERVILHA | 1718.37 |
| CENOURA | 1625.37 |
| BETERRABA | 1624.27 |
| ABOBORA | 1527.80 |
| MARACUJÁ | 1377.57 |
| MILHO VERDE | 788.33 |
| LIMÃO | 720.95 |
| TOMATE CEREJA | 625.39 |
| ALHO PORRÓ | 620.00 |
| MAXIXE | 551.33 |
| RÚCULA | 534.24 |
| LARANJA | 374.27 |

| CULTURAS | PRODUCAOCOLHIDA |
|---|---|
| MILHO | 369.69 |
| BERTALHA | 304.50 |
| VAGEM FRANCESA | 261.37 |
| BATATA | 255.17 |
| FEIJÃO | 201.42 |
| NABO | 85.70 |
| ABACATE | 56.03 |
| ARROZ | 48.28 |
| UVA | 32.17 |
| LIXIA | 28.13 |
| MANDIOCA | 25.00 |
| MANGA | 18.67 |
| PITAIA | 6.00 |
| CAFÉ CONILON | 5.77 |
| FIGO | 2.92 |
| PESSEGO | 2.48 |

## 4. Visão geral do Clima

Visão das médias de temperatura, umidade e pressão. Assim como o somatório do volume de chuvas. A região SERRANA apresenta um clima com médias anuais de temperatura em torno de 16.62°C, umidade relativa do ar de 80.95% e pressão atmosférica média de 879.47 hPa. O regime de chuvas com um volume pluviométrico total anual de aproximadamente 2444.6 mm. Essas condições climáticas influenciam diretamente a escolha das culturas e as práticas agrícolas, sendo favoráveis para [exemplos de culturas ou atividades adaptadas]. Compreender esses padrões é essencial para o planejamento agrícola, minimizando riscos e maximizando a produtividade de acordo com as particularidades da região.

Dados mensais

| Período | Precipitação Total (mm) | Temperatura Média (°C) | Temperatura Máxima (°C) | Temperatura Mínima (°C) | Pressão Atmosférica (mB) | Umidade Relativa (%) |
|---|---|---|---|---|---|---|
| 2019-01 | 400.6 | 19.52 | 29.6 | 12.7 | 864.48 | 84.46 |
| 2019-02 | 511.0 | 18.76 | 30.9 | 10.0 | 863.44 | 88.20 |
| 2019-03 | 539.8 | 17.76 | 28.8 | 8.4 | 863.44 | 88.97 |
| 2019-04 | 176.6 | 17.10 | 28.3 | 9.0 | 862.89 | 88.75 |
| 2019-05 | 139.6 | 15.63 | 26.1 | 7.9 | 863.57 | 88.14 |
| 2019-06 | 82.4 | 13.68 | 25.8 | 5.4 | 866.78 | 87.06 |

| Período | Precipitação Total (mm) | Temperatura Média (°C) | Temperatura Máxima (°C) | Temperatura Mínima (°C) | Pressão Atmosférica (mB) | Umidade Relativa (%) |
|---|---|---|---|---|---|---|
| 2019-07 | 63.0 | 11.78 | 24.2 | 1.1 | 865.97 | 79.96 |
| 2019-08 | 186.4 | 12.64 | 26.7 | 3.8 | 867.55 | 79.63 |
| 2019-09 | 261.4 | 15.94 | 30.7 | 6.7 | 864.91 | 77.07 |
| 2019-10 | 231.8 | 16.65 | 28.3 | 6.3 | 863.04 | 80.61 |
| 2019-11 | 422.0 | 16.66 | 31.2 | 7.3 | 861.51 | 87.22 |
| 2019-12 | 458.8 | 17.31 | 27.6 | 5.8 | 861.74 | 85.90 |
| 2020-01 | 414.6 | 18.89 | 29.2 | 10.8 | 865.44 | 86.47 |
| 2020-02 | 705.2 | 18.16 | 29.0 | 11.4 | 863.60 | 88.67 |
| 2020-03 | 349.8 | 18.15 | 26.6 | 9.6 | 898.57 | 82.07 |
| 2020-04 | 49.0 | 16.49 | 27.2 | 7.3 | 899.76 | 81.46 |
| 2020-05 | 95.4 | 14.50 | 23.6 | 3.8 | 900.38 | 78.91 |
| 2020-06 | 13.6 | 14.91 | 25.9 | 2.9 | 901.82 | 78.67 |
| 2020-07 | 9.4 | 14.56 | 24.6 | 5.6 | 901.67 | 79.15 |
| 2020-08 | 72.6 | 13.92 | 26.1 | 2.6 | 902.34 | 78.05 |
| 2020-09 | 43.4 | 17.64 | 30.7 | 5.9 | 900.61 | 72.77 |
| 2020-10 | 164.2 | 18.10 | 32.4 | 9.0 | 897.87 | 78.55 |
| 2020-11 | 207.6 | 17.75 | 27.8 | 9.8 | 897.63 | 81.26 |
| 2020-12 | 337.2 | 19.99 | 30.0 | 13.6 | 896.80 | 80.78 |
| 2021-01 | 178.0 | 18.82 | 28.6 | 12.0 | 863.81 | 82.02 |
| 2021-02 | 524.8 | 17.80 | 28.7 | 10.0 | 863.90 | 85.40 |
| 2021-03 | 221.8 | 18.19 | 28.1 | 11.1 | 864.87 | 83.52 |
| 2021-04 | 136.4 | 15.21 | 25.2 | 5.6 | 872.87 | 83.37 |
| 2021-05 | 54.2 | 14.56 | 25.7 | 4.8 | 870.27 | 82.45 |
| 2021-06 | 48.8 | 13.20 | 23.4 | 3.8 | 873.06 | 83.67 |

