



PROGRAMA DE PÓS-GRADUAÇÃO em

Ciências Ambientais

ARTHUR PEREIRA DOS SANTOS

**INTEGRAÇÃO DE PARÂMETROS AMBIENTAIS E *MACHINE LEARNING* NA
MODELAGEM DO SOLO PARA AGRICULTURA SUSTENTÁVEL**

Sorocaba
2024

PROGRAMA DE PÓS-GRADUAÇÃO em

*ciências
ambientais*



unesp
Sorocaba

ARTHUR PEREIRA DOS SANTOS

**INTEGRAÇÃO DE PARÂMETROS AMBIENTAIS E *MACHINE LEARNING* NA
MODELAGEM DO SOLO PARA AGRICULTURA SUSTENTÁVEL**

Tese apresentada como requisito para a obtenção do título de Doutor em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental.

Orientador: Prof. Dr. Roberto Wagner Lourenço

Coorientador: Prof. Dr. Márcio Alexandre Marques

Sorocaba
2024

S237i

Santos, Arthur Pereira dos

Integração de parâmetros ambientais e machine learning na modelagem do solo para agricultura sustentável / Arthur Pereira dos Santos. -- Sorocaba, 2024

135 p.

Tese (doutorado) - Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba

Orientador: Roberto Wagner Lourenço

Coorientador: Márcio Alexandre Marques

1. Geoprocessamento. 2. Machine learning. 3. Ciência do solo. 4. Gestão ambiental. 5. Agricultura sustentável. I. Título.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Integração de Parâmetros Ambientais e *Machine Learning* na Modelagem do Solo para Agricultura Sustentável

AUTOR: ARTHUR PEREIRA DOS SANTOS

ORIENTADOR: ROBERTO WAGNER LOURENÇO

COORIENTADOR: MARCIO ALEXANDRE MARQUES

Aprovado como parte das exigências para obtenção do Título de Doutor em Ciências Ambientais, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:

Documento assinado digitalmente
 **ROBERTO WAGNER LOURENÇO**
Data: 18/12/2024 17:26:29-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. ROBERTO WAGNER LOURENÇO (Participação Virtual)
Departamento de Engenharia Ambiental / Instituto de Ciencia e Tecnologia Campus de Sorocaba Unesp

Documento assinado digitalmente
 **JOSE CARLOS DE SOUZA**
Data: 16/12/2024 22:26:34-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOSÉ CARLOS DE SOUZA (Participação Virtual)
Departamento de Geografia / Universidade Estadual de Goiás (UEG) - Unidade Universitária De Anápolis - CSEH - Nelson De Abreu Júnior

Profª Drª JOCY ANA PAIXÃO DE SOUSA (Participação Virtual)
Centro de Ciências Agrárias, Ambientais e Biológicas / Universidade Federal do Recôncavo da Bahia (UFRB)

Documento assinado digitalmente
 **JOCY ANA PAIXAO DE SOUSA**
Data: 17/12/2024 06:59:25-0300
Verifique em <https://validar.iti.gov.br>



Documento assinado digitalmente

KELLY CRISTINA TONELLO

Data: 18/12/2024 09:37:04-0300

Verifique em <https://validar.iti.gov.br>

Prof^a. Dr^a. KELLY CRISTINA TONELLO (Participação Virtual)

Departamento de Engenharia Florestal / Universidade Federal de São Carlos - UFSCAR



Documento assinado digitalmente

ADMILSON IRIO RIBEIRO

Data: 18/12/2024 09:49:46-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. ADMILSON IRIO RIBEIRO (Participação Virtual)

Departamento de Engenharia Ambiental / Unesp - Campus Sorocaba

Sorocaba, 12 de novembro de 2024

Dedico este trabalho a José Gonçalves dos Santos – *In memoriam* – por tudo que fez por mim
e pela minha família.

Agradecimentos

Primeiramente, agradeço a Deus e a Nossa Senhora por me guiarem até aqui e, principalmente, por me conduzirem no caminho do bem.

Aos meus pais, Maurilia e Ciro, que nunca mediram esforços para apoiar seus filhos em questões de educação e aprendizado.

Ao meu irmão, Igor, meu maior exemplo de vida.

À minha noiva, Gabryeli, por ter suportado todos os momentos difíceis ao meu lado, especialmente no último ano. Não tenho dúvidas de que todo esse esforço valerá a pena.

Ao meu orientador, Prof. Dr. Roberto Wagner Lourenço, por todos os ensinamentos e pela orientação. Estou convicto de que ofereci o meu melhor durante toda a minha trajetória no Laboratório de Geoprocessamento e Modelagem Matemática Ambiental (LABGEMM). Fica aqui o meu sincero agradecimento.

Ao Prof. Dr. Darllan Collins da Cunha e Silva, que conheci como professor e se tornou um amigo que levarei por toda a vida. A você, toda a minha gratidão, especialmente por todos os conselhos acadêmicos, profissionais e pessoais. Conte sempre comigo.

Aos meus amigos de profissão e pesquisa, Henzo Simionatto e Alessandro Xavier, agradeço por toda a ajuda e pelo apoio nos trabalhos de campo e de laboratório. Minha eterna gratidão a vocês.

Por fim, agradeço a todos os professores e técnicos da UNESP, que, durante minha estadia em Sorocaba, São Paulo (SP), sempre foram prestativos em solucionar minhas dúvidas e questões relacionadas à pesquisa.

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

“É justo que muito custe o que muito vale” (Santa Teresa D'Ávila).

RESUMO

O modelo agrícola convencional, embora contribua para o aumento da produção de alimentos, está associado a impactos ambientais que comprometem sua sustentabilidade a longo prazo. Para mitigar esses impactos, a Organização das Nações Unidas (ONU) propõe, por meio dos Objetivos de Desenvolvimento Sustentável (ODS), a eliminação da fome através de práticas agrícolas sustentáveis. Nesse contexto, o aprimoramento das técnicas de Agricultura de Precisão (AP), aliado ao entendimento do solo como um sistema dinâmico de aptidão fértil, tem se mostrado promissor. Esse avanço é impulsionado pelo uso de imagens de satélite e pela aplicação de Inteligência Artificial (IA), especialmente técnicas de *Machine Learning* (ML), com destaque para o algoritmo *Random Forest* (RF), utilizado neste estudo para modelar a Bacia Hidrográfica do Rio Sorocabaçu (BHRS) e identificar áreas mais e menos aptas ao cultivo de olerícolas. Foram realizadas análises físico-químicas em 27 pontos amostrais da BHRS, e os resultados foram segmentados em classes de teor de fertilidade agrícola. A modelagem textural do solo foi conduzida com técnicas de ML, enquanto análises estatísticas multivariadas investigaram o comportamento das concentrações dos parâmetros físico-químicos, identificando variáveis significativas que influenciam a aptidão agrícola da bacia hidrográfica. Além disso, as classes de declividade e a distância euclidiana aos corpos hídricos foram utilizadas para segmentar áreas em níveis de aptidão agrícola. Uma amostragem proporcional estratificada, baseada na extensão territorial de cada classe textural do solo, permitiu treinar o algoritmo RF para classificar as áreas como mais aptas, medianamente aptas ou menos aptas ao cultivo de olerícolas. Os resultados, validados com dados de campo, confirmaram a robustez do modelo e indicaram uma predominância da classe textural argilosa na BHRS. Em relação aos micronutrientes, foi observada uma boa distribuição espacial dos teores de Cobre (Cu), Manganês (Mn) e, parcialmente, Zinco (Zn), enquanto o Boro (B) e o Ferro (Fe) apresentaram, respectivamente, classes de baixo e alto teor predominantes. Quanto aos macronutrientes, a BHRS demonstrou predisposição ao Enxofre (S), Magnésio (Mg) e Cálcio (Ca), com boa distribuição espacial, mas revelou deficiências em P-resina e Potássio (K). O solo da bacia hidrográfica foi caracterizado por acidez baixo-média (pH). A análise estatística apontou variações significativas na Capacidade de Troca Catiônica (CTC), Mg, S, Saturação por Bases (V%), Cu, Matéria Orgânica (MO), P-resina e Zn entre as classes texturais predominantes. A declividade foi identificada como a variável mais influente nas decisões do algoritmo, destacando a relevância da topografia na produtividade agrícola e reforçando a necessidade de práticas conservacionistas e planejamento territorial, essenciais para mitigar impactos ambientais negativos que podem comprometer a capacidade produtiva do solo. Os resultados obtidos oferecem subsídios importantes para o cumprimento das metas dos ODS 2, 12 e 13 da ONU. Modelos semelhantes podem ser desenvolvidos considerando os parâmetros mais relevantes, simplificando futuras aplicações. Além disso, recomenda-se a segmentação por sub-bacias hidrográficas para uma gestão mais eficiente, priorizando práticas conservacionistas que maximizem o potencial produtivo e assegurem a sustentabilidade da BHRS.

Palavras-chave: Segurança Alimentar. Produção Agrícola Sustentável. Cultivo de Olerícolas. Inteligência Artificial. Geoprocessamento. *Random Forest*.

ABSTRACT

The conventional agricultural model, although contributing to increased food production, is associated with environmental impacts that threaten its long-term sustainability. To mitigate these impacts, the United Nations (UN) proposes, through the Sustainable Development Goals (SDGs), the elimination of hunger via sustainable agricultural practices. In this context, the enhancement of Precision Agriculture (PA) techniques, combined with the understanding of soil as a dynamic system of fertile suitability, has shown promise. This advancement is driven by the use of satellite imagery and the application of Artificial Intelligence (AI), especially Machine Learning (ML) techniques, with particular emphasis on the Random Forest (RF) algorithm, used in this study to model the Sorocabuçu River Basin (SRB) and identify areas more and less suitable for vegetable crop cultivation. Physico-chemical analyses were conducted at 27 sampling points within the SRB, and the results were segmented into classes of agricultural fertility levels. Soil texture modeling was performed using ML techniques, while multivariate statistical analyses investigated the behavior of the concentrations of physico-chemical parameters, identifying significant variables that influence the agricultural suitability of the watershed. Additionally, slope classes and Euclidean distance to water bodies were used to segment areas into agricultural suitability levels. A stratified proportional sampling, based on the territorial extent of each soil texture class, was used to train the RF algorithm to classify areas as more suitable, moderately suitable, or less suitable for vegetable cultivation. The results, validated with field data, confirmed the robustness of the model and indicated a predominance of clayey texture class in the SRB. Regarding micronutrients, a good spatial distribution of Copper (Cu), Manganese (Mn), and partially Zinc (Zn) was observed, while Boron (B) and Iron (Fe) showed, respectively, predominant classes of low and high content. As for macronutrients, the SRB demonstrated a predisposition to Sulfur (S), Magnesium (Mg), and Calcium (Ca), with good spatial distribution, but revealed deficiencies in Resin Phosphorus (P-resin) and Potassium (K). The soil of the watershed was characterized by low-medium acidity (pH). Statistical analysis revealed significant variations in Cation Exchange Capacity (CEC), Mg, S, Base Saturation (V%), Cu, Organic Matter (OM), P-resin, and Zn among the predominant texture classes. Slope was identified as the most influential variable in the algorithm's decisions, highlighting the relevance of topography in agricultural productivity and reinforcing the need for conservation practices and territorial planning, essential for mitigating negative environmental impacts that may compromise the soil's productive capacity. The results obtained provide important insights for achieving the UN SDGs 2, 12, and 13. Similar models can be developed by considering the most relevant parameters, simplifying future applications. Furthermore, it is recommended to segment by sub-basins for more efficient management, prioritizing conservation practices that maximize productive potential and ensure the sustainability of the SRB.

Keywords: Food Security, Sustainable Agricultural Production, Vegetable Cultivation, Artificial Intelligence, Geoprocessing, Random Forest.

LISTA DE FIGURAS

Figura 1	- Etapas realizadas para alcançar o objetivo do presente trabalho.....	22
Figura 2	- Localização da área de estudo.....	32
Figura 3	- Localização dos pontos de coleta do solo na BHRS.....	35
Figura 4	- Modelo de treino e validação do algoritmo RF para os procedimentos de classificação textural do solo.....	40
Figura 5	- Diagrama textural do solo.....	42
Figura 6	- Distribuição espacial de argila (a), areia (b), silte (c) e declividade (d) da BHRS.....	52
Figura 7	- Classificação da textura do solo da BHRS gerado com base no algoritmo RF.....	58
Figura 8	- Distribuição espacial de areia, silte e argila nas classes de textura do solo da BHRS.....	59
Figura 9	- Importância das classes no modelo gerado.....	62
Figura 10	- Geração de erros do modelo de textura do solo com base no número de árvores.....	63
Figura 11	- Distribuição espacial dos micronutrientes em relação às classes de teor para o cultivo de olerícolas na BHRS.....	66
Figura 12	- Distribuição espacial dos macronutrientes em relação às classes de teor para o cultivo de olerícolas na BHRS.....	73
Figura 13	- Distribuição espacial dos demais nutrientes importantes para a fertilidade do solo.....	81
Figura 14	- PCA dos parâmetros físico-químicos entre as classes de textura do solo na BHRS.....	90
Figura 15	- Resultados estatísticos para a escolha dos parâmetros na modelagem final: micronutrientes.....	92
Figura 16	- Resultados estatísticos para a escolha dos parâmetros na modelagem final: macronutrientes.....	92
Figura 17	- Resultados estatísticos para a escolha dos parâmetros na modelagem final: demais parâmetros influentes na fertilidade agrícola.....	93

Figura 18	- Classes de aptidão agrícola em função da distância das áreas em relação aos corpos hídricos (a) e do nível de declividade (b).....	94
Figura 19	- Classificação da aptidão agrícola na BHRS com base no algoritmo RF	96
Figura 20	- Importância das variáveis para a geração do modelo de aptidão agrícola.....	97
Figura 21	- Erro OOB em função do número de árvores no treinamento do modelo.....	98
Figura 22	- Cultivo de olerícolas cercado por vegetação em área de declive acentuado.....	100
Figura 23	- Cultivo de olerícolas com sistema de irrigação em área de declive acentuado, próximo ao corpo hídrico.....	101

LISTA DE QUADROS

Quadro 1 -	Definição das classes de declividade variando em função das características do local para o uso agrícola.....	39
-------------------	---	-----------

LISTA DE TABELAS

Tabela 1	- Caracterização dos pontos de coleta do solo na BHRS.....	35
Tabela 2	- Resultados da análise granulométrica.....	51
Tabela 3	- Estatística descritiva da distribuição espacial da areia, silte e argila.....	52
Tabela 4	- Área e porcentual das classes de declividade na BHRS.....	53
Tabela 5	- Quantitativo de classes de textura do solo da BHRS.....	58
Tabela 6	- Desempenho do algoritmo RF para classificação textural do solo na BHRS.....	61
Tabela 7	- Estatística das classes de textura do solo na BHRS.....	62
Tabela 8	- Valores de cada ponto amostral para os micronutrientes (mg/dm ³).....	64
Tabela 9	- Distribuição espacial dos micronutrientes do solo na BHRS (mg/dm ³)....	66
Tabela 10	- Área e porcentual das classes de micronutrientes do solo para o cultivo de olerícolas na BHRS.....	67
Tabela 11	- Valores de cada ponto amostral para os macronutrientes (mmolc/dm ³)....	71
Tabela 12	- Distribuição espacial dos macronutrientes do solo na BHRS.....	73
Tabela 13	- Área e porcentual dos teores para cultivo de olerícolas dos macronutrientes.....	74
Tabela 14	- Valores de cada ponto amostral para os demais parâmetros químicos influentes na fertilidade agrícola.....	80
Tabela 15	- Distribuição espacial dos demais parâmetros influentes na fertilidade do solo do solo na BHRS.....	81
Tabela 16	- Área e porcentual dos teores para cultivo de olerícolas dos parâmetros analisados.....	82
Tabela 17	- Área e porcentagem das classes de declividade e distância dos corpos hídricos relacionadas à aptidão agrícola.....	94
Tabela 18	- Distribuição espacial das classes de aptidão agrícola na BHRS.....	97
Tabela 19	- Estatística das classes de aptidão agrícola na BHRS.....	97

LISTA DE ABREVIATURAS E SIGLAS

Al	=	Alumínio
AP	=	Agricultura de Precisão
APA	=	Área de Preservação Ambiental
B	=	Boro
BHRS	=	Bacia Hidrográfica do Rio Sorocabuçu
Ca	=	Cálcio
CEAGESP	=	Companhia de Entrepósitos e Armazéns Gerais de São Paulo
Cl	=	Cloro
Co	=	Cobalto
CO₂	=	Dióxido de carbono
CTC	=	Capacidade de troca catiônica
Cu	=	Cobre
Cwa	=	Clima subtropical de inverno seco e verão quente
dm	=	Decímetro
EMBRAPA	=	Empresa Brasileira de Pesquisa Agropecuária
Fe	=	Ferro
g	=	Grama
GLM	=	Modelo Linear Generalizado
H+Al	=	Potencial de acidez
IA	=	Inteligência Artificial
IAC	=	Instituto Agronômico de Campinas
IBGE	=	Instituto Brasileiro de Geografia e Estatística
IDW	=	Inverse Distance Weighted
K	=	Potássio
m	=	Metro
Mg	=	Magnésio
mg	=	Miligrama
ML	=	<i>Machine Learning</i>
mmol	=	Milimol
Mn	=	Manganês
MO	=	Matéria orgânica

N	=	Nitrogênio
Na	=	Sódio
Ni	=	Níquel
NPV	=	Negative Predictive Value
ODS	=	Objetivos de Desenvolvimento Sustentável
ONU	=	Organização das Nações Unidas
OOB	=	<i>Out-Of-Bag</i>
P	=	Fósforo
PCA	=	Análise de Componentes Principais
pH	=	Potencial hidrogeniônico
PPV	=	Positive Predictive Value
RF	=	<i>Random Forest</i>
S	=	Enxofre
SB	=	Soma das Bases
Se	=	Selênio
Si	=	Silício
SP	=	São Paulo
SR	=	Sensoriamento Remoto
V%	=	Porcentagem de saturação por bases
Zn	=	Zinco