| Período | Precipitação Total (mm) | Temperatura Média (°C) | Temperatura Máxima (°C) | Temperatura Mínima (°C) | Pressão Atmosférica (mB) | Umidade Relativa (%) |
|---|---|---|---|---|---|---|
| 2021-07 | 12.8 | 11.06 | 24.4 | 0.0 | 870.60 | 77.85 |
| 2021-08 | 51.4 | 13.56 | 25.8 | 2.4 | 873.33 | 77.91 |
| 2021-09 | 61.0 | 17.47 | 30.2 | 9.2 | 899.83 | 76.87 |
| 2021-10 | 242.4 | 17.11 | 28.0 | 10.7 | 895.61 | 82.65 |
| 2021-11 | 205.8 | 16.53 | 27.8 | 7.9 | 872.37 | 80.50 |
| 2021-12 | 345.2 | 17.78 | 27.5 | 8.2 | 878.54 | 83.42 |
| 2022-01 | 288.2 | 19.68 | 28.4 | 13.8 | 875.97 | 82.57 |
| 2022-02 | 412.0 | 18.91 | 28.0 | 12.8 | 877.46 | 85.23 |
| 2022-03 | 270.2 | 18.66 | 28.2 | 11.5 | 868.81 | 81.95 |
| 2022-04 | 255.4 | 16.77 | 27.3 | 6.5 | 873.96 | 83.97 |
| 2022-05 | 62.2 | 13.52 | 24.9 | 1.6 | 870.63 | 82.57 |
| 2022-06 | 41.8 | 13.40 | 24.8 | 2.8 | 872.38 | 76.69 |
| 2022-07 | 23.0 | 13.31 | 26.1 | 2.6 | 868.66 | 78.47 |
| 2022-08 | 227.8 | 13.05 | 26.1 | 1.0 | 872.34 | 79.03 |
| 2022-09 | 240.4 | 13.77 | 29.5 | 3.9 | 871.29 | 79.17 |
| 2022-10 | 86.8 | 18.05 | 28.7 | 8.5 | 888.75 | 79.05 |
| 2022-11 | 258.2 | 16.54 | 26.0 | 7.4 | 886.15 | 81.75 |
| 2022-12 | 800.4 | 16.61 | 28.8 | 7.7 | 861.01 | 81.30 |
| 2023-01 | 650.4 | 18.12 | 28.2 | 9.1 | 873.20 | 82.02 |
| 2023-02 | 246.8 | 20.65 | 29.2 | 14.1 | 896.47 | 78.93 |
| 2023-03 | 116.2 | 19.56 | 27.9 | 10.3 | 899.01 | 80.72 |
| 2023-04 | 240.4 | 17.58 | 26.4 | 6.4 | 898.19 | 82.64 |
| 2023-05 | 78.8 | 14.67 | 24.2 | 4.5 | 900.69 | 82.73 |
| 2023-06 | 32.4 | 13.28 | 23.6 | 2.5 | 902.25 | 81.30 |

| Período | Precipitação Total (mm) | Temperatura Média (°C) | Temperatura Máxima (°C) | Temperatura Mínima (°C) | Pressão Atmosférica (mB) | Umidade Relativa (%) |
|---|---|---|---|---|---|---|
| 2023-07 | 60.8 | 14.00 | 25.9 | 1.8 | 902.40 | 80.31 |
| 2023-08 | 94.6 | 15.37 | 29.9 | 2.6 | 900.40 | 79.59 |
| 2023-09 | 45.4 | 17.67 | 30.9 | 6.8 | 899.85 | 76.83 |
| 2023-10 | 342.4 | 19.29 | 29.5 | 13.0 | 892.14 | 83.42 |
| 2023-11 | 206.8 | 19.01 | 33.3 | 7.9 | 876.32 | 79.74 |
| 2023-12 | 92.6 | 19.64 | 29.0 | 11.3 | 873.65 | 85.14 |
| 2024-01 | 19.4 | 20.11 | 29.6 | 13.0 | 886.13 | 85.52 |
| 2024-02 | 190.0 | 18.97 | 27.8 | 10.9 | 865.80 | 86.89 |
| 2024-03 | 213.0 | 19.91 | 30.0 | 10.3 | 884.45 | 84.38 |
| 2024-04 | 40.2 | 18.24 | 27.4 | 9.4 | 893.21 | 81.33 |
| 2024-05 | 73.4 | 16.44 | 27.9 | 5.7 | 864.66 | 78.89 |
| 2024-06 | 9.0 | 14.30 | 24.0 | 4.1 | 865.98 | 71.18 |
| 2024-07 | 59.6 | 13.49 | 25.8 | 0.4 | 867.24 | 69.15 |
| 2024-08 | 146.8 | 13.69 | 28.1 | 1.3 | 866.35 | 62.00 |
| 2024-09 | 81.0 | 17.00 | 29.6 | 7.5 | 864.80 | 62.94 |
| 2024-10 | 126.4 | 16.94 | 29.9 | 8.5 | 874.38 | 78.42 |
| 2024-11 | 263.8 | 18.56 | 29.0 | 11.3 | 897.22 | 79.75 |
| 2024-12 | 253.0 | 19.99 | 30.0 | 12.3 | 894.46 | 80.76 |