SUMÁRIO

1	INTRODUÇÃO.....	19
2	OBJETIVOS.....	21
2.1	Objetivo geral.....	21
2.2	Objetivos específicos.....	21
3	ESTRUTURA DO TRABALHO.....	22
4	REVISÃO BIBLIOGRÁFICA.....	23
4.1	Olericultura: importância, manejo sustentável e impacto na produtividade agrícola.....	23
4.2	Estrutura, nutrientes e textura do solo: importantes aliados da fertilidade agrícola.....	24
4.3	Produtividade agrícola potencializada pelas tecnologias de detecção remota.....	27
4.4	Técnicas de <i>Machine Learning</i> como instrumento norteador das práticas agrícolas.....	29
5	MATERIAIS E MÉTODOS.....	32
5.1	Área de estudo.....	32
5.2	Procedimentos metodológicos.....	33
5.2.1	Plano amostral e análise físico-química do solo.....	33
5.2.2	Interpolação dos dados e estatística descritiva.....	37
5.2.3	Mapeamento da declividade do terreno.....	38
5.2.4	Elaboração do plano amostral e aplicação de ML para classificar a textura do solo da BHRS.....	39
5.3	Modelagem da aptidão agrícola para o cultivo de olerícolas na BHRS por meio do algoritmo RF.....	45
5.3.1	Análise estatística multivariada.....	45
5.3.2	Segmentação das classes de declividade em níveis de aptidão agrícola.....	46
5.3.3	Cálculo da distância euclidiana entre os corpos hídricos e segmentação em classes de aptidão agrícola.....	47
5.3.4	Amostragem proporcional estratificada.....	48

5.3.5	Modelagem do algoritmo RF para classificar a aptidão agrícola da BHRS em relação à olericultura.....	49
6	RESULTADOS E DISCUSSÕES.....	51
6.1	Análise granulométrica e da declividade da BHRS.....	51
6.2	Geração do modelo das classes de textura do solo baseado no algoritmo <i>Random Forest</i>.....	58
6.3	Análise química do solo.....	64
6.3.1	Micronutrientes.....	64
6.3.2	Macronutrientes.....	71
6.4	Demais parâmetros químicos influentes na fertilidade agrícola.....	80
6.5	Modelagem da aptidão agrícola da BHRS com base no algoritmo RF.....	89
7	CONCLUSÃO.....	105
	REFERÊNCIAS BIBLIOGRÁFICAS.....	108

1 INTRODUÇÃO

Tendo em vista o cenário de crescimento populacional ascendente, de forma a elevar as demandas sociais e industriais para com o consumo de alimentos, existe um reconhecimento global no que diz respeito à relevância em se estabelecer políticas territoriais, agrícolas e ambientais que visem garantir a segurança alimentar do planeta (FAO, 2022; DESA, 2019).

Nesse sentido, por mais que as últimas décadas tenham sido marcadas pelo aumento significativo da disponibilidade de alimentos, por meio dos ganhos de produtividade no campo (BENTON; BAILEY, 2019), manter esse rendimento agrícola em alto nível é uma das preocupações das gestões governamentais atuais e futuras (ZHU *et al.*, 2023), principalmente diante das incertezas, a longo prazo, do impacto negativo dessa atividade nas mudanças climáticas (YAO *et al.*, 2023; SANTOS; SIMIONATTO, 2024).

Em se tratando do Brasil, o cenário encontrado é, de fato, ainda mais crítico, principalmente ao se verificar o último relatório de Segurança Alimentar e Nutrição no Mundo da Organização das Nações Unidas para a Alimentação e a Agricultura (FAO, 2022), que indica que aproximadamente 61 milhões de brasileiros enfrentaram algum grau de insegurança alimentar entre os anos 2019 e 2021, apresentando uma piora significativa da fome no país em comparação com o cenário de 2014 e 2016, quando esse contexto atingia cerca de 37 milhões de pessoas.

Isso é, se por um lado a segurança alimentar é vista como um dos pilares para garantir o desenvolvimento sustentável da sociedade (FAO, 2022), por outro, é considerada como um desafio territorial, ambiental, agrícola e demográfico (JAMBO *et al.*, 2021), haja vista as tendências de crescimento populacional e o aumento pela procura de alimentos, induzindo o incremento das áreas agrícolas (SANTOS *et al.*, 2024a) e evidenciando a necessidade de se exercer uma gestão eficiente do uso da terra frente às mudanças climáticas (FAROOQ *et al.*, 2023; YAO *et al.*, 2023; SANTOS; SIMIONATTO, 2023).

Além do mais, apesar dos esforços para encontrar soluções que busquem acabar com a fome em todas as dimensões até 2030 (ONU, 2018), a insegurança alimentar continua a aumentar com o passar dos anos (MABE *et al.*, 2021). Portanto, analisar as características espaciais do solo e o seu potencial de fertilidade para determinado cultivo é crucial para que se verifique a sua aptidão agrícola, de forma a garantir um fornecimento eficiente e sustentável de cultivares (MOHAMMED *et al.*, 2022), sendo essa, a justificativa para o presente trabalho.

Dessa forma, o conhecimento dos atributos granulométricos do solo, que influenciam diretamente o fluxo superficial e o movimento de água no solo, e químicos, correlatos ao seu

potencial de fertilidade e desenvolvimento das plantas, analisados conjuntamente com os fatores topográficos e de disponibilidade hídrica, é de fundamental importância para as 3 vertentes de planejamento e gestão: 1) agrícola; 2) ambiental; e 3) territorial (GUERRA, 1998).

Entretanto, realizar esse gerenciamento não é uma tarefa fácil, pois os solos e as suas inter-relações formam um ecossistema dinâmico e que se associa a uma diversidade de outros fatores quando analisado como um todo, conforme apresentado por Dhaliwal *et al.* (2019), que ressalta: em se tratando de análise da qualidade e potencialidade agrícola do solo, quais os parâmetros devem ser considerados? Quais as propriedades mais importantes e como medi-las?

Embora seja um conceito simples, gerir o potencial de fertilidade do solo é uma tarefa árdua e onerosa. Todavia, os avanços tecnológicos, alavancados pela Agricultura Digital - Agricultura de Precisão (AP) -, têm se mostrado essenciais para otimizar essa função, contribuindo significativamente para a promoção da segurança alimentar em escala global (ERICKSON; FAUSTI, 2021), gerando melhores resultados quando vinculados às técnicas de geoprocessamento e do uso da Inteligência Artificial (IA), com destaque para os processos de *Machine Learning* (ML) (BERHANE *et al.*, 2018; PAREETH, *et al.*, 2019; JIN *et al.*, 2023).

Portanto, esta pesquisa possui a hipótese de que é possível, com base nas características físicas e químicas do solo de uma bacia hidrográfica, aliados à sua topografia e da disponibilidade de recursos hídricos, identificar as áreas mais adequadas para o cultivo de olerícolas, promovendo uma gestão territorial mais eficiente e, conseqüentemente, em práticas agrícolas sustentáveis.

2 OBJETIVOS

2.1 Objetivo geral

Desenvolver um modelo matemático a partir do algoritmo *Random Forest* (RF) capaz de identificar as áreas mais, medianamente e menos aptas para o cultivo de olerícolas na Bacia Hidrográfica do Rio Sorocabaçu (BHRS).

2.2 Objetivos específicos

- Levantar e caracterizar os parâmetros físico-químicos dos solos da BHRS, avaliando seu padrão espacial e identificando os que apresentam variação significativa entre diferentes classes texturais;
- Aplicar o algoritmo *Random Forest* (RF) para a classificação textural dos solos da BHRS com base em sua granulometria;
- Segmentar as classes de aptidão agrícola para o cultivo de olerícolas considerando o grau de declividade do terreno e a distância euclidiana em relação aos corpos hídricos;
- Realizar a classificação de aptidão agrícola integrando parâmetros físico-químicos, declividade e distância dos corpos hídricos;
- Identificar e analisar os parâmetros mais e menos influentes na geração do modelo de aptidão agrícola a partir do algoritmo RF.

3 ESTRUTURA DO TRABALHO

Pretendendo alcançar o objetivo proposto, este trabalho possui 7 etapas, realizadas de forma sequencial, que, em busca de alcançar o melhor entendimento, estão dispostas na Figura 1, que também apresenta as principais atividades realizadas.

Figura 1 – Etapas realizadas para alcançar o objetivo do presente trabalho.



Fonte: Elaborado pelo autor (2024).

4 REVISÃO BIBLIOGRÁFICA

4.1 Olericultura: importância, manejo sustentável e impacto na produtividade agrícola

A olericultura, ramo da agricultura voltado ao cultivo de hortaliças, abrange uma diversidade de espécies, incluindo folhosas, de fruto e de raiz (EMBRAPA, 2013; AHMED *et al.*, 2024). Seu papel é essencial para a segurança alimentar, contribuindo significativamente para a economia agrícola e gerando oportunidades de desenvolvimento rural, consolidando-se como um setor estratégico no agronegócio (AKBAR *et al.*, 2024; KUZICHEVA *et al.*, 2022).

O manejo adequado do solo é crucial na olericultura, especialmente devido à sensibilidade dessas culturas a variações nos teores de macro e micronutrientes. Portanto, práticas conservacionistas, como rotação de culturas, adubação orgânica e controle da erosão, são indispensáveis para manter a fertilidade do solo e otimizar a produtividade agrícola (NWOSU *et al.*, 2020; RATHORE *et al.*, 2023).

Além disso, a sustentabilidade na olericultura envolve a preservação dos recursos naturais e a minimização dos impactos ambientais negativos. Logo, o manejo sustentável do solo, aliado a técnicas de conservação e ao uso racional de insumos, previne a sua degradação e garante a longevidade produtiva das áreas cultivadas (PARAJULI *et al.*, 2019). Portanto, o equilíbrio entre eficiência produtiva e conservação ambiental é essencial para a viabilidade da olericultura a longo prazo (STIRZAKER *et al.*, 1989; GAUTAM *et al.*, 2024).

Convém destacar que a qualidade do solo é fundamental para maximizar o rendimento e a qualidade desse tipo de cultura, pois cultivar olerícolas em áreas com solos mal estruturados ou com baixa concentração de nutrientes pode resultar em produtividade reduzida e aumentar a suscetibilidade a doenças e pragas (SHAFIQUE *et al.*, 2016; AHMED *et al.*, 2024).

Nesse contexto, vale destacar que, embora o desenvolvimento de doenças nas plantas faça parte do ecossistema agrícola, esse cenário torna-se preocupante quando essas causam perdas significativas na colheita (MORSY *et al.*, 2009). Portanto, para mitigar esses impactos, práticas que promovam a conservação do solo são essenciais para garantir a disponibilidade de nutrientes e a saúde dos cultivares (MOHANTY *et al.*, 2024; EL BEHAIRY *et al.*, 2022), ou seja, o monitoramento da aptidão agrícola do solo é crucial para garantir o sucesso no cultivo (GAUTAM *et al.*, 2024; EL BEHAIRY *et al.*, 2022).

Por outro lado, práticas inadequadas de manejo do solo intensificam os processos erosivos e comprometem, por exemplo, a capacidade de retenção hídrica, resultando em menor

produtividade e aumentando a vulnerabilidade das culturas a eventos climáticos extremos (SMITH *et al.*, 2024; LÓKI, 2024).

Logo, é válido destacar que as práticas de manejo do solo na olericultura, quando integradas às técnicas de AP, possibilitam o monitoramento contínuo das potenciais condições de cultivo do local. Ademais, o uso do SR e das técnicas de geoprocessamento pode viabilizar uma gestão mais eficiente do uso da terra (NERY *et al.*, 2024; SANTOS *et al.*, 2024b) e, conseqüentemente, dos recursos naturais (ZUDE-SASSE *et al.*, 2016; GAUTAM *et al.*, 2024; RIZZO *et al.*, 2024).

Portanto, a interação entre a estrutura, a textura e a disponibilidade de nutrientes do solo é essencial para a produtividade das olericulturas, exigindo um manejo que integre esses fatores com as condições ambientais (RAMI *et al.*, 2023). Logo, compreender a espacialidade desses parâmetros e monitorar continuamente suas condições permite otimizar as práticas agrícolas, assegurando ao produtor o sucesso na colheita e a sustentabilidade em sua produção (AHMED *et al.*, 2024; EL BEHAIRY *et al.*, 2022).

4.2 Estrutura, nutrientes e textura do solo: importantes aliados da fertilidade agrícola

As características intrínsecas do solo permitem sua classificação em diferentes tipos, com destaque para a estrutura, que é definida pela forma como as partículas de areia, silte, argila, matéria orgânica e o espaço poroso se organizam (DEXTER, 1988; DEXTER, 2004; RILLIG, 2006; EMBRAPA, 2018).

Entretanto, o arranjo dessas partículas no solo está susceptível aos impactos provenientes das atividades antrópicas, bem como dos processos bióticos e abióticos (ROMERO-RUIZ, 2018), sendo essas, informações consolidadas por Dexter (1988) e Oades (1993), revisadas por Diaz-Zorita *et al.* (2002) e verificadas no contexto atual, conforme Williams *et al.* (2020) e Or *et al.* (2021), ressaltando a necessidade de um manejo adequado para potencializar a aptidão fértil do solo.

De forma conjunta, os parâmetros supracitados influenciam em diferentes e importantes funções ecológicas do sistema de fertilidade agrícola (DEXTER, 1988; 2004; RILLIG, 2006), com destaque para a infiltração, percolação e retenção de água, susceptibilidade à erosão, trocas gasosas, quantidade de matéria orgânica, dinâmica de nutrientes minerais e biomassa microbiana (ELLIOT; COLEMAN, 1988; BOTINELLI, 2015; RABOT *et al.*, 2018).

Além do mais, é importante destacar a vulnerabilidade aos processos erosivos e o carreamento e armazenamento de água no solo, que são fatores diretamente impactados pela

forma com que as partículas do solo estão organizadas (DORAN; PARKIN, 1996; LOWERY *et al.*, 1996; EMBRAPA, 2017), sendo esse, portanto, um importante indicador da qualidade do solo e do seu potencial de fertilidade (LOW, 1972; BOWMAN *et al.*, 1970; TISDALL; OADES, 1982).

Na perspectiva de manejo adequado e da aptidão agrícola do solo, proveniente desses aspectos, é válido destacar que a sua estrutura também pode afetar a disponibilidade de nutrientes para o crescimento e a reprodução das plantas, sendo que a ausência desses pode afetar negativamente o desenvolvimento dos cultivares (MIRANSARI, 2013). Essas perdas são ressaltadas por Guareschi *et al.* (2019) como correlatas, dentre outros fatores, aos processos erosivos e de lixiviação.

Tratando especificamente dos elementos com funções específicas e essenciais no metabolismo das plantas, esses são classificados em dois grupos, micronutrientes e macronutrientes, a depender da quantidade requerida para o crescimento e a reprodução dessas (MIRANSARI, 2013).

Os macronutrientes - Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg) e Enxofre (S) - são considerados como os principais por serem absorvidos pela planta em maior proporção que os micronutrientes - Boro (B), Zinco (Zn), Cobre (Cu), Ferro (Fe), Molibdênio, Cloro (Cl) e Manganês (Mn) - os chamados elementos-traço (KIRKBY; RÖMHELD, 2007; FAGERIA *et al.*, 2002).

É válido destacar que outros nutrientes - Selênio (Se), Silício (Si), Cobalto (Co), Sódio (Na), Alumínio (Al), Vanádio (V) e Níquel (Ni) – são considerados elementos benéficos, pois estimulam o crescimento das plantas, entretanto, não são essenciais, assim como outros parâmetros, como pH, Capacidade de Troca Catiônica (CTC), Soma das Bases (SB), Porcentagem de Saturação por bases (V%), Matéria Orgânica (MO) e o Potencial de Acidez (H+Al) (EMBRAPA, 2020; EMBRAPA, 2017).

Ressalta-se que um ou vários nutrientes podem possuir poucas concentrações ou estarem ausentes nos solos, de forma que as raízes não consigam absorver ou alcançá-lo, a depender do seu arranjo estrutural, ou seja, para torná-lo disponível, o solo deve ser bem manejado e possuir estruturação adequada para tal (SFREDO; SARRUGE, 1990; EMBRAPA, 2020).

Tratando exclusivamente das proporções granulométricas de areia, silte e argila, o Instituto Agronômico de Campinas (IAC) destaca que esses estão associados aos fatores físicos e químicos do solo, estando também correlatos ao crescimento de plantas (IAC, 2009) e sendo

essenciais para se entender o melhor tipo de manejo a se utilizar naquele local (BRADY; WEIL, 2009).

Esses atributos, além de se relacionarem com a ciclagem de nutrientes e com a troca de íons, também podem ser indicadores da qualidade e do potencial de fertilidade do solo, e, dessa maneira, estão sendo cada vez mais investigados em diferentes condições de uso e manejo (HE *et al.*, 2014).

No Brasil, a classificação referente ao tamanho das partículas utilizadas para classificar o arranjo do solo segue o padrão definido pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA, 1979), sendo possível realizar a classificação do tipo de solo por meio desses valores (TIETJE; HENNINGS, 1996). As partículas são categorizadas em: a) argila ($< 0,002$ mm); b) silte ($0,002 - 0,05$ mm); c) areia fina ($0,05 - 0,2$ mm); d) areia grossa ($0,2 - 2$ mm). As frações mais grosseiras do que a fração areia são: e) cascalho ($2 - 20$ mm); f) calhau ($20 - 200$ mm) e; g) matacão (> 200 mm).

Diante desse contexto, ao analisar a classificação do solo e seu potencial de fertilidade, há um consenso de que áreas produtivas devem conter boa quantidade de argila. Esse entendimento se originou porque, no passado, devido às limitações de manejo, solos arenosos eram menos valorizados na agricultura, uma vez que suas partículas, sem carga elétrica, aumentam a percolação da água e a dispersão de nutrientes e poluentes (RAMANHO; BEEK, 1995).