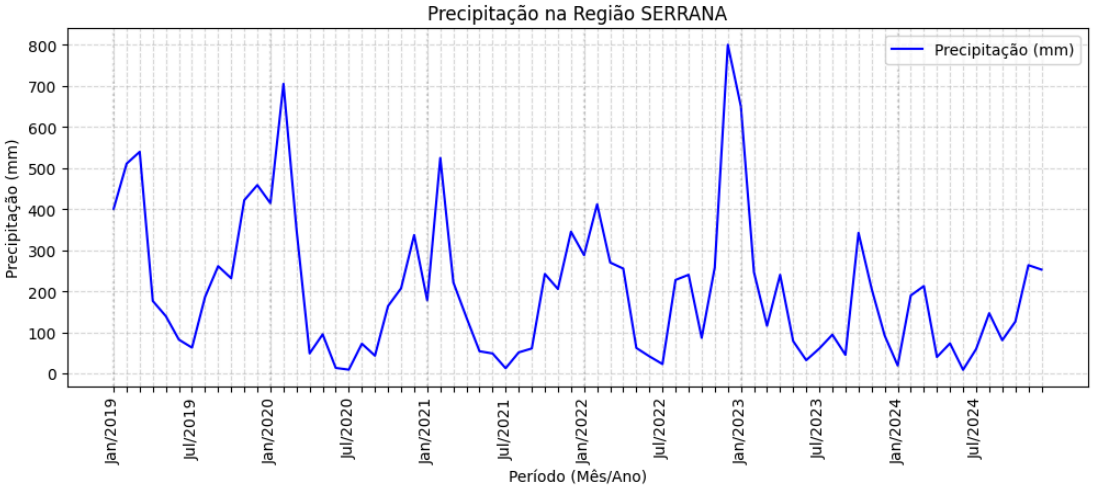
Dados Anuais

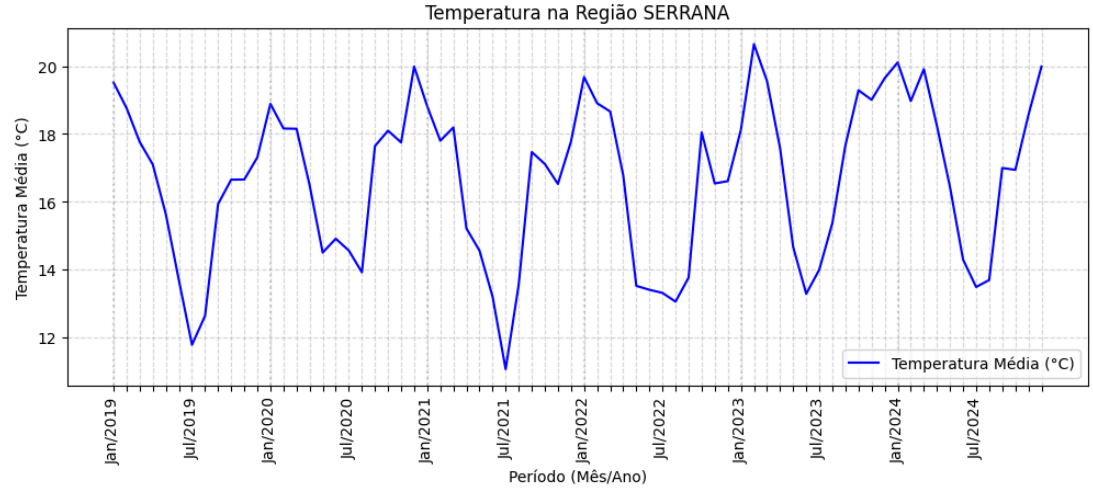
| Ano | Precipitação Anual Total (mm) | Máxima Mensal de Chuva (mm) | Mínima Mensal de Chuva (mm) | Temperatura Média Anual (°C) | Temperatura Máxima Absoluta (°C) | Temperatura Mínima Absoluta (°C) | Pressão Atmosférica (mB) | Umidade Relativa Média (%) |
|---|---|---|---|---|---|---|---|---|
| 2019 | 3473.4 | 539.8 | 63.0 | 16.12 | 31.2 | 1.1 | 864.11 | 84.66 |
| 2020 | 2462.0 | 705.2 | 9.4 | 16.92 | 32.4 | 2.6 | 893.87 | 80.57 |
| 2021 | 2082.6 | 524.8 | 12.8 | 15.94 | 30.2 | 0.0 | 874.92 | 81.64 |

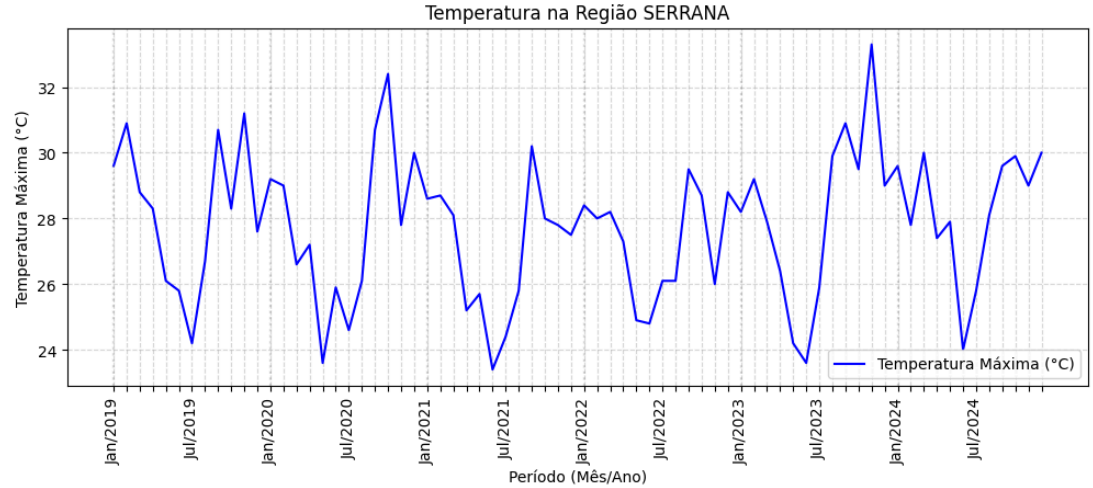
| Ano | Precipitação Anual Total (mm) | Máxima Mensal de Chuva (mm) | Mínima Mensal de Chuva (mm) | Temperatura Média Anual (°C) | Temperatura Máxima Absoluta (°C) | Temperatura Mínima Absoluta (°C) | Pressão Atmosférica (mB) | Umidade Relativa Média (%) |
|---|---|---|---|---|---|---|---|---|
| 2022 | 2966.4 | 800.4 | 23.0 | 16.02 | 29.5 | 1.0 | 873.95 | 80.98 |
| 2023 | 2207.6 | 650.4 | 32.4 | 17.40 | 33.3 | 1.8 | 892.88 | 81.11 |
| 2024 | 1475.6 | 263.8 | 9.0 | 17.30 | 30.0 | 0.4 | 877.06 | 76.77 |

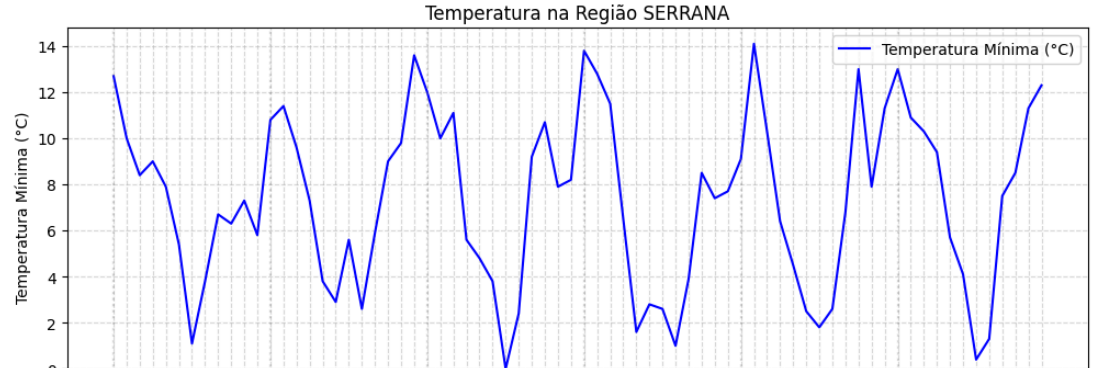
## 5. Gráfico de Análise Climática

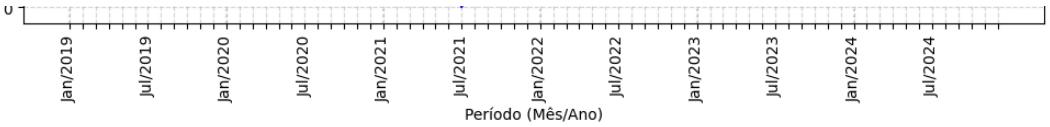
Gráficos com as tendências climáticas da região SERRANA.

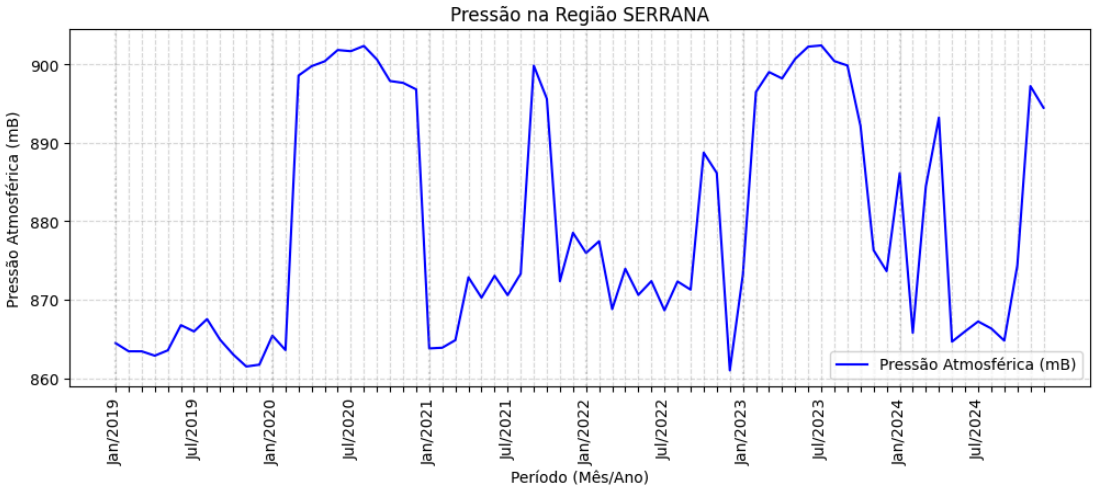

Precipitação na Região SERRANA
Precipitação (mm)
Precipitação (mm)
Período (Mês/Ano)
0
100
200
300
400
500
600
700
800
Jan/2019
Jul/2019
Jan/2020
Jul/2020
Jan/2021
Jul/2021
Jan/2022
Jul/2022
Jan/2023
Jul/2023
Jan/2024
Jul/2024

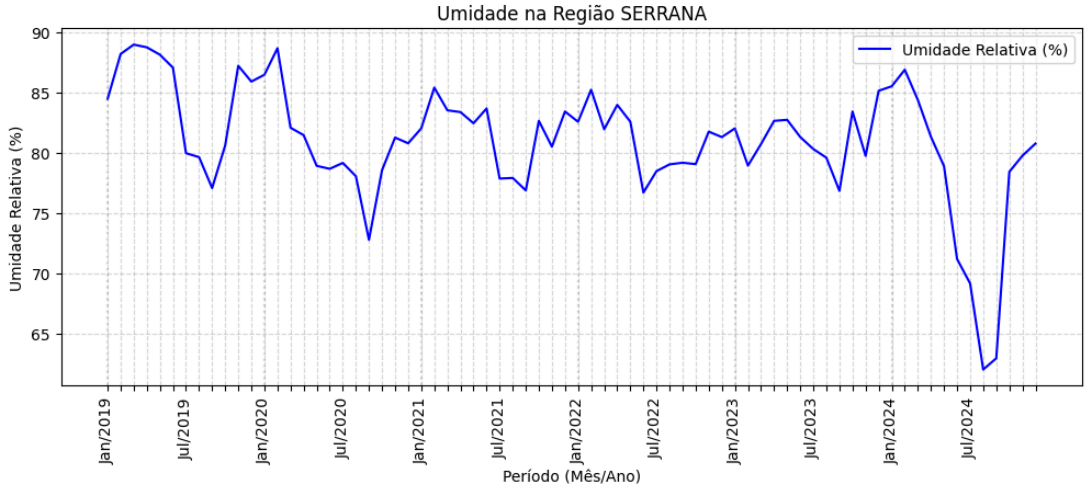

Temperatura na Região SERRANA
Temperatura Média (°C)
Temperatura Média (°C)
Período (Mês/Ano)
12
14
16
18
20
Jan/2019
Jul/2019
Jan/2020
Jul/2020
Jan/2021
Jul/2021
Jan/2022
Jul/2022
Jan/2023
Jul/2023
Jan/2024
Jul/2024


Temperatura na Região SERRANA
Temperatura Máxima (°C)
Temperatura Máxima (°C)
Período (Mês/Ano)
24
26
28
30
32
Jan/2019
Jul/2019
Jan/2020
Jul/2020
Jan/2021
Jul/2021
Jan/2022
Jul/2022
Jan/2023
Jul/2023
Jan/2024
Jul/2024


Temperatura na Região SERRANA
Temperatura Mínima (°C)
Temperatura Mínima (°C)
0
2
4
6
8
10
12
14