De fato, as frações arenosas, em condições normais, estão mais propensas a degradação e a perda da capacidade produtiva quando comparadas aos teores de argila, que possuem cargas negativas que promovem a adsorção dos nutrientes (DONAGEMMA *et al.*, 2016). Entretanto, essa situação vem sendo cada vez mais alterada, principalmente pelo avanço tecnológico e do melhoramento da eficiência das práticas de geoprocessamento, atrelados ao surgimento da AP, que viabiliza algumas atividades agrícolas nesses locais.

Diante do exposto e analisados conjuntamente, nota-se que as inter-relações entre a fertilidade do solo e a sua estrutura ocorrem numa escala de micrómetros a metros, passando pela nutrição do solo e das plantas, sendo essa associação diretamente correlata à produtividade das culturas (JUMA, 1993). No entanto, suas estimativas exigem, além do conhecimento prévio da área de estudo e em pedologia, tempo para ser executado *in situ*.

Nesse sentido, a monitorização da agricultura a partir da detecção remota é um tema vasto e que tem sido amplamente abordado a partir de múltiplos pontos de vista, objetivando minimizar o tempo para se tomar decisões eficazes e minimizar o prazo das práticas onerosas (AREAL *et al.*, 2018), corroborando ao desenvolvimento da AP e dos princípios do SR e

geoprocessamento aplicados em processos de modelagem da produtividade agrícola (WEISS *et al.*, 2020).

4.3 Produtividade agrícola potencializada pelas tecnologias de detecção remota

Após a terceira Revolução Industrial, a agricultura praticada nos países em desenvolvimento, como o Brasil, foi tendenciada a se apoiar nas práticas que visam a produtividade agrícola em larga escala, ocasionando na utilização dos recursos naturais de forma insustentável e, conseqüentemente, em impactos socioambientais negativos (HAMDAN *et al.*, 2022).

Kogo *et al.* (2021) e Xie *et al.* (2019) destacam que a produtividade agrícola em larga escala do passado estava associada à degradação, salinização e compactação dos solos, à redução das águas subterrâneas e ao aumento do CO₂ atmosférico. Esses fatores limitaram, por certo tempo, o desenvolvimento agrícola sustentável, especialmente em países em desenvolvimento, que enfrentam, atualmente, graves ameaças de eventos climáticos extremos intensificados pela expansão agrícola sem as mitigações necessárias (IPCC, 2014).

Essa situação tornou-se ainda mais crítica a partir da estimativa de crescimento populacional exponencial, que ocasiona na necessidade de maior produção alimentar para satisfazer as necessidades da população (FAO, 2022; IPCC, 2022; KARTHIKEYAN *et al.*, 2020) e atingir a segurança alimentar, que é parte dos Objetivos de Desenvolvimento Sustentável (ODS), instituído pela Organização das Nações Unidas (ONU, 2015).

Nesse sentido, a ONU objetiva, até 2030, dobrar a produtividade agrícola e a renda dos pequenos produtores de alimentos, de forma a garantir os sistemas de produção de alimentos por meio de práticas agrícolas sustentáveis (ONU, 2015). Além do mais, dadas as taxas sem precedentes das alterações climáticas, do crescimento populacional e do consumo de recursos naturais, a segurança alimentar global emergiu como uma questão crítica no século XXI.

Dessa forma, é possível notar que existe uma lacuna entre a produção agrícola em larga escala, impulsionadas pelas estimativas de crescimento populacional, e a utilização dos recursos naturais de forma eficiente, garantindo a segurança alimentar da população, que tende a aumentar para cerca de 10 mil milhões até 2050 (FAO, 2022; IPCC, 2022).

Ou seja, diante das terras aráveis limitadas, do esgotamento dos recursos naturais, da escassez de trabalhadores agrícolas e do aumento exponencial dos custos de produção de

alimentos, existe atualmente uma mudança de paradigma em direção a um novo método produtivo que visa garantir uma agricultura sustentável e efetiva.

Com as mudanças tecnológicas impulsionadas pelas práticas agrícolas, a agricultura está se modernizando através da incorporação de inovações tecnológicas nos processos produtivos. Esse avanço visa utilizar os recursos naturais de maneira mais eficiente, o que caracteriza o sistema de gerenciamento agrícola conhecido como AP (PATEL, 2013), que, embora possa ter diversas definições, seu conceito central é a gestão agrícola baseada em técnicas avançadas de informação, comunicação e análise de dados, visando decisões mais eficazes (SHARMA *et al.*, 2020).

Por exemplo: a) em uma bacia hidrográfica altamente impactada pela produção agrícola, pode-se existir áreas mais adequadas para determinado cultivo do que outras? A resposta para essa pergunta é sim, mas, como realizar esse procedimento de forma rápida e eficiente? Ademais, b) com base em quais parâmetros pode-se tomar uma decisão de qual a melhor área para se realizar o cultivo? (GEBBERS; ADAMCHUK, 2010; ZHANT *et al.*, 2002).

Tais questões podem ser respondidas por meio da utilização das tecnologias de detecção remota, que possuem a capacidade de contribuir para com o monitoramento da superfície terrestre por meio do fornecimento de parâmetros espaço-temporais que, quando combinados com modelos matemáticos, são úteis na previsão do rendimento das mais diversas culturas (SHANMUGAPRIYA *et al.*, 2019; DORAISWAMY *et al.*, 2005), informações fenológicas (SAKAMOTO *et al.*, 2005) e na detecção de estresse hídrico (GU *et al.*, 2007; KINGRA *et al.*, 2016).

Todavia, vale destacar que os pesquisadores reconhecem, há algum tempo, a importância de se mapear e trabalhar com os dados do uso da terra e do solo para se realizar uma gestão agrícola sustentável em escala local, regional e nacional (METTERNICHT, 2018; SANTOS *et al.*, 2023), entretanto, por mais que essa possibilidade já existisse com as fotografias aéreas, após o lançamento do primeiro satélite LANDSAT, em 1972, notou-se um incremento da utilização das imagens de satélite como forma de classificar as paisagens agrícolas e dos recursos naturais (BAUER; CIPRA, 1972).

Com o passar dos anos, estudos como os de Fadl *et al.* (2024) Ge *et al.* (2011), Zhang *et al.* (2011), Courault *et al.* (2005) formavam, aos poucos, o estado da arte das técnicas de detecção remota, com enfoque na avaliação do potencial de produtividade do solo, nas estimativas de sua propriedade, no manejo de doenças e pragas e na estimativa da evapotranspiração, respectivamente.

Desde então, inúmeras foram as formas utilizadas para se subsidiar os agricultores nas tomadas de decisão agrícolas, pois, segundo Karthikeyan *et al.* (2020), a detecção remota por satélites consegue fornecer resultados eficientes para monitorar as práticas agrícolas em grandes escalas espaciais.

Apesar desses avanços e na evolução significativa das resoluções espaciais, temporais e espectrais dos sensores a bordo dos satélites, o uso dessas imagens ainda é limitada para fins de áreas mais aptas para certo cultivo, principalmente perante as restrições impostas pela presença de nuvens e pelas variações sazonais, além do tempo de revisita dos satélites (KATSIGIANNIS *et al.*, 2016).

Diante dessa limitação, o SR para fins agrícolas está sendo cada vez mais integrado às técnicas de IA, que atraem atenção significativa de pesquisadores multidisciplinares devido ao seu potencial de compilar grandes volumes de dados. A combinação com processos de ML permite utilizar uma vasta gama de variáveis que influenciam os processos produtivos, treinando modelos para obter respostas mais precisas e realistas (JUNG *et al.*, 2020).

Vale destacar ainda que, na atualidade, imagens de alta resolução obtidas por drones e Veículos Aéreos Não Tripulados (VANTs) têm sido amplamente empregadas nas práticas de AP, haja vista que esses recursos oferecem uma visão detalhada e dinâmica das condições agrícolas, melhorando a eficiência e a precisão das análises e, também, subsidiando os gestores agrícolas em suas tomadas de decisão.

4.4 Técnicas de *Machine Learning* como instrumento norteador das práticas agrícolas

De forma geral, as práticas agrícolas ainda enfrentam muitos desafios, com destaque para o uso insustentável dos recursos naturais, em especial do solo e da água, o que restringe algumas áreas à produtividade (JHA *et al.*, 2019). Todavia, a IA, em conjunto com as técnicas de ML, possuem a capacidade de minimizar e, quando não, solucionar esse problema, fornecendo dados de forma precisa que, se bem utilizados pelos tomadores de decisão, aprimoram a eficiência do uso desses recursos (PATEL *et al.*, 2021).

Por conseguinte, pesquisadores vêm buscando, de forma veemente, algoritmos que sejam capazes de classificar padrões, prever fenômenos inesperados e propor áreas adequadas para se obter a melhor produtividade agrícola frente a um determinado cultivo (BEN AYED; HANANA, 2021; PATEL *et al.*, 2021). Porém, para cada área analisada, diferentes são as características do solo, os tipos de manejo e os fatores que podem influenciar nesse processo, o que dificulta a realização de padronização e restringe a área de interesse (GEETHA *et al.*, 2020).

Ainda assim, esses trabalhos envolvem um grande volume de variáveis, que necessitam, além de uma grande capacidade de armazenamento, da análise técnica multidisciplinar, de forma a serem geridos, compilados, analisados e interpretados, sendo o último, possuidor da capacidade de agregar valor à sociedade, ao meio ambiente e aos tomadores de decisão agrícolas e ambientais (SONKA, 2016).

Para tanto, o ML, considerado como um subconjunto da IA, possui a capacidade de realizar essa tarefa de forma eficiente, utilizando métodos matemáticos, estatísticos e obtendo decisões com base no comportamento desses dados frente a inúmeras combinações, aperfeiçoando-se com os erros de forma automática e repetidamente (BEN AYED; HANANA, 2021; PANDITH *et al.*, 2020).

Analizando o solo como fonte de dados para o gerenciamento agrícola sustentável e o treinamento de ML, Eli-Chukwu (2019) e Smriti (2015) destacam que esse recurso natural, por meio das suas propriedades químicas e físicas, é capaz de, juntamente com as características físicas locais, fornecer informações preditivas sobre qual tipo de cultura plantar em determinada área, melhorando o rendimento do cultivo e utilizando, de maneira eficiente, os recursos naturais.

Neste ponto, vale salientar que inúmeros são os algoritmos que abrangem as técnicas de ML. Porém, diante do seu ótimo desempenho frente a estudos que envolvem as características do solo e a influência desse na produtividade agrícola, o algoritmo RF é utilizado por grande parte desse pesquisadores, conforme resultados apresentados por Batistella *et al.* (2023), Alabi *et al.* (2022), Li *et al.* (2022), Habibi *et al.* (2021), Stepanov *et al.* (2020); Andrade *et al.* (2020).

A proeminência desse algoritmo frente aos demais se deve à possibilidade de investigação não linear e relações hierárquicas entre os preditores e a resposta usando uma abordagem de aprendizagem em conjunto, realizando várias tentativas de combinação de dados diferentes ou modelos para prever uma variável de resposta, além de ser utilizado tanto para classificação quanto para regressão, possuindo capacidade de prever uma variável de resposta categórica ou contínua (BREIMAN, 2001).

Todavia, em ambas as abordagens, o algoritmo consegue ajustar um conjunto de modelos de árvore de decisão a um agrupamento de dados, ou seja, para cada árvore, os dados são divididos recursivamente em unidades mais homogêneas, comumente denominadas de ‘nós’, a fim de se obter uma melhor previsibilidade da variável resposta. Os pontos de divisão são baseados nos valores da variável preditora (BREIMAN, 2001).

Outro destaque importante é que o RF também consegue classificar a importância relativa de cada variável preditora no modelo a ser gerado (BATISTELLA *et al.*, 2023), sendo essa, calculada com base no erro *Out-Of-Bag* (OOB) (BREIMAN 2001; LIAW; WIENER 2002).

Fundamentalmente, o RF consegue, por meio de diversas árvores de decisão, combiná-las, paralelamente e sem interações (HANADÉ HOUMMA *et al.*, 2023; SULEYMANOV *et al.*, 2023). Ou seja, o método não possui sob ajuste e os valores previstos não são sensíveis, independente dos dados treinados, conforme frisado por Zarei *et al.* (2023), que ressalta ainda os benefícios do algoritmo: a) precisão das previsões; b) eficiência para uma grande classe de conjunto de dados; c) precisão para conjuntos de dados de alta dimensão; d) capacidade de determinar a taxa dos efeitos dos preditores na variável de resposta; e) redução do erro total e; e) eficácia para aplicação em conjunto de dados com dados faltantes.


Em conclusão, vale ressaltar que a abordagem supracitada é corroborada por Li *et al.* (2023), que ratifica o desempenho do algoritmo RF, considerando-o como o menos propenso ao processo de *overfitting*, sendo fortemente capaz de explicar a importância de cada uma das variáveis treinadas para com o modelo gerado, garantido a precisão dos dados alcançados por meio das análises descritivas produzidas, mesmo que esses estejam parcialmente ausentes.

5 MATERIAIS E MÉTODOS

5.1 Área de estudo

O presente estudo foi desenvolvido na BHRS (Figura 2), que abrange uma área de 202,67 km² e está integralmente localizada no município de Ibiúna, São Paulo (SP). A área de estudo representa cerca de 19% do território municipal, o qual possui uma população estimada em aproximadamente 75 mil habitantes (IBGE, 2023).

Figura 2 – Localização da área de estudo.



Fonte: Elaborado pelo autor (2024).

A BHRS encontra-se inserida no bioma Mata Atlântica (IBGE, 2021) e no interior da Área de Preservação Ambiental (APA) de Itupararanga, preenchendo 22% da sua extensão espacial e tendo o rio Sorocabaçu como um dos seus principais formadores (JÚNIOR; LOURENÇO, 2020).

Quanto ao clima, Dubreuil (2017) atualizou a classificação de Köppen (1948) para a região onde se insere a bacia hidrográfica, identificando-a como do tipo Cwa, caracterizada por

apresentar um clima subtropical de inverno seco, com médias de temperatura inferiores a 18° C e precipitação de 47,5 mm durante esse período, e verão quente, com médias de temperatura superiores a 22° C e precipitação de 196 mm.

A área de estudo é marcada por uma baixa densidade populacional, porém, é ocupada por uma considerável quantidade de propriedades rurais (MAIA JÚNIOR; LOURENÇO, 2020). A atividade agrícola predominante é a olericultura, com hegemonia de agricultores familiares, cujos produtos têm como principal destino a Companhia de Entrepostos e Armazéns Gerais de São Paulo (CEAGESP), uma importante distribuidora de legumes, verduras, pescados e flores em todo o país (CEAGESP, 2019).

Além disso, cerca de 60% do que é consumido de hortaliça e pescado na região da grande São Paulo possui, como origem, a comercialização realizada na CEAGESP, possuindo extrema importância no abastecimento de alimentos (CEAGESP, 2019). Dessa forma, a BHRS apresenta, além da relevância ecológica, interesse econômico.

5.2 Procedimentos metodológicos

Inicialmente, convém destacar que a base de apoio cartográfica foi construída por meio de dados planialtimétricos extraídos de cartas topográficas na escala 1:10.000 para o município de Ibiúna, fornecidas pelo Instituto Geográfico e Cartográfico do Estado de SP (IGC, 1979).

Em vista dos dados espaciais, incluindo informações cartográficas acerca da hidrografia, curvas de nível, pontos cotados, limites da bacia hidrográfica, além do uso da terra, foram disponibilizados pelo Laboratório de Geoprocessamento e Modelagem Matemática Ambiental (LABGEMM), sendo que, quando necessário, foram adequados em termos de resolução espacial para o presente estudo.

5.2.1 Plano amostral e análise físico-química do solo

A análise física do solo foi realizada com base no Boletim Técnico 106 do IAC e foi conduzida através de análise granulométrica (IAC, 2009). Foram selecionados 27 pontos na BHRS (Figura 3), distribuídos com base na topografia, nas classes de uso e ajustados a partir de sua acessibilidade. Essa seleção foi fundamentada no conhecimento prévio da área e complementada pela análise de uma imagem de satélite CBERS4-A, do ano de 2022, com resolução espacial de 2 metros e fusão da banda pancromática.


Foram coletadas amostras da classe agrícola (5), pastagem (5), ambiente urbano (4), floresta (7), campo (2) e solo exposto (4). Todas essas categorias foram tipificadas com base no Manual Técnico de Uso da Terra (IBGE, 2013) e no mapeamento de uso da terra disponibilizado pelo LABGEMM, que oferece dados atualizados sobre o uso da terra na BHRS.

A coleta de amostras em diferentes classes de uso da terra é fundamental para uma avaliação abrangente da aptidão agrícola. Embora o objetivo principal deste estudo seja identificar áreas com maior potencial para cultivo, a aptidão agrícola é influenciada não apenas pelas propriedades físico-químicas do solo, mas também pela interação dessas características com os diferentes tipos de uso (KRISHNA MURTHY, 2023). Dessa forma, a amostragem diversificada possibilita uma análise mais precisa das condições do solo em diferentes contextos de uso.

As coletas foram realizadas nos dias 03/07/2023, 07/07/2023 e 17/07/2023, sendo selecionado esse período com base nas características climáticas da região, por se tratar da estação seca, conforme descrito por Dubreuil (2017), o que minimiza possíveis interferências dos fatores climáticos, como umidade e temperatura, nas análises realizadas.

No primeiro dia de coleta, a temperatura ambiente mínima para o município de Ibiúna foi de 15° C, enquanto a máxima foi de 27° C. No segundo dia, a mínima também foi de 15° C, e a máxima de 20° C. Já na última coleta, a mínima foi de 16°, enquanto a máxima foi de 23° C. Além do mais, em cada ponto de coleta, mediu-se a temperatura ambiente do local. Dessa forma, a Tabela 1 apresenta as coordenadas, o horário da coleta, a temperatura ambiente, a elevação e a respectiva classe de uso de cada ponto.