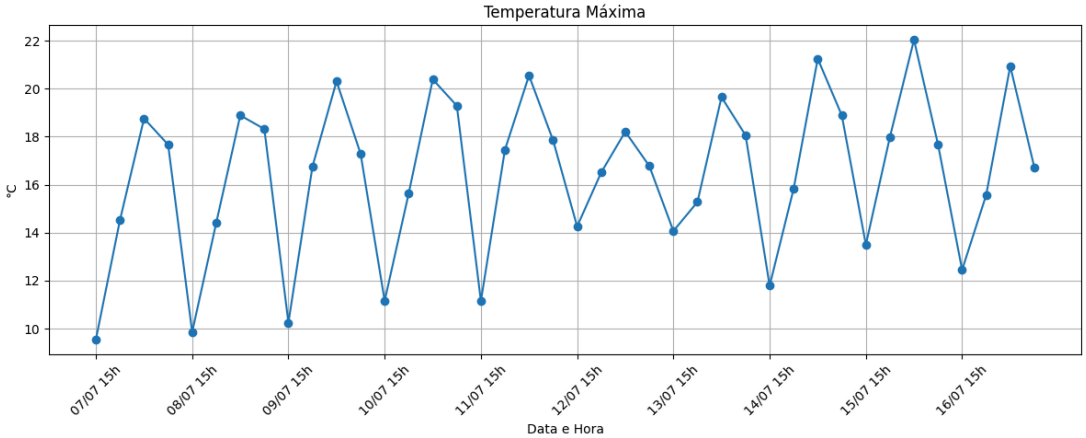


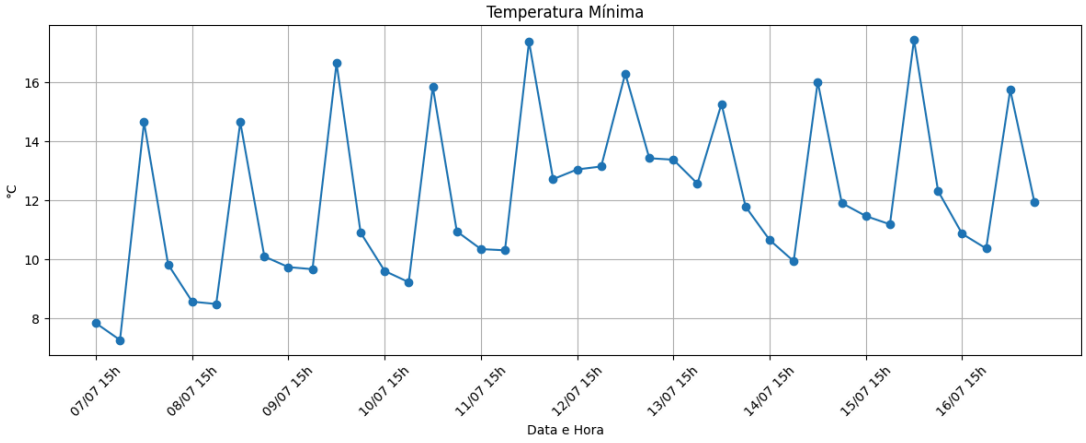




## 6. Previsão dos próximos 10 dias de Clima

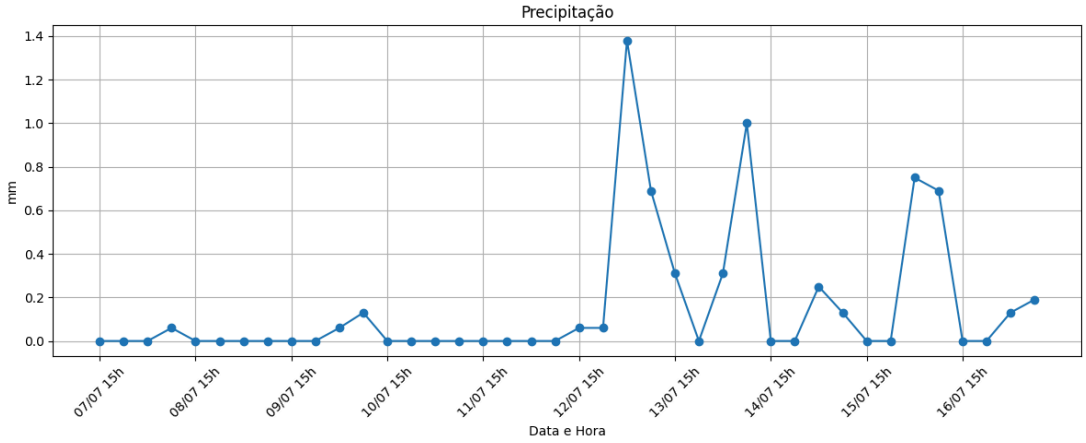
Gráficos com as temperaturas máximas dos próximos 10 dias da região SERRANA.




Gráficos com as temperaturas mínimas dos próximos 10 dias da região SERRANA.




Gráficos com o volume de chuvas dos próximos 10 dias da região SERRANA.




**Cidades na região:** Bom Jardim, Cantagalo, Carmo, Cordeiro, Duas Barras, Macuco, Nova Friburgo, Santa Maria Madalena, Sapucaia, Sumidouro, São José do Vale do Rio Preto, São Sebastião do Alto, Teresópolis, Trajano de Morais

## 7. Recomendações Gerais de Adubagem e Calagem

**Fonte:** Manual de adubagem e calagem da Embrapa, 2013, **Autor:** Luiz Rodrigues Freire

As recomendações de nutrientes constantes das planilhas referentes às culturas foram elaboradas com base nas informações sobre respostas das culturas à adubação e à calagem, resultantes das experiências de especialistas, aplicadas e adaptadas às especificidades da agricultura fluminense. As recomendações oferecem ao usuário sugestões que o ajudarão a tomar decisões quanto à quantidade de insumos a ser utilizada em cada situação.

Neste capítulo, estão apresentados os critérios gerais de obtenção dessas recomendações, além de outras informações de interesse dos usuários. Algumas planilhas exibem os dados sobre a extração de nutrientes da cultura, os quais poderão ser utilizados para adequar a recomendação que consta da planilha, desde que se apliquem os cálculos apropriados.

## 7.1 Critérios Gerais

As sugestões de adubação foram baseadas na adubação por ciclo de produção. Em alguns casos, os dados divulgados poderão ser aplicados à adubação corretiva, mas cumpre lembrar que essa não foi a meta deste trabalho.

Para determinar a quantidade de fósforo, potássio e calcário a ser utilizada, foram estabelecidas classes de interpretação das análises químicas do solo, por meio dos critérios apresentados a seguir. Da mesma forma, foram apresentados os critérios que foram adotados para o estabelecimento das recomendações de nitrogênio e de adubação orgânica. A carência de pesquisa básica sobre a utilização de micronutrientes restringiu a apresentação de dados apenas à sua recomendação; assim, somente nos casos em que a experimentação permitia, foram feitas menções a eles.

### 7.1.1 Fósforo

Para o fósforo, à exceção das culturas de cana-de-açúcar e aspargo, foram estabelecidas cinco classes de interpretação dos teores encontrados nas análises:

- **Muito baixo:** até 5 mg $dm^{-3}$ de P
- **Baixo:** de 6 mg $dm^{-3}$ a 10 mg $dm^{-3}$ de P
- **Médio:** de 11 mg $dm^{-3}$ a 20 mg $dm^{-3}$ de P
- **Alto:** de 21 mg $dm^{-3}$ a 30 mg $dm^{-3}$ de P
- **Muito alto:** maior do que 30 mg $dm^{-3}$ de P

Essas classes, contudo, não são aplicadas genericamente a todas as culturas. A expectativa da ocorrência de diferenças no comportamento das espécies vegetais no tocante à absorção e ao aproveitamento do fósforo presente na solução do solo, aliada ao maior ou menor grau de refinamento das informações disponíveis, levou à adoção de conjuntos de classes para os teores de fósforo e o grupamento de culturas.

Para a cultura de cana-de-açúcar, que não figura na Tabela 1, foi adotado um critério diferente daquele das demais culturas, já que existe experimentação própria, com método de análise específica, que leva a resultados analíticos diversos dos obtidos com o usado paras as outras culturas no Estado do Rio de Janeiro.

O conjunto A está constituído por culturas que têm apresentado resposta reduzida ou mesmo nula à aplicação de adubos fosfatados, quando o solo possui teores, revelados pela análise, superiores a 10 mg dm-3 de P. Provavelmente, isso se deve a vários fatores: à maior capacidade dessas culturas em absorver P do solo, à presença de micorrizas, ao maior volume de raízes no solo, à baixa exigência em fósforo, ou, no caso específico do arroz cultivado em várzeas úmidas, às modificações na disponibilidade do fósforo nativo, ao se alterarem as condições do potencial redox da camada do solo em que se concentra seu sistema radicular.

No conjunto B, figuram espécies vegetais para as quais não se dispõe de dados que justifiquem a separação em classes para os valores de 0 a 10 mg dm-3 e de 11 mg dm-3 a 30 mg dm-3 de P, o que motivou a adoção de somente três níveis de interpretação. A cultura de pinhão-manso, de recente introdução no Rio de Janeiro, foi inserida em novo agrupamento, com base nas expectativas de sua resposta à adubação com fósforo.

No conjunto D, está agrupado o maior número de espécies cultivada no Rio de Janeiro e para as quais já se adotavam as classes de interpretação apresentadas, não tendo sido considerada necessária a introdução de alterações quanto aos níveis de interpretação vigentes. Contudo, para as recomendações de adubação fosfatada, foram feitas modificações, com o objetivo de aperfeiçoá-las. As quantidades sugeridas constam das planilhas correspondentes.