Figura 3 – Localização dos pontos de coleta do solo na BHRS.



Fonte: Elaborado pelo autor (2024).

Tabela 1 – Caracterização dos pontos de coleta do solo na BHRS.

Ponto	Coordenadas UTM	Temperatura (°C)	Horário da coleta	Altitude (m)	Classe de uso da terra
1	23K 0274464 7368803	21°C	12:45	887	Agrícola
2	23K 0276038 7375687	22°C	13:48	862	Pastagem
3	23K 0285858 7366589	23°C	14:17	915	Floresta
4	23K 0285616 7368722	23°C	14:35	884	Campo
5	23K 0273697 7371006	17°C	09:40	882	Agrícola
6	23K 0279631 7372934	21°C	16:33	907	Pastagem
7	23K 0275065 7377222	23°C	15:55	912	Floresta
8	23K 0281506 7373437	22°C	15:47	865	Campo
9	23k 0278011 7370542	15° C	10:10	1008	Pastagem

10	23k 0274831 7370863	16° C	10:53	871	Agrícola
11	23K 0278285 7365562	16° C	11:28	969	Floresta
12	23K 0276004 7365132	16° C	11:52	897	Floresta
13	23K 0271967 7365181	17°C	13:52	1000	Floresta
14	23K 0279619 7374884	22°C	15:17	889	Solo exposto
15	23K 0272758 7367159	17°C	13:23	873	Agrícola
16	23K 0269220 7366359	18°C	14:49	1091	Pastagem
17	23K 0278375 7374428	20°C	11:20	875	Urbano
18	23K 0274494 7380673	17°	09:33	857	Urbano
19	23K 0275660 7382248	16°C	08:48	885	Urbano
20	23K 0276526 7373425	22°C	14:32	865	Pastagem
21	23K 0284447 7371990	23°C	14:55	920	Urbano
22	23K 0276516 7363650	18°C	10:39	1006	Floresta
23	23K 0278172 7377906	19°C	10:46	907	Agrícola
24	23K 0279931 7367918	20°C	11:30	891	Floresta
25	23K 0282505 7368379	23°C	13:03	890	Solo exposto
26	23K 0280778 7370910	22°C	12:15	903	Solo exposto
27	23K 0275353 7367378	18° C	12:48	961	Solo exposto

Fonte: Elaborado pelo autor (2024).

Para a coleta do solo, utilizou-se ferramentas de atividades agrícolas: um enxadão e uma cavadeira articulada, de forma que a primeira foi utilizada para limpar toda a parte superficial do ponto de análise, retirando todos os detritos que, ali presentes, poderiam entrar na cova utilizada para coleta e influenciar nos resultados laboratoriais (EMBRAPA, 2014).

Já com a cavadeira, retirou-se entre 10 e 20 centímetros de solo, de forma a encher cerca de 2 quilos de material coletado, dispostos em sacos plásticos do tipo *zip lock* e identificados, conforme recomendado pela Embrapa (2014).

Após a realização de cada dia de coleta, as amostras foram levadas para o laboratório de Águas e Solos da Universidade Estadual “Júlio de Mesquita Filho” – UNESP de Sorocaba, onde foram secadas em temperatura ambiente (IAC, 2009).

A análise física foi realizada por meio do método da pipeta na Terra Fina Seca ao Ar (TFSA), conforme sugerido pela metodologia referenciada, sendo necessário a utilização de solução dispersante de hidróxido e hexametáfosfato de sódio, com agitação por 16 horas, a 30 rpm, no agitador rotatório de Wagner.

A fração de areia foi obtida mediante uma peneira de 0,053 mm, e as frações de argila e silte foram separadas por meio de pipetagem, em períodos de sedimentação, conforme a Lei de Stokes. Para argila+silte, considerou-se uma profundidade de 10 cm após o período de sedimentação de 4 minutos e 28 segundos. Para argila, estabeleceu-se 5 cm de profundidade após 3 horas e 43 minutos (IAC, 2009).

As análises químicas do solo foram realizadas junto à Faculdade de Ciências Agrônômicas da UNESP, no Departamento de Solos e Recursos Ambientais de Botucatu (SP), sendo os parâmetros analisados: a) pH; b) MO (g/dm³); c) P-resina (mg/dm³); d) Alumínio (Al³⁺); e) H+Al (mmol_c/dm³); f) K (mmol_c/dm³); g) Ca (mmol_c/dm³); h) Mg (mmol_c/dm³); i) Soma das Bases (SB) (mmol_c/dm³); j) CTC (mmol_c/dm³); k) V%; l) S (mg/dm³); m) B (mg/dm³); n) Cu (mg/dm³); o) Fe (mg/dm³); p) Mg (mg/dm³); q) Mn (mg/dm³); r) Zn (mg/dm³).

A justificativa para a escolha de tais parâmetros se dá pela essencialidade desses para com a nutrição das plantas, sendo que o manejo do solo e o tipo de cultura podem influenciar diretamente em suas concentrações e disponibilidade (MALAVOLTA, 1997), de forma que o desequilíbrio das proporções pode causar deficiência ou excesso de nutrientes, ocasionando em limitações ao crescimento das plantas ou mesmo sua morte (NOVAIS *et al.*, 2007).

5.2.2 Interpolação dos dados e estatística descritiva

Com a obtenção dos resultados da análise físico-química do solo, atribuiu-se os valores resultantes à tabela de atributos dos pontos coletados, sendo possível realizar a interpolação desses dados.

Nesta fase, foi empregado o software ArcGIS, versão 10.5 (ESRI, 2016), juntamente com o interpolador *Inverse Distance Weighted* (IDW), representado pela Equação 1. Esse método prevê valores para locais não especificados com base nas amostras circundantes, atribuindo maior peso aos valores próximos. Em resumo, cada ponto exerce influência sobre os

pontos vizinhos, sendo essa influência inversamente proporcional à distância entre eles. (LANDIM, 1998; LU; WONG, 2008).

Além disso, o sistema IDW é caracterizado por ser um interpolador suave e global, sendo fiel à amostragem e recomendado quando se pretende obter uma solução única e com contornos fiéis aos dados originais (LANDIM, 1998; YAMAMOTO, 1998; LANDIM, 2000; JAKOB; YOUNG, 2006).

$$Z_p = \frac{\sum_{i=1}^n \frac{Z_i}{h_{ij}}}{\sum_{i=1}^n \frac{1}{h_{ij}^\beta}} \quad (1)$$

Sendo: Z_p valor estimado dos parâmetros analisados; Z_i o valor do resíduo entre o ponto amostrado mais próximo vizinho ao valor estimado; h_{ij} a distância entre o valor estimado e o valor amostrado; β o expoente de ponderação (peso) e; n o número de pontos amostrados utilizados para estimar cada valor.

Feito isso, para subsidiar a discussão dos resultados obtidos, extraiu-se, pixel a pixel, os valores de mínimo, médio, máximo e Desvio Padrão (DvP $\pm$) de cada um dos parâmetros analisados, organizando-os em uma planilha Excel.

Vale destacar que, para fins de avaliação da fertilidade do solo, utilizou-se os teores apresentados no Boletim Técnico 251 (Hortaliças – Recomendações de calagem e adubação para o estado de São Paulo) para classificação dos parâmetros (TRANI, 2018). Para os componentes não disponibilizados pelo Boletim, empregou-se as recomendações de Ribeiro *et al.* (1999).

Após essa etapa, elaborou-se o layout de cada variável contendo a sua respectiva distribuição espacial. Para isso, utilizou-se o software QGIS em sua versão 3.36.0 (QGIS DEVELOPMENT TEAM, 2024).

5.2.3 Mapeamento da declividade do terreno

O Modelo Digital de Elevação (MDE) com 5 metros de resolução espacial foi obtido a partir das curvas de nível e por meio das cotas de alguns pontos da BHRS, derivado da base de dados do LABGEMM. Para tanto, utilizou-se o método de triangulação Delaunay (*Triangular Irregular Network* - TIN), comumente empregada para gerar uma melhor descrição morfológica da superfície (TSAI, 1993) e que resulta em uma grade triangular contendo informações acerca da elevação do terreno (LI *et al.*, 2005).

Nesse modelo, a superfície do terreno é gerada por uma malha composta de triângulos adjacentes e não sobrepostos, sendo esses, de diferentes tamanhos e orientação, que são computados a partir de pontos, com coordenadas xyz, irregularmente espaçados e amostrados sobre a superfície que se pretende representar e se constituem nos vértices da triangulação, enquanto as arestas são geradas a partir da conexão entre vértices por meio de segmentos de retas, de forma a preservar a exata localização de cada ponto sobre terreno, melhorando assim a sua precisão (JONES *et al.*, 1994).

Gerado o MDE, classificou-se as declividades da área em classes (Quadro 1) de porcentagem, por meio da função matemática *Slope*, disponível no módulo *Spatial Analyst Tools* do ArcGis 10.5 (ESRI, 2017).

Quadro 1 – Definição das classes de declividade variando em função das características do local para o uso agrícola.


Classe	(%)	Características para o uso agrícola
1	0 – 3	Plano: Terreno praticamente nivelado, propenso a reter água e adequado para culturas sensíveis ao encharcamento.
2	3 - 8	Suave ondulado: Terreno levemente irregular, favorecendo a infiltração de água e adequado para uma variedade de culturas agrícolas.
3	8 - 20	Ondulado: Terreno moderadamente irregular, permitindo o escoamento superficial controlado e adequado para culturas com exigências médias de drenagem.
4	20 - 45	Forte ondulado: Terreno bastante irregular, propenso ao escoamento superficial rápido e adequado para culturas adaptadas a condições de drenagem mais intensa.
5	45 - 75	Montanhoso: Terreno caracterizado por elevações pronunciadas, suscetível a erosão hídrica e mais adequado para pastagens ou culturas perenes.
6	> 75	Escarpado: Terreno íngreme e abrupto, com alto risco de erosão, limitando o uso agrícola principalmente a práticas de conservação do solo e revegetação.

Fonte: EMBRAPA (1999).

5.2.4 Elaboração do plano amostral e aplicação de ML para classificar a textura do solo da BHRS

Na Figura 4, encontra-se disposto o modelo de comportamento de treino e validação utilizado para a classificação textural do solo da BHRS.

Figura 4 – Modelo de treino e validação do algoritmo RF para os procedimentos de classificação textural do solo.



Fonte: Elaborado pelo autor (2024).

Nesta etapa, apresenta-se os estágios subsequentes para a elaboração de um modelo, por meio de técnicas de ML, capaz de apresentar os tipos de classificação textural do solo em escala de 5x5 metros, o que ainda não foi verificado na área de estudo.

Esse procedimento se justifica pelo fato de que as pesquisas de solo existentes no Brasil estão disponíveis para escalas de alto valor, o que inviabiliza algumas tomadas de decisão para a gestão territorial local e regional, haja vista a dificuldade de se extrair o conhecimento nesse tipo de escala.

Portanto, a fim de verificar o desempenho das técnicas de ML em estudos de ciência do solo, optou-se por trabalhar com o algoritmo RF, modelando-o, treinando e validando-o com base nas informações coletadas em campo.

A partir das análises físicas do solo, desenvolveu-se uma grade amostral considerando a distribuição espacial das 9 sub-bacias hidrográficas da BHRS e levando em conta as variações de classe de uso e declividade.

Quanto às classes de uso, recorreu-se ao nível II do Sistema de Classificação da Cobertura e do Uso da Terra, conforme disposto no Manual Técnico de Uso da Terra (IBGE, 2013), para identificar as categorias, a saber: a) Área urbanizada; b) Cultura temporária; c) Cultura permanente; d) Pastagem; e) Floresta. Tais categorias foram deduzidas a partir de uma

imagem orbital capturada pelo satélite CBERS4-A (2022), em cor verdadeira e com resolução espacial de 5 metros.


É importante salientar que o referido manual classifica a atividade de reflorestamento como silvicultura. No entanto, neste estudo, optou-se por agrupar essas classes, haja vista que essas possuem comportamento espectral semelhantes e agem de forma similar na proteção do solo, permitindo, assim, uma compreensão mais ampla de todas as áreas com cobertura vegetal arbórea.

Em relação às classes topográficas, as categorias de declividade foram determinadas com base na classificação da EMBRAPA (1999), seguindo a metodologia previamente mencionada. Subsequentemente, foi elaborado um arranjo amostral visando garantir a representatividade de 2 amostras de cada categoria de uso e de declividade em cada sub-bacia hidrográfica. Desse modo, foram distribuídos 540 pontos em toda extensão territorial da BHRS.

Posteriormente, foram coletados os valores percentuais de areia, silte e argila de cada ponto amostrado, categorizando-os conforme o diagrama textural da Sociedade Brasileira de Ciência do Solo (SBCS), Figura 5, que está presente no pacote '*The soil texture wizard* (soiltexture)', do software RStudio (RSTUDIO, 2023), com a denominação de BRASIL.TT (MOEYS, 2015).

As porcentagens de argila, silte e areia foram diagramadas respectivamente nas arestas esquerda, direita e inferior do triângulo textural, sendo divididas com base nos tamanhos de suas partículas. Após implementação do algoritmo, foi possível verificar a disposição espacial dos 540 pontos no diagrama textural do solo.

Figura 5 – Diagrama textural do solo.



Fonte: SBCS (1984;1996).

Feito isso, também no software RStudio, elaborou-se um modelo de textura do solo com base no algoritmo RF, implementado no pacote de algoritmos da plataforma estatística R (LIAW; WIENER, 2002; R CORE TEAM, 2014), de forma a atribuir, para toda a BHRS, sua classificação textural.

Para isso, inicialmente, elaborou-se o empilhamento dos arquivos *rasters* contendo a distribuição espacial, em porcentagem, de areia, silte e argila. Em seguida, procedeu-se a mesclagem desse arquivo com as amostras contendo a classificação textural do solo.

Esse procedimento foi necessário para que fosse possível se obter uma matriz de dados na qual cada coluna fosse formada por uma variável preditiva (porcentagem de areia, silte e argila) e pela variável meta (classificação textural do solo).

Para o treinamento (calibração) do modelo, optou-se por trabalhar com o padrão de proporção 70/30, ou seja, 70% das amostras para treino e 30% para teste. Na implementação

do modelo RF, necessitou-se realizar a configuração de 2 parâmetros, sendo-os: a) número de árvores (ntree) e b) número de feições em cada divisão (ntry).

Estudos afirmam que resultados satisfatórios podem ser alcançados com os parâmetros padronizados, conforme apresentado por Zhang e Roy (2017); Noi e Kapas (2018). Nessa perspectiva, Breiman (2001) apresentou que, ao utilizar um número excessivo de árvores, embora não afete o modelo gerado, prejudica-se o desempenho computacional. Dessa forma, é sugerido o valor de até 100.

Ressalta-se que, assim como recomendado por Junaid *et al.* (2023) e Han *et al.* (2021), que frisam que a melhor classificação possível do RF seja realizada por meio de testes desses parâmetros, ao realizá-los neste estudo, esses não apresentaram diferenças significativas, o que pode estar relacionado com a efetividade e discrepância entre as classes de solo apresentada.

Todavia, optou-se por trabalhar com 50 ntree e 4 ntry, pois, diante da variabilidade dos parâmetros físico-químicos das bacias hidrográficas, futuros trabalhos possam utilizar essa quantidade e obter resultados satisfatórios.

Também foi realizada uma avaliação da importância relativa dos diferentes fatores de entrada para com a classificação. Essa etapa é crucial para se verificar como cada variável preditiva influencia no modelo de classificação gerado (GHIMIRE *et al.*, 2010).

Para tal, utilizou-se o critério de Gini, disposto na Equação 2, possibilitando, dessa forma, de se calcular a medida Gini, obtida pela diferença entre $Gini_{index}$ antes e após a divisão (Equação 3) (FILHO, 2014).

$$Gini_{index}(nó) = 1 - \sum_{i=1}^c p \frac{i}{nó} \quad (2)$$

Sendo: $p(i/nó)$ a proporção da classe i no nó.

$$Gini = Gini_{index}(pai) - \sum_{j=1}^n \left[\frac{N(v_j)}{N} Gini_{index}(v_j) \right] \quad (3)$$

Sendo: n se refere ao número de nós-filhos, N é o número total de observações do nó-pai e $N(v_j)$ é o número de observações associados ao nó-filho v_j .

Esse índice apresenta, para cada variável, o quão importante ela é na classificação dos dados, conforme apresentado por Han *et al.* (2016). O gráfico *Mean Decrease Accuracy* expressa quanto de precisão o modelo irá perder ao se excluir cada variável, ou seja, quanto mais a precisão for prejudicada, mais importante é a variável para o sucesso da classificação (MARTINEZ-TABOADA; REDONDO, 2020)

Nesse gráfico, as variáveis são apresentadas em ordem decrescente de importância, em que a diminuição média no coeficiente de Gini é uma medida de como cada variável contribui para a homogeneidade dos nós e folhas no modelo RF gerado (MARTINEZ-TABOADA; REDONDO, 2020).

Por fim, para verificar o teste de desempenho do algoritmo, utilizou-se das seguintes métricas para avaliar a acurácia do modelo: a) acurácia global (Accuracy), que é definida, matematicamente, como a proporção do número de previsões feitas corretamente pelo algoritmo para o conjunto total de dados (Equação 4) e o b) índice Kappa, calculado a partir da matriz de confusão (WEISS; ZHANG, 2003).

Todos os procedimentos metodológicos e estatísticos utilizados adotaram o nível de confiança de 95%. Além disso, ainda em relação à medição de desempenho dos modelos gerados, analisou-se a *Sensitivity* (SSV), *Specificity* (SPV), *Positive Predictive Value* (PPV) e *Negative Predictive Value* (NPV) de cada classe.

A SSV (Equação 5), é explicada pela porcentagem de acertos (positivos) previstos sobre os casos reais em cada classe de textura do solo, e a SPV (Equação 6), que indica a porcentagem de casos reais previstos como negativos nas outras classes (VAN STRALEN *et al.* 2009; GLAROS; KLINE 1988).

Já o PPV (Equação 7) indica a porcentagem dos números de casos corretamente identificados como verdadeiros, enquanto o NPV (Equação 8) aponta para a quantidade de casos identificados corretamente como negativos.

Convém destacar que se optou por utilizar, além da acurácia global, a métrica de *Balanced Accuracy* (Equação 9), pois, na presença de dados desbalanceados, a métrica global pode não fornecer informações adequadas sobre o desempenho do classificador e acabar sendo enganosa.

$$Accuracy = \frac{\text{number of correct predictions}}{\text{the total number of predictions made}} \quad (4)$$

$$Sensitivity = \frac{\text{true positive}}{\text{false negative} + \text{true negative}} \quad (5)$$

$$Specificity = \frac{\text{false positive}}{\text{false positive} + \text{true negative}} \quad (6)$$

$$PPV = \frac{\text{number of true positives}}{\text{number of true positives} + \text{number of false positives}} \quad (7)$$

$$NPV = \frac{\text{number of true negative}}{\text{number of true negative} + \text{number of false negative}} \quad (8)$$

$$\text{Balanced accuracy} = \frac{\text{Sensitivity} + \text{Specificity}}{2} \quad (9)$$

Após a conclusão da modelagem, o arquivo resultante foi exportado no formato raster, permitindo sua utilização em um ambiente SIG, no qual foi elaborado o layout correspondente.

5.3 Modelagem da aptidão agrícola para o cultivo de olerícolas na BHRS por meio do algoritmo RF

5.3.1 Análise estatística multivariada

Inicialmente, foi conduzida uma Análise de Componentes Principais (PCA), de forma descritiva, com o intuito de explorar a possível relação entre os parâmetros físico-químicos predominantes e os diferentes tipos de textura do solo presentes na BHRS. Além disso, foram aplicados Modelos Lineares Generalizados (GLMs), onde os parâmetros físico-químicos atuaram como variáveis de resposta e os tipos de textura do solo foram considerados como variáveis explicativas.

Para tanto, utilizou-se das 540 amostras anteriormente empregadas para a realização. Inicialmente, esses dados foram organizados em uma planilha eletrônica composta pela concentração de cada parâmetro físico-químico naquele ponto e sua respectiva classe textural.

Convém destacar que a PCA foi empregada, nesta etapa, a fim de se entender a dimensionalidade dos dados e identificar os componentes principais que explicam a maior parte da variação observada. Cada amostra foi analisada considerando a associação entre os parâmetros físico-químicos e o tipo de textura do solo, permitindo uma interpretação detalhada das interações e influências dos diferentes tipos de textura do solo sobre os parâmetros analisados. Para determinar a melhor distribuição dos dados, realizou-se uma análise de resíduo.

A partir disso, foi aplicado um pós-teste (análise de contraste) para verificar diferenças entre as categorias analisada. Em todos os testes foram considerados significativos os valores de $p < 0,05$. Vale ressaltar que o pós-teste foi aplicado para comparar os níveis dos parâmetros físico-químicos entre as categorias de solo, verificando a significância das diferenças observadas.

Parâmetros que não apresentaram variação significativa entre os tipos de estrutura do solo foram considerados menos relevantes para a fertilidade agrícola, uma vez que sua uniformidade entre esses sugere uma baixa influência na variação da produtividade ou qualidade agrícola, conforme apresentado por Asadu *et al.* (2001).

Essa abordagem, portanto, permitiu o enfoque nos parâmetros que realmente diferem entre os tipos de textura do solo e que, conseqüentemente, têm maior probabilidade de influenciar na fertilidade agrícola da BHRS, sendo essencial para refinar a interpretação dos dados, destacando os fatores físico-químicos mais críticos para o manejo agrícola e a sustentabilidade do uso do solo na bacia hidrográfica.

Considerando a distribuição dos tipos de estrutura do solo, a análise incluiu uma etapa adicional para avaliar como os parâmetros físico-químicos variavam não apenas entre todas as diferentes classes encontradas, mas também especificamente entre os tipos de textura do solo predominantes na BHRS. Assim, a avaliação da fertilidade agrícola foi fundamentada tanto nas diferenças entre os tipos de textura do solo quanto na importância dos solos mais comuns na bacia hidrográfica.

Destaca-se que a metodologia empregada garante a identificação abrangente dos parâmetros físico-químicos mais relevantes para a fertilidade agrícola local, considerando a variação e predominância dos tipos de textura do solo da área de estudo, pois essas etapas foram elaboradas para serem replicáveis em diferentes bacias hidrográficas, tipos de estrutura do solo e parâmetros físico-químicos, permitindo a aplicação dos mesmos princípios e técnicas em outros contextos de estudo. Todas as análises estatísticas foram realizadas utilizando o software R (R CORE TEAM, 2023).

5.3.2 Segmentação das classes de declividade em níveis de aptidão agrícola

A segmentação das classes de declividade em níveis de aptidão agrícola é essencial para o alcance do objetivo deste trabalho, pois possibilita a identificação de áreas adequadas e inadequadas para cultivo de olerícolas na BHRS, otimizando o uso da terra e reduzindo os riscos de erosão do solo. Dessa forma, fundamenta-se uma abordagem técnica para a gestão agrícola sustentável na área de estudo.

Nesta etapa, segmentou-se as classes de declividade com foco na aptidão agrícola por meio do software QGIS 3.36.0., e a classificação foi baseada em estudos que correlacionam a inclinação do terreno com o potencial fértil (LEPSCH, 2011; EMBRAPA, 2018), resultando na seguinte segmentação:

a) Mais apta: declividades entre 0 e 8%, favorecendo a mecanização, com menores riscos de erosão e maior facilidade para a implementação de sistemas de irrigação (LEPSCH, 2011).

b) Medianamente apta: áreas com declividade entre 8 e 20%, que exigem práticas conservacionistas devido ao risco moderado de erosão. Embora possam ser usadas para o cultivo agrícola, apresentam limitações (EMBRAPA, 2018).

c) Menos apta: inclinações superiores a 20% são menos adequadas para o cultivo agrícola, principalmente em função do risco elevado de erosão e dificuldade de mecanização.

5.3.3 Cálculo da distância euclidiana entre os corpos hídricos e segmentação em classes de aptidão agrícola

A análise da distância euclidiana em relação aos corpos hídricos foi realizada para avaliar a aptidão agrícola das áreas, destacando a relevância da proximidade às fontes de água para garantir disponibilidade hídrica e eficiência nas práticas de irrigação.

O cálculo da distância euclidiana (Equação 10) avalia a menor distância linear entre cada ponto de uma área e o corpo hídrico mais próximo.

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (10)$$

Sendo: d se refere à distância euclidiana, x_1 e y_1 são as coordenadas do ponto de origem e x_2 e y_2 são as coordenadas do ponto de destino.

Para realização desta etapa, utilizou-se a malha hídrica da BHRS, disponibilizada pela base de dados do LABGEMM e que foi convertida em formato raster a partir da ferramenta nativa do QGIS, *v.to.rast*, que transforma os dados vetoriais em células raster, facilitando a análise espacial. Posteriormente, aplicou-se a ferramenta *r.grow.distance*, do mesmo software, para calcular a distância euclidiana entre cada célula e o corpo hídrico mais próximos.

Com os valores de distância euclidiana calculados, procedeu-se à segmentação das áreas em três classes de aptidão agrícola, baseando-se na relação entre proximidade a fontes hídricas e potencial agrícola, conforme apontado pela Apostila irrigação e fertirrigação em fruteiras e hortaliças: manejo da água de irrigação (EMBRAPA, 2011).

A partir disso, adotou-se o método de classificação baseado no *break values* do histograma da imagem *.raster* gerada, metodologia amplamente utilizada em análises geoespaciais e reconhecida por sua eficácia em lidar com dados que não seguem uma

distribuição normal ou que possuem uma distribuição irregular (BIJEESH *et al.*, 2020; KE *et al.*, 2023).

O *break values* utiliza o algoritmo de quebras naturais (*Jenks*), que agrupa os dados em intervalos que minimizam a divergência interna e maximizam a variação entre as classes analisadas, sendo útil para contextos em que a distribuição dos dados é não uniforme, assim como no caso das distâncias dos corpos hídricos, que podem exibir uma concentração de valores próximos a zero e uma extensão significativa (BIJEESH *et al.*, 2020; KE *et al.*, 2023).

Portanto, a escolha desse método é justificada pela necessidade de refletir com precisão a variação natural nos dados de distância, além de fornecer categorias que representem adequadamente as diferentes zonas de aptidão na BHRS, garantindo uma classificação mais significativa e útil para a análise agrícola.

Em relação à definição das classes com base nos intervalos determinados pelos *break values* do histograma, essas foram definidas para refletir a aptidão agrícola com base nas distâncias de determinado ponto ao corpo hídrico, sendo-as: 1) mais apta; 2) medianamente apta; 3) menos apta.

5.3.4 Amostragem proporcional estratificada

Foi realizada uma amostragem proporcional estratificada a fim de garantir a representatividade da amostra em relação à quantidade de pixels da BHRS (população total). A escolha desse método se deu devido à sua eficácia em representar adequadamente diferentes subgrupos dentro de uma população heterogênea, conforme discutido por Westfall *et al.* (2011), que recomendam a amostragem estratificada para assegurar que cada estrato da população esteja representado de forma proporcional ao seu tamanho, melhorando a precisão das estimativas e a generalização dos resultados.

Dessa forma, diante das diferentes características físico-químicas do solo e a presença de distintas classes de textura na BHRS, buscou-se garantir que cada estrato (classe de textura do solo) estivesse representado proporcionalmente na amostra.

Inicialmente, foi calculado o tamanho mínimo ideal da amostra com base na margem de erro de 5% e um nível de confiança de 95%, conforme a Equação 11. Posteriormente, realizou-se a distribuição proporcional das amostras entre os estratos (diferentes tipos de textura do solo), conforme apresentado na Equação 12.

$$n = \frac{N \cdot z^2 \cdot p \cdot (1-p)}{e^2 \cdot (N-1) + z^2 \cdot p \cdot (1-p)} \quad (11)$$

Sendo: n: tamanho da amostra, N: tamanho da população, z: valor da distribuição normal para o nível de confiança, p: proporção esperada de indivíduos, e: margem de erro.

$$n_i = n \cdot \frac{N_i}{N} \quad (12)$$

Sendo: n_i: tamanho da amostra no estrato i, N_i: tamanho da população no estrato i, N: tamanho da população, n: tamanho total da amostra.

5.3.5 Modelagem do algoritmo RF para classificar a aptidão agrícola da BHRS em relação à olericultura

Com base nos resultados da amostragem proporcional estratificada, a quantidade total de amostras foi dividida pelo número de variáveis do modelo, abrangendo parâmetros físico-químicos, declividade e distância dos corpos hídricos. Embora alguns desses parâmetros apresentassem diferentes classes de teor, todos foram padronizados em 3 categorias de aptidão agrícola para o cultivo de olerícolas: mais aptas, medianamente aptas e menos aptas.

As amostras foram distribuídas de maneira proporcional entre as variáveis, garantindo que, para cada estrato (classe de estrutura do solo), a quantidade de dados refletisse a representação adequada dos diferentes fatores analisados. Essa abordagem assegurou que cada variável estivesse devidamente representada em todos os estratos, respeitando os valores observados durante a estratificação. Dessa forma, o treinamento do modelo foi capaz de refletir a variabilidade e as características específicas de cada classe de textura do solo.

Ressalta-se que para as classes em que o número total de amostras era ímpar, a amostragem foi realizada arredondando para o inteiro mais próximo, garantindo que todas as classes fossem adequadamente representadas.

Posteriormente, foi realizado o empilhamento dos arquivos em formato *.raster*, contendo as respectivas distribuições espaciais desses parâmetros. Os arquivos foram, então, integrados às amostras classificadas quanto à aptidão agrícola, resultando em uma matriz de dados que compreende as variáveis preditivas (parâmetros físico-químicos, declividade e distância dos corpos hídricos) e a variável alvo (classes de aptidão agrícola: mais aptas ao cultivo de olerícolas, medianamente aptas e menos aptas).

Foi adotado o uso de 50 árvores e 4 feições por divisão na modelagem do algoritmo, levando em conta a variabilidade dos parâmetros físico-químicos em diferentes bacias hidrográficas. Essa abordagem metodológica, que utilizou uma divisão de 70/30 para treinamento e validação, foi escolhida para garantir que possa ser replicada em futuras

aplicações, proporcionando resultados consistentes. Além disso, foi elaborado um gráfico de erro em função da quantidade de árvores, a fim de determinar o número ideal de árvores recomendado para demais trabalhos.

A relevância das variáveis preditivas no modelo foi avaliada utilizando o critério de Gini, e o impacto de cada variável no desempenho do modelo foi quantificado por meio da métrica de *Mean Decrease Accuracy*.

Para avaliar o desempenho da modelagem, foram aplicadas as métricas de acurácia global e o índice Kappa. Adicionalmente, foram calculados a SSV, SPV, PPV e NPV para cada classe de aptidão agrícola, permitindo avaliar a capacidade do modelo em prever corretamente os casos positivos e negativos em cada tipo de classe.

Por fim, a validação do modelo gerado em relação à importância das variáveis foi realizada por meio de registros fotográficos, visando verificar se a correspondência entre as predições do modelo e as condições reais observadas estava sendo corroborada. Além disso, foi elaborado um layout a partir do software QGIS na versão 3.36.0, a fim de facilitar a tomada de decisão dos órgãos agrícolas da região, bem como da comunidade científica e agricultores, permitindo uma visão detalhada acerca da aptidão agrícola para o cultivo de olerícolas.

6 RESULTADOS E DISCUSSÕES

6.1 Análise granulométrica e da declividade da BHRS

A Tabela 2 apresenta o resultado da análise granulométrica encontrada em cada ponto amostral da BHRS.

Tabela 2 – Resultados da análise granulométrica.


Ponto	Areia (g)	Areia (%)	Silte (g)	Silte (%)	Argila (g)	Argila (%)
1	3,9995	38,5044	0,0114	4,2478	0,1174	57,2478
2	5,3535	52,2329	0,0046	1,2085	0,0953	46,5585
3	5,0381	49,1619	0,0150	6,2940	0,0915	44,5440
4	4,7771	48,0113	0,0483	24,4194	0,0546	27,5694
5	6,4660	63,8544	0,0108	4,6228	0,0646	31,5228
6	5,5547	54,5437	0,0175	7,8531	0,0770	37,6031
7	3,7261	35,1128	0,0144	5,0686	0,1239	59,8186
8	5,3857	51,1604	0,0083	1,4948	0,1000	47,3448
9	3,7635	35,2444	0,0207	8,0278	0,1181	56,7278
10	4,4528	42,3855	0,0199	8,0572	0,1029	49,5572
11	5,3079	51,2403	0,0204	8,4048	0,0843	40,3548
12	3,5888	38,7429	0,0199	12,8300	0,0911	48,4300
13	3,4334	36,3045	0,0379	21,0300	0,0812	42,6800
14	3,0092	27,4376	0,0092	2,0062	0,1463	70,5562
15	4,1237	41,2858	0,0227	11,7500	0,0931	46,9500
16	4,0526	38,2170	0,0210	8,2165	0,1117	53,5665
17	3,3869	32,0327	0,0069	1,6587	0,1362	66,3087
18	2,7909	25,9338	0,0120	4,0331	0,1440	70,0331
19	3,0694	27,8771	0,0236	8,9865	0,1319	63,1365
20	3,9999	37,9788	0,0395	18,0106	0,0915	44,0106
21	3,8276	36,4542	0,0176	7,0729	0,1164	56,4729
22	4,0826	40,3073	0,0169	7,9464	0,1045	51,7464
23	2,7896	25,2085	0,0031	1,5500	0,1516	73,2400
24	3,1941	31,0729	0,0123	5,2886	0,1290	63,6386

25	5,0720	50,6645	0,0214	10,6678	0,0774	38,6678
26	7,4839	73,2259	0,0168	6,8370	0,0430	19,9370
27	3,7948	37,1027	0,0107	4,5986	0,1181	58,2986

Fonte: Elaborado pelo autor (2024).

Na Figura 6, encontra-se disposto a espacialidade desses parâmetros na BHRS, adicionados das classes de declividade.

Figura 6 – Distribuição espacial de argila (a), areia (b), silte (c) e declividade (d) da BHRS.



Fonte: Elaborado pelo autor (2024).

A Tabela 3 apresenta a estatística descritiva da distribuição espacial da areia, argila e do silte.

Tabela 3 – Estatística descritiva da distribuição espacial da areia, silte e argila.

Areia				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
25,21	73,22	48,01	42,03	7,05

Silte				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP ($\pm$)
1,21	24,42	23,21	8,24	3,78
Argila				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP ($\pm$)
19,94	73,24	53,30	49,73	8,73

Fonte: Elaborado pelo autor (2024).

A Tabela 4 demonstra o quantitativo das classes de declividade e o seu respectivo percentual na BHRS.

Tabela 4 – Área e percentual das classes de declividade na BHRS.

Declividade		
Classe	Área (km²)	Porcentual na BHRS (%)
0 a 3%	25,91	12,78
3 a 8%	14,60	7,20
8 a 20%	71,56	35,31
20 a 45%	75,77	37,39
45 a 75%	13,82	6,82
>75%	1,01	0,50

Fonte: Elaborado pelo autor (2024).

Analizados conjuntamente, os percentuais de areia, silte e argila, atrelados às classes de declividade, são atributos que, a depender de sua concentração, implicam em fatores que impactam negativamente o meio (RAJBANSHI *et al.*, 2023), com destaque para os processos erosivos, conforme destacado He *et al.* (2023), Yang *et al.* (2023) e por Smith e Wischmeier (1962), que ainda apresentam duas possíveis formas dessa influência acontecer: a) velocidade de infiltração ou permeabilidade da água no solo e; b) influência na resistência do solo às forças de dispersão, agregação e transporte pela energia cinética da chuva.