Nos conjuntos E e F, foi feita a separação dos teores de fósforo revelados pela análise em somente duas categorias, as quais foram definidas levando em consideração aspectos já apresentados e, também, o sistema de manejo preconizado para essas espécies. Assim, o valor de 20 mg dm-3 de P para o conjunto F expressa o limite para definir uma determinada dose de fósforo, sem, contudo, deixar de usá-lo na adubação mineral, mesmo quando forem elevados os níveis desse

elemento no solo. Já no conjunto E, constituído por espécies florestais de reconhecida rusticidade, adotou-se o valor de 10 mg dm-3 de P, para determinar se deveria ser usada a adubação fosfatada em baixa dosagem ou se ela poderia ser dispensada.

**Tabela 1.** Agrupamento de culturas em conjunto de classes para os teores de fósforo.

| Conjunto | Classes de teores de P (mg dm⁻³) | Cultura |
|---|---|---|
| A | Até 5, 6–10, > 10 | Arroz, café (produção), feijão-mauá (macáçar), mandioca e inhame |
| B | Até 10, 11–30, > 30 | Abacate (plantio e formação), abacaxi, banana, cebola, coco, eucalipto, frutas cítricas, goiaba, maçã (formação), mamão, manga (plantio e formação), maracujá, nectarina (formação e produção), pera (formação), pêssego (formação e produção) e quiabo |
| C | Até 10, 11–20, > 20 | Pinhão-manso |
| D | Até 10, 11–20, 21–30, > 30 | Abóbora, abobrinha, alface, alho, amendoim, aspargo, batata-doce, batata-inglesa, berinjela, beterraba, brócolos, cenoura, chuchu, couve, couve-flor, ervilha-vagem, feijão-de-vagem, feijão, pepino tutorado e rasteiro, formação e manutenção de capineiras e de forrageiras, jiló, mandioquinha-salsa, mamona, maxixe, melancia, melão, milho, moranga, nabo, pimenta, pimentão, rabanete, repolho, soja, sorgo granífero e tomate |
| E | Até 10, > 10 | Leguminosas, arbóreas e arbustivas, e seringueira |
| F | Até 20, > 20 | Abacate (produção), café (plantio), caqui e figo (formação), maçã (plantio), manga (produção), nectarina (plantio), pera (plantio), pêssego (plantio) e urucu |

### 7.1.2 Potássio

Para o potássio, foram estabelecidas quatro classes de interpretação dos teores encontrados nas análises:

- **Baixo:** até 45 mg dm⁻³ de K
- **Médio:** de 46 mg dm⁻³ a 90 mg dm⁻³ de K
- **Alto:** de 91 mg dm⁻³ a 135 mg dm⁻³ de K
- **Muito alto:** teores superiores a 135 mg dm⁻³ de K

Por razões explicitadas no item anterior, não foi incluída nessas classes a cultura de cana-de-açúcar e, para as explorações com plantas ornamentais, foi adotado um valor limite (de 270 mg dm-3 de K), acima do qual não se recomenda a adubação com adubo mineral contendo potássio. Por motivos semelhantes aos já expostos para o fósforo, adotou-se a separação das classes em conjuntos por grupo de culturas, conforme mostra a Tabela 2.

**Tabela 2.** Agrupamento de culturas em conjunto de classes para os teores de potássio.

| Conjunto | Classes de teores de K (mg dm⁻³) | Cultura |
|---|---|---|
| A | Até 45, > 45 | Feijão-mauá (macáçar), leguminosas arbóreas e arbustivas, maçã (plantio), mandioca, pera (plantio), seringueira e urucu |
| B | Até 45, 46–90, >90 | Abacaxi (produção), alho, arroz, amendoim, café (plantio e produção), cebola, eucalipto, feijão, inhame, mamão, maracujá (produção), milho, nectarina (plantio), pêssego (plantio), pinhão-manso, quiabo, soja e sorgo granífero |
| C | Até 45, 46–90, 91–135, >135 | Abóbora, abobrinha, alface, aspargo, batata-doce, batata-inglesa, berinjela, beterraba, brócolos, cenoura, chuchu, couve, couve-flor, ervilha-vagem, feijão-de-vagem, formação e manutenção de capineiras e de forrageiras, girassol, jiló, mamona, mandioquinha-salsa, melancia, melão, moranga, maxixe, nabo, pepino tutorado e rasteiro, pimenta, pimentão, tomate, rabanete e repolho |

| Conjunto | Classes de teores de K (mg $dm^{-3}$) | Cultura |
|---|---|---|
| D | Até 90, 91–135, >135 | Abacate, banana, caqui, coco, figo, frutas cítricas, goiaba, maçã (formação), manga (plantio e produção), nectarina (formação e produção), pera (formação) e pêssego (formação e produção) |
| E | Até 90, 91–135, 136–270, >270 | Antúrio, crisântemo, gladíolo e rosa |

No conjunto A, estão culturas que têm apresentado reduzidas ou inconsistentes respostas econômicas à aplicação de adubos minerais contendo potássio quando o teor desses, revelado nas análises de terra, é superior a 45 mg dm-3 de K. A inclusão de algumas espécies frutíferas nessa categoria deve-se ao fato de se tratar de adubação complementar à orgânica, na fase de plantio; para as fases de formação e produção, contudo, essas espécies são objeto de outra avaliação.

No conjunto B, estão presentes culturas cuja recomendação de potássio está vinculada ao limite de 90 mg dm-3 de K, não estando disponíveis informações que permitam recomendação segura de adubos minerais que contenham potássio quando os teores revelados pela análise forem superiores àquele valor.

O conjunto C, além de outras culturas, é constituído por espécies de hortaliças para as quais não se espera resposta economicamente consistente quando as análises do solo revelarem teores superiores a 135 mg dm-3 de K. Também se levou em consideração que os sistemas de produção adotados no Estado do Rio de Janeiro, com o uso frequente de adubos orgânicos, levam à existência de potássio disponível em quantidade provavelmente suficiente para altas produções. Para a batatinha foi feita uma exceção, em virtude das elevadas exigências dessa cultura em potássio; nesse caso, há a recomendação de aplicação de adubo mineral potássico mesmo para teores superiores a 135 mg dm-3 de K.

No conjunto D, figuram culturas perenes exigentes em potássio, e para as quais foram adotadas classes de fertilidade cujo limite inferior corresponde a 90 mg dm-3 de K, visando a diminuir a probabilidade de comprometer a produtividade dessas espécies por inadequado suprimento de potássio.

As classes que constituem o conjunto E diferem das que compõem o conjunto anterior pela adoção do valor 270 mg dm-3 de K como limite para o emprego de adubo mineral potássico. As culturas abrangidas nesse conjunto são espécies ornamentais para as quais, regionalmente, ainda não estão disponíveis dados experimentais. Essas culturas recebem elevadas adubações potássicas nos níveis inferiores e, geralmente, são cultivadas com o uso de adubos orgânicos. Além disso, nem sempre a irrigação é feita de forma controlada, o que estimula a lixiviação.