Partindo desse princípio, entende-se que a predisposição do solo aos fatores erosivos tende a aumentar quando os teores de areia e silte são elevados, e a diminuir com altas concentrações de argila (WISCHMEIER; SMITH, 1958), sendo essa situação influenciada pelo grau de declividade do local (DELGADO *et al.*, 2023) e pelas práticas conservacionistas ali presentes (RAJBANSHI *et al.*, 2023).

Nesse sentido, a análise da distribuição espacial dos parâmetros granulométricos da BHRS apresenta uma clara predominância das concentrações de argila no solo. Os resultados demonstram que a média espacial de argila é próxima de 50% em grande parte da sua extensão territorial, e esse padrão é particularmente evidente nas regiões norte e centro-oeste, onde a concentração de argila pode atingir até 60% do solo.

Estudo realizado pelo IAC corrobora a predominância de solos argilosos na região, conforme identificado no Levantamento Pedológico do Estado de SP, o qual destaca que grande parte da área em análise é caracterizada por Latossolos Vermelhos, reconhecidos pela alta concentração de argila (ROSSI, 2017).

Adicionalmente, os levantamentos de solos realizados na região de Ibiúna indicam que a alta concentração de argila nos Latossolos Vermelhos influencia diretamente a retenção de umidade e disponibilização de nutrientes (ROSSI, 2017), fatores essenciais para a aptidão agrícola da região, especialmente para as culturas de olericultura.

Convém destacar que locais com predominância de argila, em função das suas propriedades químicas e físicas, geralmente, são mais propícias para fins agrícolas (REICHARDT, 1987), por mais que essa definição esteja sendo, aos poucos, modificada, por meio das estratégias adotadas pela AP (KARUNATHILAKE *et al.*, 2023). Ainda assim, essa concentração pode se vincular à presença predominante da atividade de olericultura na BHRS (BEZERRA, 2022).

Em oposição a esse cenário, no sudeste da bacia hidrográfica, a quantidade de argila no solo é bastante inferior ao valor médio de 49,73%, atingindo concentrações de aproximadamente 20% do solo. Situação similar é verificada em uma pequena porção de área ao oeste da BHRS, que apresenta valores abaixo da distribuição espacial média, o que pode influenciar diretamente na dificuldade da retenção de água nessas regiões (BRADY; WEIL, 2009), havendo a necessidade de práticas de conservação, protegendo esse solo do arraste de partículas e consequente perda de nutrientes (CHEN *et al.*, 2019).

A partir da análise da classe de areia, evidencia-se uma disposição inversamente proporcional aos teores de argila, ou seja, onde a argila predomina, a concentração de areia tende a ser mais baixa, e vice-versa. Essa tendência revela um desequilíbrio na distribuição dos componentes granulométricos dos solos na região da BHRS, o que pode afetar diretamente a qualidade e a fertilidade do solo.

Essa perspectiva vale destaque pois, para o cultivo de olerícolas, recomenda-se que o solo ideal seja plano ou levemente inclinado, profundo, com textura média (Areno-Argiloso ou Argilo-Arenoso), e possuir boa aeração e drenagem, mas também uma razoável capacidade de

retenção de água. Comparando esses parâmetros ideais com os resultados apresentados, observa-se que o desequilíbrio entre os teores de areia e argila na BHRS pode comprometer a adequação dos solos para a olericultura (EMBRAPA, 2007).

Além do mais, em áreas onde a argila é predominante, a baixa concentração de areia pode afetar a drenagem e a aeração do solo, enquanto em áreas com maior teor de areia, a menor capacidade de retenção de água pode influenciar na manutenção da umidade necessária para as essas culturas (BRADY; WEIL, 2009; CHEN *et al.*, 2019). Portanto, entender e corrigir essas diferenças texturais é crucial para otimizar o manejo e garantir a sustentabilidade e produtividade do solo na região.

Ainda assim, essa situação pode ser considerada normal, pois, conforme abordado por Souza *et al.* (2004), as frações do solo geralmente apresentam comportamento inverso, principalmente no quesito de distribuição, pois como são medidos em porcentagem, quando há acréscimo de um parâmetro ocorre a redução de outro.

Contudo, Zaaboubi *et al.* (2020) levantaram a hipótese de que, de fato, esse desequilíbrio textural poderia influenciar no rendimento agrícola, particularmente em regiões secas, pois, ao se conhecer a distribuição granulométrica de um local, auxilia-se o conhecimento da relação solo-planta e se aponta os locais com condições favoráveis para o melhor rendimento.

Nessa perspectiva, a situação evidencia a necessidade de um manejo adequado nas áreas com a predominância de um determinado parâmetro, pois, por mais que essas práticas possuam maior impacto nas propriedades físicas de solos arenosos (RICHART, 2005; BRADY, 1989), no setor majoritário de argila, em casos de uso inadequado, existe a tendência de ocorrer a perda da fase argilosa e o aumento da fração de areia (RESENDE; ROSOLEN, 2013).

Além disso, ainda que tenha apresentado valores médios menores, os percentuais de areia apresentaram-se relativamente altos por toda a área, com destaque para as concentrações no sudeste da BHRS, que apresentou valores de aproximadamente 73% da composição do solo nessa região. Essa situação é similar a uma pequena concentração de areia a oeste da BHRS.

Não obstante, é pertinente ressaltar que, conforme apontado por Donagemma *et al.* (2016), em condições ambientais similares, as áreas com grandes porcentagens de areia estão mais propensas à degradação e, conseqüentemente, à perda de capacidade produtiva quando comparados aos locais com maiores teores de argila.

Por outro lado, os menores teores de areia estão distribuídos ao norte da bacia hidrográfica, onde se situa a malha urbana de Ibiúna e os altos teores de argila, o que é correlato

à permeabilidade (SKEMPTON, 1953) e aos desafios da construção civil para com os solos com alto percentual de areia (ROY; BHALLA, 2017).

Nesse sentido, Vieira *et al.* (2020), ao verificarem amostragens de solo sob Mata Atlântica em regeneração para fins de fertilidade, notaram, por meio de análise granulométrica, que a classe de areia foi a que menos apresentou percentuais na variabilidade espacial do local, apontando para uma boa recuperação da fertilidade do solo por meio da facilidade na ciclagem dos nutrientes imposta pela classe de argila.

Portanto, o desequilíbrio percentual entre essas partículas no solo em algumas regiões da BHRS aponta para a necessidade de se realizar um manejo adequado frente às práticas agrícolas, principalmente no setor sudeste da bacia hidrográfica, que, em casos de uso inadequado, pode-se modificar a densidade e a porosidade do solo daquele local, impactando na infiltração da água e no escoamento superficial (SILVA *et al.*, 2020).

Ainda diante dessa desarmonia das classes granulométricas, os percentuais de silte apresentaram valores médios muito abaixo dos de argila e areia, em torno de 8%, com as maiores concentrações no sudeste e ao sul da bacia.

Além da relação entre areia e argila, é importante considerar o papel do silte, frequentemente situado como intermediário entre essas duas classes granulométricas, e que, por sua vez, é suscetível a processos de erosão, sendo o primeiro a se deslocar sob a ação das gotas de chuva, como destacado por Resende *et al.* (1999).

Essa instabilidade do silte é particularmente preocupante, uma vez que sua deposição em áreas mais baixas pode contribuir significativamente para o assoreamento de corpos d'água, conforme ressaltado por Gomes *et al.* (2007) e Cabral (2005). Portanto, ao considerar não apenas a relação entre areia e argila, mas também a influência do silte, torna-se ainda mais evidente a complexidade da distribuição granulométrica do solo na região da BHRS.

Essa análise mais abrangente não apenas sustenta a observação inicial de desequilíbrio entre os componentes granulométricos, mas também ressalta a importância de se compreender os processos de erosão e sedimentação para o manejo adequado do solo e a conservação dos recursos hídricos na área estudada.

Assim, é possível observar que as maiores concentrações de silte estão ao sudeste da bacia, em áreas com baixa concentração de argila e nas proximidades do rio Sorocabaçu, onde possivelmente ocorrem deposições coluviais, que podem estar associadas ao acúmulo de silte nessas regiões. Isso sugere a necessidade de implementar práticas conservacionistas para prevenir o arraste dessas partículas e o consequente assoreamento do corpo hídrico.

Entre as práticas conservacionistas para mitigar essa situação, recomenda-se a adoção de técnicas de terraceamento, que ajudam a reduzir a velocidade da água e a erosão do solo (RUTEBUKA *et al.*, 2021) e a promoção de coberturas vegetais no solo, como a utilização de culturas de cobertura, que foi a técnica conservacionista mais eficiente na redução da perda de solo em todos os 5 continentes analisados por Xiong *et al.* (2018) – América do Norte, América do Sul, Ásia, Europa e África.

Frente a esses resultados, é imprescindível discutir a necessidade de uma gestão eficiente do uso da terra na BHRS, havendo a premência de se realizar um manejo do solo eficiente, atrelado às práticas de conservação, para que esses possam, além de aumentar a aptidão agrícola local, proteger os mananciais e a qualidade ambiental.

Nesse ponto, convém ressaltar os resultados da classe de declividade da BHRS, que corroboram a necessidade de uso adequado das terras, dada a predominância dos declives ondulado e forte ondulado, características de terrenos irregulares, frequentemente compostos por Argissolos ou Cambissolos, propensos ao escoamento superficial, o que reforça a importância de práticas conservacionistas.

Isso significa que os locais com manejo inadequado do solo estarão mais predispostos à erosão, assim como apresentado por Kucuker; Giraldo (2022) em sua área de estudo, que concluíram que as áreas mais susceptíveis aos processos erosivos foram classificadas como degradadas e contendo solo exposto.

Todavia, associados aos resultados apresentados por Paixão (2021), acredita-se que a predominância das áreas de mata na BHRS, ocorrendo em mais de 50% da sua extensão territorial, sendo que as maiores áreas estão presentes nos locais de superior declive, corrobora ao fato de que, analisados conjuntamente, por mais que a área possua aptidão ao arraste das partículas, alavancadas pelo grau de declividade, esse impacto é freado pela presença da vegetação densa e com grande diversidade de espécies vegetais, acarretando em uma maior infiltração da água.


É crucial destacar que a fertilidade do solo possui influência nos processos de erosão, pois solos mais férteis tendem a reter melhor as partículas, reduzindo a perda de nutrientes. Ademais, entre as principais propriedades que afetam a erosão estão a textura, densidade aparente, porosidade, teor de matéria orgânica, estabilidade dos agregados e o pH. Em oposição a isso, solos com baixa fertilidade, além de apresentarem menor retenção de partículas, são mais suscetíveis à erosão, resultando em perdas significativas de nutrientes e empobrecimento do solo (RUTEBUKA *et al.*, 2021; ZAABOUBI *et al.*, 2020)

Em síntese, ao analisar a suscetibilidade à erosão na BHRS, destacam-se os pontos críticos na região sudeste, caracterizados por baixos teores de argila e altas concentrações de areia e silte, sugerindo uma maior vulnerabilidade ao arraste de partículas do solo, especialmente na ausência de práticas conservacionistas. Portanto, reforça-se a importância de monitoramento contínuo por parte dos órgãos ambientais e fiscalizadores para garantir um uso do solo sustentáveis nessa área.

6.2 Geração do modelo das classes de textura do solo baseado no algoritmo *Random Forest*

A Figura 7 apresenta o modelo contendo as classes de textura do solo da BHRS gerado por meio do algoritmo RF. Na Tabela 5 encontra-se disposto o quantitativo das classes e, na Figura 8, a disposição das concentrações de areia, silte e argila com base no diagrama textural.

Figura 7 – Classificação da textura do solo da BHRS gerado com base no algoritmo RF.



Fonte: Elaborado pelo autor (2024).


Tabela 5 – Quantitativo de classes de textura do solo da BHRS.

Classe	Área (km ²)	Porcentual na BHRS (%)
--------	-------------------------	------------------------

Argilosa	104,43	51,53
Argilo Arenosa	58,13	28,68
Franco Argilo Arenosa	9,40	4,64
Muito Argilosa	30,71	15,15

Fonte: Elaborado pelo autor (2024).

Figura 8 – Distribuição espacial de areia, silte e argila nas classes de textura do solo da BHRS.



Fonte: Elaborado pelo autor (2024).

Inicialmente, convém ressaltar que a aplicação do algoritmo RF é comumente utilizada por cientistas do solo e ambientais para processos de avaliação e classificação, devido à, principalmente, sua precisão (CUTLER *et al.*, 2007; BRUNGARD *et al.*, 2015; HEUNG *et al.*, 2014).

Tratando-se especificamente da ciência do solo, o RF foi utilizado para diversos propósitos, mas com poucas replicabilidades, principalmente diante das diferentes classificações de solo disponíveis (GAMBILL *et al.*, 2016).

Contudo, é válido destacar os resultados apresentados por Ließ *et al.* (2012) e Heung *et al.* (2014), em que os primeiros pesquisadores constataram, no sul dos Andes equatorianos,

que o modelo de classificação obtido por RF na predição espacial da textura do solo obteve os melhores resultados frente às árvores de regressão e, os segundos, o excelente desempenho do algoritmo para classificar classes de solo ainda não mapeadas no Vale Lower Fraser, localizada no oeste do Canadá e que possui ocupação predominantemente agrícola e urbana, assim como a BHRS.

Em se tratando de níveis de fertilidade agrícola, as propriedades mineralógicas que compõe a textura do solo são consideradas por ter um papel significativo nessa finalidade (BADRAOUI *et al.* (1995), além de possuírem um efeito duplo no seu potencial de fertilidade, pois: a) influencia as reações químicas que regulam a disponibilidade e absorção de nutrientes; e b) afeta as propriedades físicas que controlam o equilíbrio da umidade e as condições físicas do solo (KARATHANASIS, 1985).

Considerando os resultados obtidos para a BHRS, nota-se que a classe de textura mais predominante é a argilosa, cobrindo mais de 50% da área. A classe Argilo-Arenosa segue, em termos de concentração, com uma representação significativa, mas inferior à da argilosa. Assim, a predominância de Argila é evidente, enquanto a Argilo-Arenosa também tem uma presença relevante, mas menor.

Essa característica, distribuída em quase 80% da bacia hidrográfica e considerando a atividade de olericultura disposta na área, é correlato ao papel mineralógico da argila, sendo considerado por Kome (2019) como grande influenciador da fertilidade agrícola e do crescimento das plantas, principalmente diante dos seus impactos direto nas propriedades físicas, químicas e biológicas do solo.

Adicionalmente, segundo Newman (1984), ao abordar o manejo para a produção agrícola, é crucial considerar que solos com essas características possuem estruturas complexas e uma variedade de distribuições de tamanho dos poros. Isso ocorre devido à propriedade cimentante da argila, que propicia a formação de agregados secundários ao se combinar com a fração de areia, como também observado por Araújo (2004).

A distribuição espacial dessas classes na BHRS é consistente com os resultados apresentados por Pacheco; Cantalice (2011), que concluíram que solos com ampla distribuição de partículas de argila podem ter os espaços maiores entre os poros preenchidos por partículas menores, resultando em uma maior compactação do solo.

Por último, tem-se as classes muito argilosa, compondo aproximadamente 30% da extensão territorial, e a classe franco-argilo-arenosa, com uma quantidade pouco representativa (aproximadamente 4,6%), mas que possuem características de resistência à penetração das raízes e drenagem mais lenta, exigindo um manejo adequado (SCHWAB, 1993).

Em vista da classe muito argilosa, nota-se uma predominância ao norte da BHRS, fato que se relaciona com a gestão territorial e as especificações geotécnicas da argila, haja vista que é considerado um material vantajoso para a construção civil. Ainda assim, o exposto exige um manejo adequado da terra, principalmente pela possibilidade de compactação atribuídos às classes de solo dispostas pela BHRS.

Em relação ao desempenho do algoritmo RF, na Tabela 6 e na Tabela 7 estão descritas as características estatísticas de cada classe para a geração do modelo. A Figura 9 apresenta a importância das características para a geração do modelo.

Tabela 6 – Desempenho do algoritmo RF para classificação textural do solo na BHRS.

Treinamento					
Classe	A	AAR	FAAr	MA	Erro
1	170	10	0	0	0,05
2	0	108	0	0	0,00
3	0	0	56	0	0,00
4	0	0	0	48	0,00
Modelo					
Classe	A	AAR	FAAr	MA	
1	78	0	0	0	
2	0	50	10	0	
3	0	0	0	0	
4	0	0	0	10	


Sendo as classes: A: argilosa; AAR: Argilo-Arenosa; FAAr: Franco-Argilo-Arenosa; MA: Muito Argilosa.
Fonte: Elaborado pelo autor (2024).

Tabela 7 – Estatística das classes de textura do solo na BHRS.

	Classe			
Estatística	A	AAR	FAAr	MA
Sensitivity	1,00	1,00	0,00	1,00
Specificity	1,00	0,88	1,00	1,00
Pos Pred Value	1,00	0,83	NaN	1,00
Neg Pred Value	1,00	1,00	0,93	1,00
Balanced Accuracy	1,00	0,95	0,50	1,00

Sendo as classes: A: argilosa; AAR: argilo-arenosa; FAAr: franco-argilo-arenosa; MA: muito argilosa.
Fonte: Elaborado pelo autor (2024).

Figura 9 – Importância das classes no modelo gerado.




Fonte: Elaborado pelo autor (2024).

O modelo gerado apresentou erro OOB de 2,78%, e o melhor desempenho foi obtido por meio de 50 árvores e 4 nós (Figura 10). O índice Kappa foi de 0,88%, enquanto a acurácia do modelo foi de 0,92%.

A excelência dos resultados obtidos é notória frente ao desempenho do modelo em seu treinamento, em que apenas a classe argilosa confundiu 10 das amostras com a argilo-arenosa, afetando o desempenho da sua SPV.

Figura 10 – Geração de erros do modelo de textura do solo com base no número de árvores.



Fonte: Elaborado pelo autor (2024).

Vale destacar que a SSV indica como o modelo trabalha, e esse parâmetro, juntamente com a SPV próximos a 1, corroboram e aumentam a confiabilidade dos resultados apresentados, conforme estudos correlatos (TAREK *et al.*, 2023; KULIMUSHI *et al.*, 2023).

No entanto, as variações nos resultados podem ser atribuídas às características similares das categorias de solo encontradas na BHRS, que incluem Argilosa, Argilo-Arenosa, Franco-Argilo-Arenosa e Muito Argilosa. Vale destacar que esses tipos de solo diferem-se principalmente pelo percentual de argila, o que pode ter contribuído para a alta SSV e SPV observadas (SBCS, 1984;1996),

Portanto, acredita-se que a similaridade nas características texturais pode ter facilitado a identificação correta das categorias pelo modelo. Além disso, a alta confiabilidade dos resultados pode ser influenciada pela homogeneidade geral dos dados e pela capacidade do modelo em distinguir entre variações sutis nas proporções de argila.

Já no modelo gerado, a classe argilo-arenosa confundiu 10 pixels com a classe Franco-Argilo-Arenosa, fato que refletiu no desempenho do NPV da classe e, consequentemente, em suas acurácias. Contudo, esses erros não influenciaram no desempenho do classificador.

A análise dos resultados que apresentam a importância das variáveis para com a geração do modelo reforça a importância do tipo de textura do solo no desempenho do

algoritmo, com o percentual de areia se destacando como o parâmetro mais relevante, seguido pela argila e o silte.

Esse resultado indica que, apesar da similaridade nas características texturais entre os diferentes tipos de solo na BHRS, a variação no teor de areia foi o fator mais decisivo na classificação das categorias pelo RF. Ademais, esses resultados estão em concordância com as análises granulométricas apresentadas anteriormente.

A alta relevância da areia sugere que as diferenças na proporção desse componente textural desempenharam um papel crucial na distinção entre os solos, enquanto a argila, com menor variação, também contribuiu significativamente, mas de forma menos expressiva. A menor importância do silte reflete sua menor variabilidade nos solos da BHRS, impactando menos o desempenho geral do modelo.

Portanto, é plausível afirmar que o modelo desenvolvido conseguiu identificar que a classificação textural do solo está intrinsecamente relacionada com a concentração de cada componente mineral, permitindo sua aplicação na classificação de solos em unidades de gestão territorial semelhantes, fortalecendo a confiabilidade e a utilidade do modelo para futuras análises e planejamento de uso da terra na BHRS, assim como apresentado por Arantes *et al.* (2024).

6.3 Análise química do solo

6.3.1 Micronutrientes

A Tabela 8 apresenta os resultados dos micronutrientes analisados em cada ponto amostral. Na Figura 11 encontra-se a distribuição espacial dos mesmos na BHRS.


Tabela 8 – Valores de cada ponto amostral para os micronutrientes (mg/dm³).

Ponto	B	Cu	Fe	Mn	Zn
1	0,2	1,2	49	1,6	1,1
2	0,36	0,4	94	4,2	1,1
3	0,2	0,4	98	0,6	0,7
4	0,08	0,7	23	18,3	0,7
5	0,14	1,1	28	12,1	1,2
6	0,18	0,1	28	0,1	0,1

7	0,06	0,2	25	3,7	0,9
8	0,26	0,4	103	0,3	0,2
9	0,2	0,1	29	7,4	0,3
10	0,28	1,1	68	1,2	0,7
11	0,42	1,7	36	50,4	1
12	0,26	0,2	44	1,2	0,1
13	0,14	0,1	2	0,4	0,1
14	0,16	0,1	18	0,6	0,1
15	0,18	5,6	64	9,8	1,2
16	0,2	0,1	53	1,8	1,3
17	0,13	0,2	14	0,3	0,3
18	0,1	0,1	2	0,1	0,1
19	0,19	0,1	22	0,1	0,1
20	0,28	0,7	224	11,2	2,9
21	0,16	0,5	82	3,1	0,6
22	0,11	0,2	52	0,2	0,1
23	0,16	0,1	5	0,1	0,1
24	0,19	0,1	51	0,1	0,1
25	0,1	0,1	33	0,1	0,1
26	0,07	0,4	23	2,8	0,7
27	0,2	0,6	79	0,9	0,4

Fonte: Elaborado pelo autor (2024).

Figura 11 – Distribuição espacial dos micronutrientes em relação às classes de teor para o cultivo de olerícolas na BHRS.



Fonte: Elaborado pelo autor (2024).

Na Tabela 9 apresenta-se, respectivamente, a estatística descritiva da distribuição espacial de B, Cu, Fe, Mn e Zn, e, por último, na Tabela 10, é apresentado o quantitativo das classes e o seu respectivo percentual na BHRS.

Tabela 9 – Distribuição espacial dos micronutrientes do solo na BHRS (mg/dm³).

B				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
0,06	0,42	0,36	0,18	0,04
Cu				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
0,10	5,60	5,50	0,62	0,64
Fe				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
2,00	224,00	222,00	50,52	24,12

Mn				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
0,10	50,40	50,30	4,93	5,12
Zn				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
0,10	2,90	2,80	0,60	0,36

Fonte: Elaborado pelo autor (2024).

Tabela 10 – Área e percentual das classes de micronutrientes do solo para o cultivo de olerícolas na BHRS.

B (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Baixa (0 – 0,20)	144,70	71,40
Média (0,21 – 0,60)	57,97	28,60
Alta (>0,60)	0,00	0,00
Cu (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Baixa (0 – 0,2)	57,60	28,42
Média (0,3 – 0,8)	99,77	49,23
Alta (>0,8)	45,30	22,35
Fe (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Baixa (0 – 4)	1,70	0,84
Média (5 – 12)	4,00	1,97
Alta (>12)	196,97	97,19
Mn (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Baixa (0 – 1,2)	32,44	16,00
Média (1,3 – 5,0)	98,04	48,38
Alta (>5)	72,19	35,62
Zn (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Baixa (0 – 0,5)	95,08	46,92
Média (0,6 – 1,2)	97,73	48,22
Alta (>1,2)	9,86	4,86

Fonte: Elaborado pelo autor (2024).

Analísado espacialmente e com base na classificação dos teores de micronutrientes no solo para o cultivo olericultura, a BHRS possui uma área de aproximadamente 59 km² de teor médio de B, enquanto a classe baixa foi, majoritariamente, distribuída por aproximadamente 143 km². Não houve presença da classe alta do parâmetro.

Vale destacar que, em se tratando de solos brasileiros, a deficiência desse parâmetro é um fator comum, mesmo em solos férteis (EMBRAPA, 2023; OLIVEIRA *et al.*, 1999), sendo essa situação, ressaltada por Malavolta *et al.* (1997), que destaca que o B é um dos micronutrientes que estão em menor quantidade nos solos desse território, correlacionando à concentração espacial média de 0,18 mg/dm⁻³ na BHRS (RAIJ *et al.*, 1997).

A baixa variabilidade espacial desse parâmetro (DvP de $\pm 0,04$ mg/dm³) indica que os teores desse micronutriente são semelhantes em grande parte do território da BHRS. Isso significa que, apesar das áreas com classes baixas e médias predominarem, a uniformidade dos valores implica que as correções devem ser aplicadas de maneira ampla e não pontual, já que não há grandes variações locais que justifiquem ajustes específicos.

Além do mais, é importante destacar que a presença de B é concentrada, em quase sua totalidade, em uma faixa do setor centro-sul da bacia hidrográfica, o que pode ser relacionado com os resultados de textura do solo, fator que afeta a disponibilidade de B em determinados locais (WEAR; PATTERSON, 1962), pois Gupta (1980) indica que essa relação pode ser atribuída ao fato de que, nessa superfície, parte desse parâmetro é adsorvido pelas partículas de argila.

Em oposição ao exposto, o autor desse estudo menciona que os menores percentuais de B, em solos arenosos, podem estar associados a lixiviação do micronutriente, apontando para a importância das práticas de conservação e manejo adequado da BHRS.

Em relação a distribuição espacial das classes de teor de Cu na BHRS, nota-se que esse micronutriente é mais bem distribuído, em proporção, pelos setores da bacia hidrográfica. Ainda assim, existe a predominância da classe média (49,23%) por toda a parte centro-sul da área, separada pelo teor alto no centro-oeste/sul (22,35%) da bacia e pela classificação baixa ao norte (28,42%)

Convém salientar também que o valor espacial médio de 0,62 mg/dm³ de Cu apresentado na BHRS é caracterizado como teor médio no solo para o cultivo de olerícolas. Ainda assim, em alguns pontos da classe alta, foi notório a discrepância dos valores, chegando a apresentar valores 800% superiores à média do micronutriente.

O DvP de $\pm 0,64$ mg/dm³ para o Cu indica uma maior variabilidade em relação ao encontrado para o B, sugerindo que há diferenças significativas na disponibilidade desse

parâmetro em diferentes áreas da bacia hidrográfica. Portanto, tal situação pode exigir estratégias diferenciadas de manejo e correções para equilibrar a disponibilidade desse parâmetro no solo da BHRS.

Diante disso, é válido associar a presença da classe alta de Cu na região da BHRS que possui os maiores teores de argila, o que implica na adsorção máxima do micronutriente (ALLEONI *et al.*, 2007), sendo conveniente destacar que, ainda segundo os autores, pelo fato de que as reações físico-químicas se processam, em grande parte, na superfície dos colóides, a fração argila que é formada por colóides com cargas negativas exerce um controle considerável na adsorção do Cu.

Nessa perspectiva, Pombo e Klamt (1986) também verificaram uma correlação significativa entre a adsorção de Cu e o teor de argila do solo, melhorando assim o metabolismo de proteínas, carboidratos, na fixação simbiótica de N₂ e, conseqüentemente, na fertilidade agrícola do local.

Em relação a distribuição espacial das classes de Fe para o cultivo de olerícolas, a BHRS é, de forma predominante, caracterizada por apresentar altos teores desse micronutriente, pois 97,19% da sua extensão territorial foi considerada como alta, apontando para a característica das hortaliças em apresentar bons teores desse parâmetro (SOUSA *et al.*, 2007; BORGES *et al.*, 2014).

O valor médio de 50,52 mg/dm³ para Fe, com um DvP de $\pm 24,12$, indica uma variabilidade espacial considerável, demonstrando que, apesar da predominância de teores altos, ainda há diferenças significativas nas concentrações em diferentes locais da BHRS, o que serve como subsídio para uma análise mais precisa, a fim de garantir que todas as áreas estejam com as quantidades adequadas de Fe para o cultivo agrícola, evitando potenciais impactos negativos devido a excessos ou deficiências.

Essa predominância corrobora também o fato de que o Fe ocorre em concentrações relativamente altas na maioria dos solos, principalmente agrícolas, haja vista que, diante dos micronutrientes essenciais para o crescimento e produtividade das plantas, é o requerido em maiores quantidades (ZULUAGA *et al.*, 2023).

De maneira oposta, menos de 3% da BHRS foi classificada com baixo ou médio teor de Fe para a atividade agrícola, com pequenas concentrações ao norte e ao sul da bacia, ou seja, por mais que nesse caso, e em questão de concentração, a distribuição espacial do Fe não vá influenciar na indicação das áreas mais adequadas para o cultivo de olerícolas, é válido destacar a importância de se monitorar as concentrações desse parâmetro para que não ocorra danos às estruturas das plantas (LAPAZ *et al.*, 2022).

Resultados similares a esses foram apresentados por Silva (2017), em que a autora verificou, ao avaliar o uso do solo sobre a qualidade da água em área com produções de olericultura, altas concentrações de Fe tanto no solo quanto na água do local analisado, apresentando valores similares ao de concentração média da BHRS.

Em relação ao Mn, o micronutriente apresentou predominância das classes médias e de alto teor no solo para o cultivo de olerícolas, com destaque para a classe intermediária, que apresentou 48% da extensão territorial da BHRS.

O valor médio de $4,93 \text{ mg/dm}^3$ desse parâmetro no solo da bacia hidrográfica, com um DvP de $\pm 5,12$, reflete uma variação considerável nos teores encontrados, indicando que há uma distribuição desigual do parâmetro na extensão territorial da BHRS. Tal variabilidade pode influenciar diretamente na aplicação de corretivos, exigindo, portanto, um manejo mais específico para garantir que todas as áreas recebam quantidades adequadas de Mn no que tange ao cultivo de olerícolas.

Vale destacar que o alto teor também apresentou valores expressivos de distribuição, com aproximadamente 35% da área, enfocadas no limite sul da bacia e com algumas faixas de concentração no centro-oeste da área de estudo. Em oposição a isso, a classe baixa apresentou pequenos valores ao norte da BHRS.

Em relação a sua distribuição descritiva, é válido destacar que o valor médio ($4,93 \text{ mg/dm}^3$) da bacia hidrográfica apresentou valores muitos próximos do limite da classe alta de teor para o cultivo de hortaliça ($>5 \text{ mg/dm}^3$), fato que explica e aponta para a importância do parâmetro para com a fertilidade agrícola local.

A boa distribuição de Mn pela BHRS é correlata às definições de nutrição de olerícolas apresentadas por Mello e Mendonça (2017), que ressaltam que a disponibilidade do Fe no solo é altamente dependente do teor de Mn, sendo que na presença de MnO_2 o ferro reduzido se oxida e passa para a forma férrica não absorvida pelas plantas. Portanto, a disponibilidade de Fe, segundo os autores, é mais dependente do equilíbrio com o Mn do que o teor de Fe absoluto.

Perante a importância desse micronutriente na fertilidade dos solos com presença de olericultura, Franco (2019) apresenta que, embora a absorção do Mn seja entre 3 e 5%, as frutas e hortaliças são fonte moderadamente boas desse parâmetro, o que é destacado também por Gallagher (2010).

Por último, em relação ao Zn, houve a predominância das classes de médio e baixo teor para o cultivo de olerícolas, que, analisadas conjuntamente, foram responsáveis por estarem presentes em mais de 95% da extensão territorial da BHRS, cobrindo uma área de $192,81 \text{ km}^2$.

De forma oposta, a classe alta apresentou poucas concentrações desse micronutriente, estando presente em apenas uma porção do oeste da bacia, cobrindo uma área de 4,86%.

O valor médio de 0,60 mg/dm³ de Zn, com um DvP de $\pm 0,36$ mg/dm³, indica uma variação baixa na BHRS, sugerindo uma distribuição homogênea do micronutriente. Embora predominem classes de médio e baixo teor, essa baixa variabilidade dificulta a identificação de áreas com deficiência ou excesso. Assim, as estratégias de manejo e aplicação de corretivos podem ser feitas de forma ampla e uniforme, garantindo ajustes adequados nas áreas destinadas ao cultivo de olerícolas e evitando intervenções pontuais.

Em relação a sua concentração, o Zn apresentou valor médio no limite da classificação entre os teores baixos e médios para o cultivo de olerícolas, e, ao analisar o valor máximo encontrado, é notório que, mesmo na classe alta, o valor não se torna muito discrepante frente às concentrações de classe média e baixa.

Todavia, a distribuição espacial de Zn na BHRS pode se relacionar com os resultados apresentados por Natasha *et al.* (2022), em que os autores frisam que as frações de argila desempenham um papel vital na disponibilidade de Zn no solo, pois esse micronutriente não é igualmente adsorvido em todos os minerais argilosos. Nessa perspectiva, segundo Małeck *et al.* (2015), geralmente, os locais com maior presença de argila e sumo teor de Fe, atrelados a baixas concentrações de Mn, contribuem para o aumento da adsorção de Zn.

6.3.2 Macronutrientes

A Tabela 11 apresenta os valores encontrados nos pontos amostrados para cada macronutriente analisado, e a Figura 12 apresenta a distribuição espacial desses na BHRS.


Tabela 11 – Valores de cada ponto amostral para os macronutrientes (mmolc/dm³).

Ponto	Ca	Mg	K	P-resina	S
1	50	6	2	14	24
2	48	9	2,8	10	12
3	10	0	0,2	6	18
4	95	20	0,6	9	6
5	96	15	1,2	18	25
6	4	1	0,6	5	12
7	84	2	0,2	8	5

8	5	1	0,4	5	14
9	10	3	2,1	7	19
10	26	10	2,1	26	15
11	48	19	2,7	29	3
12	14	2	0,7	3	22
13	3	1	0,4	1	61
14	8	4	0,3	3	19
15	72	7	1,4	22	7
16	3	0	0,4	5	11
17	21	2	0,5	5	97
18	3	1	0,2	1	40
19	4	1	0,3	4	25
20	50	16	1,1	39	28
21	18	2	0,5	7	37
22	16	19	0,4	3	8
23	15	5	1,7	2	96
24	5	2	0,3	2	44
25	9	1	0,5	2	21
26	77	5	0,4	7	5
27	17	6	1,3	28	10

Fonte: Elaborado pelo autor (2024).

Figura 12 – Distribuição espacial dos macronutrientes em relação às classes de teor para o cultivo de olerícolas na BHRS.



Fonte: Elaborado pelo autor (2024).

Na Tabela 12 apresenta-se, respectivamente, a estatística descritiva da distribuição espacial desses parâmetros, enquanto a Tabela 13 demonstra o quantitativo desses na BHRS.

Tabela 12 – Distribuição espacial dos macronutrientes do solo na BHRS.

Ca				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
3,00	96,00	93,00	30,75	17,37
Mg				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
2,51	20,00	17,49	5,92	3,70
K				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
0,20	2,80	2,60	0,92	0,50
P-resina				

Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP ($\pm$)
1,00	39,00	38,00	9,84	6,11
S				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP ($\pm$)
3,00	97,00	94,00	24,63	13,23

Sendo: Ca, Mg e K (mmol_c/dm³) e P-resina e S (mg/dm³).