### 7.1.3 Calagem

A recomendação de calagem considera a exigência das culturas quanto ao cálcio e ao magnésio, ou a tolerância delas ao teor de alumínio trocável. Os critérios utilizados estão descritos a seguir:

- Quando o teor de $Al^{3+}$ for menor que 0,3 $cmol_a\ dm^{-3}$ de TFSA e a soma dos teores de cálcio e magnésio for superior a 3 $cmol_a\ dm^{-3}$ de TFSA (culturas mais exigentes em cálcio e/ou magnésio), ou a 2 $cmol_a\ dm^{-3}$ de TFSA (demais culturas), não será necessária a aplicação de calcário.
- Se o teor de $Al^{3+}$ for igual a ou maior que 0,3 $cmol_a\ dm^{-3}$ de TFSA, será necessário corrigir o solo.
- Se a soma dos teores de $Ca^{2+}$ e $Mg^{2+}$ for inferior a 2 $cmol_a\ dm^{-3}$ de TFSA, ou no caso de culturas mais exigentes em cálcio e/ou magnésio, e com teor inferior a 3 $cmol_a\ dm^{-3}$ de TFSA, será necessária a aplicação de calcário para corrigir as deficiências desses nutrientes; as exigências das culturas estão definidas nas planilhas.
- Se o teor de $Mg^{2+}$ for inferior a 0,5 $cmol_a\ dm^{-3}$ de TFSA, será preciso usar calcário dolomítico ou adubação magnesiana. Para se determinar a quantidade de calcário a ser aplicada ao solo, foi elaborada a Tabela 3. Os critérios empregados estão baseados na economicidade da calagem, e os resultados experimentais obtidos com o uso desses critérios reforçam a sua adoção.

**Tabela 3.** Critérios para aplicação de calcário.

| Resultado da análise (teores em cmol $dm^{-3}$) | Cálculo da necessidade de calagem[1] | |
|---|---|---|
| $Al^{3+}$ | $Ca^{2+} + Mg^{2+}$ | |
| < 0,3 | > 2,0 | Não aplicar calcário, exceto para culturas mais exigentes, se Ca + Mg < 3,0 cmol $dm^{-3}$ |
| < 0,3 | < 3,0 | 3 - $cmol_a$ ($Ca^{2+} + Mg^{2+}$) $dm^{-3}$ (para culturas mais exigentes) |
| < 0,3 | < 2,0 | 2 - $cmol_a$ ($Ca^{2+} + Mg^{2+}$) $dm^{-3}$ |
| >= 0,3 | > 2,0 | $cmol_a$ $Al^{3+}$ $dm^{-3}$ x fator de calagem |
| >= 0,3 | > 3,0 | $cmol_a$ $Al^{3+}$ $dm^{-3}$ x fator de calagem (para culturas mais exigentes) |
| >= 0,3 | < 2,0 | $cmol_a$ $Al^{3+}$ $dm^{-3}$ x fator de calagem ou 2 - $cmol_a$ ($Ca^{2+} + Mg^{2+}$) $dm^{-3}$ (usar o valor mais alto) |
| >= 0,3 | < 3,0 | Para culturas mais exigentes: 3 - $cmol_a$ ($Ca^{2+} + Mg^{2+}$) $dm^{-3}$ ou $cmol_a$ $Al^{3+}$ $dm^{-3}$ x fator de calagem (usar o valor mais alto) |

[1] t calcário $ha^{-1}$ a 20 cm de profundidade.

### 7.1.4 Nitrogênio

Em razão da dificuldade de avaliar a contribuição da matéria orgânica para a disponibilidade de nitrogênio, e em virtude da variação das condições climáticas, não há, até o momento, critério satisfatório que permita generalizar o uso da análise de amostras de terra, como é feito para outros nutrientes, para se recomendar a adubação nitrogenada. Considerando esses fatores e a importância do nitrogênio no aumento da produtividade das culturas, utilizaram-se, para a recomendação da adubação nitrogenada, os critérios relacionados a seguir:

- Não recomendação do uso de adubação nitrogenada; em seu lugar, fazer a inoculação das sementes para as leguminosas cuja eficácia de fixação biológica está comprovada e podem dispensar a adubação nitrogenada.
- Recomendação de inoculação para o feijoeiro; no entanto, para cultura irrigada, em áreas com possibilidade de alcançar-se alta produtividade, recomenda-se a adubação orgânica ou complementação com N-mineral em cobertura.
- Utilização, para algumas culturas, das informações de pesquisa de campo para o território fluminense.
- Aproveitamento da experiência de técnicos da pesquisa e da assistência técnica, com as diversas culturas.
- Aceitação das modificações propostas pelo técnico local, em razão:
    1. Do histórico da área (cultura anterior, intensidade de cultivo na área).
    2. Dos sintomas visuais de carência ou de grande disponibilidade de nitrogênio em razão do teor de matéria orgânica do solo.
    3. Da recomendação de adubação verde para liberar o agricultor, na pior das hipóteses, de pelo menos parte da adubação nitrogenada mineral, e para usufruir dos grandes benefícios que essa prática proporciona, além de alertar o agricultor para a necessidade de adotar práticas que visem à conservação do solo.
    4. Da adoção do sistema orgânico de manejo sustentado.

### 7.1.5 Adubação Orgânica

Neste manual, a recomendação de adubação orgânica foi feita para a totalidade das culturas e teve como base de avaliação os seguintes fatores:

- As características das propriedades e do tipo de exploração predominante no estado (pequenas propriedades, mão de obra familiar e exploração diversificada).

- O potencial de resíduos agrícolas e urbanos do estado e o que podem representar esses resíduos orgânicos como fonte de insumos para o aumento e a sustentabilidade da produtividade agrícola.
- Os resultados de pesquisa, que demostram que a adubação orgânica pode contribuir bastante para melhorar a fertilidade dos solos e, consequentemente, para aumentar a produtividade dos solos pobres, para reduzir os custos de produção de muitas culturas e para dar independência parcial ou total ao agricultor com relação ao insumo-fertilizante.
- A necessidade de conscientização de agricultores, extensionistas e pesquisadores sobre o assunto, e de incentivo a obterem o máximo de aproveitamento dos resíduos orgânicos disponíveis localmente.
- As vantagens econômicas e sociais para a região, proporcionadas pelo aproveitamento adequado dos resíduos orgânicos na agricultura.

### 7.1.6 Outras Informações

As recomendações de nutrientes, constantes das planilhas por cultura, permitem, aos usuários, a definição de aquisição dos fertilizantes que melhor atendam às peculiaridades de cada exploração. Para serem aplicadas as quantidades recomendadas, poderão ser usados adubos simples ou fórmulas NPK, cuja composição será dividida pela avaliação dos parâmetros envolvidos, conforme foi explicitado nos capítulos 5 e 12. É pertinente lembrar que pequenas diferenças que não ultrapassem 5 kg de macronutrientes por hectare não apresentam efeitos relevantes na economicidade das culturas.

As recomendações relacionadas com o uso de micronutrientes estão limitadas às culturas para as quais têm sido observadas respostas às aplicações e que figuram nas planilhas correspondentes. Há, atualmente, impossibilidade do uso da análise química de amostras de terra para se estabelecer, antes do plantio, a necessidade da adubação com micronutrientes, pois não existem, no Estado do Rio de Janeiro, curvas de calibração para esses elementos.

Pode-se considerar, contudo, que, em determinadas condições, existem fortes expectativas de respostas aos micronutrientes. Por exemplo, áreas que tenham sido muito utilizadas, terrenos com reduzido teor de matéria orgânica, ambientes que favoreçam a lixiviação ou a erosão, solos ácidos, calagem excessiva e uso intensivo de fertilizantes concentrados, todas essas condições favorecem a carência de micronutrientes. A avaliação da possível deficiência pode ser feita por meio de análise foliar ou de testes de campo, da seguinte forma: em talhões adequadamente demarcados, fazer as aplicações foliares do micronutriente de cuja deficiência se suspeita, e acompanhar o desenvolvimento da planta, tanto no seu aspecto vegetativo quanto, e em especial, na sua produção.

Cumpre lembrar de qualquer forma que, se forem seguidas as recomendações apresentadas nas planilhas, principalmente no que se refere ao uso da adubação orgânica, não serão enfrentados problemas com micronutrientes.

## 8. Recomendações Inteligência Artificial

Nesta sessão, o sistema inteligente apresenta recomendações estratégicas para otimizar a produtividade agrícola, abordando quatro pilares essenciais: cultura, com a seleção de variedades adaptadas e rotação eficiente; adubagem, indicando fontes e doses ideais de nutrientes; calagem, orientando a correção do solo para equilíbrio do pH; e manejo de nitrogênio, com técnicas para maximizar a eficiência e reduzir perdas. Essas diretivas buscam aliar sustentabilidade e resultados econômicos, garantindo solo fértil e cultivos mais robustos.

## 🌱 Recomendações Agrícolas

**Condições do solo analisadas:**

Fósforo: 11.0

Potássio: 60.0

Alumínio: 0.1

Cálcio + Magnésio: 5.0

pH: 6.0

Textura: arenosa

Praga: acaro-rajado

### 👉 Recomendação de Cultura:

**Culturas:** Alface, Beterraba, Cenoura, Tomate

**Motivo:** Adequação de potássio médio com bom pH

**Culturas:** Café (Coffea arabica)

**Motivo:** Adaptado a pH moderado (5.0–6.5) e solos bem drenados com textura média

**Culturas:** Amendoim (Arachis hypogaea)

**Motivo:** Adequado em solos bem drenados com textura leve a média

**Culturas:** Pinhão-manso, abóbora, abobrinha, alface, alho, amendoim, aspargo, batata-doce, batata-inglesa, berinjela, beterraba, brócolos, cenoura, chuchu, couve, couve-flor, ervilha-vagem, feijão-de-vagem, feijão, pepino, jiló, mandioquinha-salsa, mamona, maxixe, melancia, melão, milho, moranga, nabo, pimenta, pimentão, rabanete, repolho, soja, sorgo granífero, tomate

**Motivo:** Teor de fósforo médio (11-20 mg/dm³)

**Culturas:** Abóbora, Alface, Amendoim, Batata-doce, Beterraba, Milho, Tomate

**Motivo:** Adequados níveis de P e K, baixa acidez e bom teor de Ca + Mg

**Culturas:** Mandioca, Feijão-macáçar

**Motivo:** Culturas adaptadas a solo arenoso

### 🔵 Recomendação de Calagem:

Não necessária no momento

Não necessária no momento

Dose: 1.0 t/ha

PRNT recomendado: 0%

Época de aplicação: Não especificada

### 🟢 Recomendação de Adubagem Mineral:

Tipo: P2O5

Dose: 45 kg/ha

Tipo: K2O

Dose: 60 kg/ha

Tipo: P2O5

Dose: 70 kg/ha

Tipo: K2O

Dose: 45 kg/ha

Tipo: K2O

Dose: 30 kg/ha

Tipo: P2O5

Dose: 60 kg/ha

### 🟡 Recomendação de Nitrogênio:

### 🛡️ Recomendação de Controle de Pragas:

**Praga:** acaro-rajado

**Produto:** Clorfenapir CCAB 240 SC (Registro: 28421)

**Cultura alvo:** Plantas Ornamentais

**Motivo:** Produto indicado para controle de Acaro-rajado na cultura Plantas Ornamentais.

**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO/DIVULGAÇÃO DE DOCUMENTO ELETRÔNICO NO CATÁLOGO DO SISTEMA DE BIBLIOTECAS DO CEFET/RJ E NO REPOSITÓRIO INSTITUCIONAL**

Na qualidade de titular dos direitos de autor da publicação abaixo citada, de acordo com a Lei nº 9610/98, autorizo, a partir da presente data, o CEFET/RJ, a disponibilizar gratuitamente, sem ressarcimento de direitos autorais, conforme permissões assinadas abaixo, no Catálogo Online do Sistema de Bibliotecas e no Repositório Institucional do Cefet/RJ, ou qualquer outro formato de disseminação da informação que a instituição implemente, no formato PDF, para fins de leitura, impressão e/ou download pela internet, a título de divulgação da produção científica gerada por esta Instituição.

**1- Tipo de trabalho:** [ ] Projeto Final (Graduação) [ ] Especialização
[ X ] Dissertação [ ] Tese

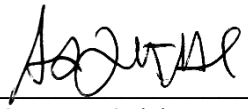
**2- Identificação do trabalho/autor(es):**

Curso:Programa de Pós-Graduação em Ciência da Computação
Título: Tecnologia e Sustentabilidade no Campo: Sistema de Recomendação para Pequenos Produtores Rurais.
Autor(es): André Luiz Coutinho Merlo
Orientador: Diego Nunes Brandão
Co-orientador:_____

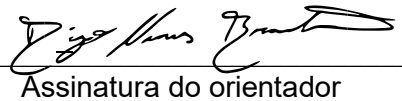
**3- Informações de acesso ao trabalho:**

Este trabalho é confidencial? [ ] Sim [ X ] Não
Pode ser liberado para publicação? [ X ] Total [ ] Parcial [ ] Não
Justifique:_____
_____
Em caso de publicação parcial, assinale as permissões:
[ ] Sumário
[ ] Capítulos. Especifique: _____
[ ] Bibliografia
[ ] Outras partes do trabalho: _____

Rio de Janeiro, 05 / 01 / 2026.



_____
Assinatura do(s) autor(es)



_____
Assinatura do orientador

_____
Assinatura do co-orientador