Fonte: Elaborado pelo autor (2024).

Tabela 13 – Área e porcentual dos teores para cultivo de olerícolas dos macronutrientes.

Ca (mmol_c/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (0 – 4)	0,84	0,41
Baixo (5 – 10)	13,76	6,80
Médio (11 – 20)	46,76	23,07
Alto (21 – 40)	56,51	27,88
Muito alto (>40)	84,80	41,84
Mg (mmol_c/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (0 – 2)	18,05	8,90
Baixo (3 – 5)	85,23	42,05
Médio (6 – 10)	69,12	34,10
Alto (11 – 15)	23,11	11,42
Muito alto (>15)	7,16	3,53
K (mmol_c/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (0,0 – 0,7)	108,07	53,32
Baixo (0,8 – 1,5)	74,45	36,74
Médio (1,6 – 3,0)	20,15	9,94
Alto (3,1 – 6,0)	0,00	0,00
Muito alto (>6,0)	0,00	0,00
P-resina (mg/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (0 – 10)	137,54	67,86

Baixo (11 – 25)	60,49	29,85
Médio (26 – 60)	4,64	2,29
Alto (61 – 120)	0,00	0,00
Muito alto (>120)	0,00	0,00
S (mg/dm³)		
Classe	Área (km²)	Porcentual na BHRS (%)
Muito baixo (0 – 2)	1,06	0,52
Baixo (3 – 5)	0,50	0,25
Médio (6 – 10)	6,60	3,26
Alto (11 – 15)	21,91	10,81
Muito alto (>15)	172,60	85,16

Fonte: Elaborado pelo autor (2024).

Em relação a distribuição espacial do Ca, nota-se que, em se tratando de teores para o cultivo de olerícolas, existe a presença de todas as classes na BHRS. Contudo, há de se destacar a discrepância entre as porções de muito alto e muito baixo, em que o primeiro apresenta valores dispares frente aos demais, enquanto o segundo surge em pequenas quantidades na extensão da bacia.

O DvP de $\pm 17,37$ mmol_c/dm³ indica uma considerável variabilidade na disponibilidade de Ca no solo da BHRS, indicando que, apesar da média elevada, tais concentrações podem diferir substancialmente entre as áreas da bacia hidrográfica. Logo, essa heterogeneidade requer a adoção de práticas de manejo específicas, que considerem essa variabilidade, a fim de otimizar a fertilidade agrícola e atender às necessidades das culturas.

Vale destacar que, analisados em conjunto, as frações de muito alto e alto teor correspondem a quase 70% da área total da bacia, enquanto os teores muito baixo e baixo, juntos, não apresentam 15 km². Ao se analisar as medidas de concentração, o macronutriente apresentou, em sua concentração média de distribuição espacial na área, valor classificado como de alto teor para o cultivo de hortaliças, chegando a apresentar, em alguns pontos, resultados próximos a 212% acima do intermédio.

Diante disso, vale destacar que a distribuição espacial de Ca apresentou comportamento ainda não verificado, até então, em nenhum outro dos parâmetros aqui analisados, haja vista que não há uma concentração em determinado ponto ou faixa da bacia, indiciando um possível apontamento de influência do modelo gerado.

Além do mais, é válido correlacionar essa boa distribuição com o fato de que esse macronutriente é de fundamental importância para a nutrição dos vegetais, pois participa intensamente no crescimento e desenvolvimento das plantas (MALAVOLTA, 1980).

Além do mais, Nariyanti *et al.* (2022), ao elaborarem um índice de fertilidade do solo baseado em altitude, verificou que a alta taxa de aptidão foi encontrada em terrenos com altas altimetrias (entre 1000 e 400 m) e baixo em locais acima de 1200 m, com destaque para o comportamento do parâmetro supracitado, pois, a uma altitude de 1200 a 1400 m, foi caracterizado por possuir baixo Ca trocável, enquanto a altitude entre 400 e 1000 foi moderada.

Vale destacar ainda que a movimentação do Ca no solo para as raízes se dá pelo mecanismo de fluxo de massa, e, nos casos desse macronutriente, em decorrência da sua menor mobilidade no solo, ainda existe a interceptação radicular, que desempenha papel importante para a distribuição funcional dos nutrientes nas folhas (BRADFIELD; GUTTRIDGE, 1984; TIBBITTS; PALZKILL, 1979;)

Ou seja, por mais que exista boas concentrações de Ca no solo da BHRS, ainda assim, há a necessidade de um manejo adequado para que ocorra uma maior efetividade das plantas na absorção do macronutriente (BENINI, 2003).

Na perspectiva de distribuição desse parâmetro, o Mg apresentou comportamento similar em relação à presença das classes de teor para o cultivo de olerícolas presente em toda a BHRS.

Contudo, a concentração das classes apresentou-se oposto ao cenário anteriormente apresentado, pois os altos e muito alto teores apresentaram menos de 15% da extensão territorial da bacia, enquanto as classes de muito baixo e alto teor constituem mais de 50% da BHRS. Porém, acredita-se que esse comportamento seja normal e, geralmente, aceito, haja vista que a quantidade de Ca no solo reduz a absorção de Mg.

Diante do antagonismo entre esses íons, o teor de Mg das plantas diminui a partir do excesso de Ca (YAN; HOU, 2018), porém, convém ressaltar que o coeficiente de absorção desse macronutriente é maior do que o apresentado em outros elementos, além de ser mais facilmente diluído no solo (MALAVOLTA; VITTI, 1997).

O DvP de $\pm 3,70 \text{ mmol}_c/\text{dm}^3$ indica uma variabilidade moderada nas concentrações de Mg, evidenciando que, apesar de a média parecer adequada, há áreas com disponibilidade significativamente reduzida desse nutriente. Essa situação requer atenção, especialmente em regiões onde o Ca se encontra em altas concentrações, pois isso pode limitar a eficácia da fertilização e afetar negativamente a produção agrícola. Portanto, é fundamental e

recomendando que se implemente práticas de manejo que considerem essa variabilidade para se otimizar a absorção de Mg e, consequentemente, a fertilidade do solo.

Quanto à distribuição espacial do K, houve a presença de apenas 3 classes para o cultivo de olerícolas, com destaque para o teor muito baixo, que apresentou mais de 50% da extensão territorial da bacia, seguido da baixa, com aproximadamente 36%.

Considerando as concentrações apresentadas na área, nota-se que o valor médio de $0,9 \text{ mmol}_c\text{dm}^{-3}$ não é próximo a classe de teor médio, evidenciando que a taxa de distribuição de K no solo da BHRS é considerado como baixa/muito baixa, justificando ainda o fato de que não ocorreu a presença das classes de alto e muito alto teor de K para a olericultura na BHRS.

O DvP de $\pm 0,50 \text{ mmol}_c/\text{dm}^3$ para o K sugere baixa variabilidade nos teores desse nutriente, indicando uma distribuição uniforme na bacia hidrográfica, que resulta na ausência de variações significativas que apontem deficiências ou excessos, dificultando a identificação de áreas que, de fato, necessitam de intervenções específicas. Como consequência, uma abordagem generalizada para a fertilização pode negligenciar áreas com necessidades específicas, comprometendo a produtividade agrícola.

Diante de tal situação, inicialmente, é válido destacar que as funções do K nos solos está, dentre muitas relações entre os nutrientes e minerais no solo, entre as primordiais, sendo esse destaque por meio da essencialidade do K para o crescimento das plantas (MOUHAMAD *et al.*, 2016).

Além disso, esse macro é, normalmente, o segundo nutriente mais exigido pelas culturas (FAQUIN, 1997), sendo necessário para o seu crescimento e sobrevivência (MOSTOFA *et al.*, 2022).

Nessa perspectiva, diante dos resultados dos teores baixos e médios na BHRS, é preciso salientar que a concentração de K no solo pode ser impactada pela presença de altos teores de Ca ou Mg (MOSTOFA *et al.*, 2022).

Araújo *et al.* (2012) destacam ainda que, diante dos resultados apresentados em seu estudo, os altos teores de K no solo encontrados pelos autores ocasionou na competição pelo sítio de absorção catiônica, resultando na redução dos teores de Ca e Mg.

Ainda com estudos correlatos, a fim de investigar a razão dos baixos teores de K, Faquin *et al.* (1994) verificaram, em cultura olerícola, que existe a interação iônica no processo de absorção dos nutrientes pelas raízes das plantas. Exemplificando: a presença excessiva de Ca pode reduzir a absorção de outro. Por fim, Lahav (1995) também concluíram que o K inibe a absorção de Mg e Ca.

Entretanto, ainda assim, existe a possibilidade de alguns pontos da BHRS fornecer doses adequadas de K para as olerícolas presentes na região, fato que possibilita o desenvolvimento pleno do seu potencial produtivo, sendo esse, incrementado pela aplicação balanceada, caso necessária, do nutriente.

Por fim, os resultados corroboram a definição de que na maioria dos solos tropicais a abundância natural desses nutrientes se dá na ordem decrescente: $\text{Ca} > \text{Mg} > \text{K}$, podendo haver a influência do excesso de um na absorção do outro (MOSTOFA *et al.*, 2022).

Logo, o K e o Mg absorvidos pelas raízes e acumulados na parte aérea das hortaliças, por exemplo, podem ser remobilizados para atendimento das necessidades nutricionais de tecidos mais novos, enquanto que o Ca, em oposição, deve estar mais homogeneamente distribuído pelo solo, pois sua deficiência nas proximidades das raízes pode representar restrições ao desenvolvimento radicular, uma vez que este nutriente não é redistribuído internamente na planta (RAIJ, 1981; MALAVOLTA; VITTI, 1997).

Diante das práticas de olericultura predominantes na região da BHRS, acredita-se que os resultados dos macronutrientes do solo indicam uma harmonia entre esses parâmetros, essencial para o desempenho nutricional das plantas e para a fertilidade agrícola. Além disso, os cultivos na área incluem diversas hortaliças, como alface, tomate e cenoura. Assim, a análise dos macronutrientes reflete a adequação do solo para sustentar essas práticas agrícolas na região.

Em relação ao P-resina, cenário similar ao K foi encontrado, pois apenas 3 classes de teor para olericultura, foram verificadas na extensão territorial da BHRS, com destaque para as classificações de muito baixo e baixo teor, compondo aproximadamente 97% da extensão territorial da bacia. Em oposição a isso, a classe de teor médio apresentou área de aproximadamente 4,6 km².

O DvP de $\pm 6,11 \text{ mg/dm}^3$ indica uma variabilidade considerada nos teores de P-resina no solo da BHRS, evidenciando diferenças significativas na disponibilidade desse parâmetro. Essa discrepância pode impactar as recomendações de fertilização e o planejamento das práticas agrícolas, havendo a necessidade de um manejo mais preciso para que se possa otimizar a disponibilidade desse nutriente para o cultivo de olerícolas.

Em se tratando dos teores de concentração, o valor médio do parâmetro foi de 9,84 mg/dm³, caracterizando a bacia por apresentar muito baixo teor para o cultivo de olerícolas, e, por mais que apenas três classes de teor tenham sido verificadas na BHRS, ao se analisar o comportamento desse macro, nota-se que, ainda assim, existe um hiato considerável entre o valor mínimo e máximo.

Contudo, esse resultado pode ser considerado como normal, haja vista que os solos brasileiros são carentes desse parâmetro em consequência do material de origem e da forte interação desse parâmetro com o solo (RAIJ, 1991), onde menos de 0,1 de P encontra-se em solução (FARDEAU, 1996).

Contudo, os resultados aqui apresentados são relatados pelo fato de que o P, por mais que seja um dos macronutrientes essenciais para a produção vegetal, é considerado como pouco absorvido pelas plantas, com necessidade de adubação, pois esse parâmetro possui alto grau de interação com os óxidos de Fe, por exemplo.

Dessa forma, Vilar *et al.* (2010) destacam ainda a possibilidade de adsorção – termo genérico para os processos que resultam na retenção do elemento (NOVAIS *et al.*, 2007) –, de P nesses solos pode acontecer de forma mais intensa (NOVAIS; SMYTH, 1999). Portanto, acredita-se que, diante do alto teor de disponibilidade de Fe na BHRS, essa situação pode estar ocorrendo.

De maneira oposta, a distribuição espacial do S, em relação as classes para o cultivo de olerícolas, apresentou valores majoritários entre muito alto e alto teor em mais de 95% da extensão territorial da BHRS, o que significa uma área de aproximadamente 194 km². Já as classes de muito baixo e baixo teor apresentam menos de 1% da área da bacia.

O DvP de $\pm 13,23$ mg/dm³ para o S também reflete uma variabilidade considerável nos teores desse nutriente, indicando diferenças significativas em sua disponibilidade na bacia hidrográfica. Essa heterogeneidade pode influenciar diretamente nas práticas de manejo, exigindo ajustes nas recomendações de fertilização para garantir que as áreas com concentrações variadas sejam adequadamente atendidas, otimizando assim o potencial de fertilidade do solo para o cultivo de olerícolass.

Em relação a concentração desse parâmetro, o valor médio apresentado corrobora a presença de muito alto teor de S no solo da BHRS. Contudo, é válido destacar o hiato verificado entre o valor máximo e mínimo, com destaque para o superior, que se apresentou em quase 300% acima da média apresentada pela bacia, sendo importantes pontos de monitoramento do parâmetro.

Nessa perspectiva, acredita-se que essa situação esteja relacionada ao fato de que solos com predominância de concentração de argila, como a BHRS, acrescidos da presença de Fe, diminuem a sua movimentação no perfil do solo, conforme apontado por Biswas *et al.* (2003). Dessa forma, entende-se que a alta concentração desse parâmetro na área seja responsável por acarretar nessa situação (MALAVOLTA, 1992).

6.4 Demais parâmetros químicos influentes na fertilidade agrícola

A Tabela 14 apresenta os resultados dos pontos amostrados para os demais parâmetros químicos analisados, e a Figura 13 demonstra a distribuição espacial desses na BHRS.


Tabela 14 – Valores de cada ponto amostral para os demais parâmetros químicos influentes na fertilidade agrícola.

Ponto	V%	pH	Al	H+Al	SB	CTC	MO
1	68	5,3	0	27	58	85	19
2	65	5,6	0	32	60	92	25
3	10	4,4	11	97	11	108	27
4	91	5,5	0	12	116	128	12
5	93	6,7	0	9	112	121	13
6	6	4,2	14	73	5	78	13
7	88	6,1	0	12	86	98	25
8	6	4	14	86	6	92	20
9	26	4,5	2	44	15	59	15
10	44	5	0	48	38	86	16
11	81	6,3	0	16	69	85	21
12	15	4,6	14	88	16	105	26
13	10	4,1	9	38	4	43	7
14	19	4,3	4	52	12	64	12
15	81	6	0	19	80	99	24
16	4	3,9	20	99	4	103	23
17	34	4,7	1	46	24	70	16
18	18	5,3	0	20	4	24	7
19	7	4,3	6	66	5	71	19
20	65	5,3	0	36	67	103	36
21	24	4,4	5	68	21	89	21
22	26	4,7	5	100	36	136	30
23	34	4,6	2	42	21	64	11
24	8	4,1	12	79	7	86	21
25	10	5,1	0	93	11	104	43

26	91	5,9	0	9	82	90	10
27	30	4,5	2	58	25	83	23

Fonte: Elaborado pelo autor (2024).

Figura 13 – Distribuição espacial dos demais nutrientes importantes para a fertilidade do solo.



Fonte: Elaborado pelo autor (2024).

Na Tabela 15, apresenta-se, respectivamente, a estatística descritiva da distribuição espacial desses parâmetros, e, na Tabela 16, a área e o percentual dos teores para o cultivo de olerícolas.

Tabela 15 – Distribuição espacial dos demais parâmetros influentes na fertilidade do solo do solo na BHRS.

V%				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
4,00	93,00	89,00	39,30	17,99
pH				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
3,90	6,70	2,8	4,94	0,42

Al³⁺				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
9,52	20,00	10,48	4,44	3,47
H+Al				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
9,00	100,00	91,00	51,11	18,40
SB				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
4,00	116,00	112,00	37,55	19,95
CTC				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
24,00	136,00	112,00	88,73	16,27
MO				
Valor mínimo	Valor máximo	Intervalo	Valor médio	DvP (±)
7,00	43,00	36,00	20,12	4,90

Sendo: SB, H+Al, Al, CTC,: mmolc/dm³; MO: g/dm³;

Fonte: Elaborado pelo autor (2024).

Tabela 16 – Área e percentual dos teores para cultivo de olerícolas dos parâmetros analisados.

V%		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (0- 25)	47,95	23,66
Baixo (26 – 50)	97,80	48,26
Médio (51 – 70)	44,31	21,86
Alto (71 – 90)	11,76	5,80
Muito alto (>90)	0,85	0,42
pH		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo (≤ 4,3)	9,15	4,51
Baixo (4,4 – 5,0)	113,45	55,98
Médio (5,1 – 5,5)	59,26	29,24
Alto (5,6 – 6,0)	16,70	8,24
Muito (>6,0)	4,11	2,03

Al³⁺ (mmol/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo ($\leq 0,20$)	55,67	27,47
Baixo (0,21 – 0,50)	73,20	36,12
Médio (0,51 – 1,0)	58,92	29,07
Alto (1,01 – 2,0)	14,88	7,34
Muito alto ($> 2,0$)	0,00	0,00
H+Al (mmol/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo ($\leq 1,00$)	0,13	0,06
Baixo (1,01 – 2,50)	3,88	1,91
Médio (2,51 – 5,00)	14,36	7,09
Alto (5,01 – 9,00)	91,70	45,24
Muito alto ($> 9,00$)	92,60	45,70
SB (mmol/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo ($\leq 0,60$)	2,33	1,15
Baixo (0,61 – 1,80)	26,87	13,26
Médio (1,81 – 3,60)	28,93	14,28
Alto (3,61 – 6,00)	60,52	29,86
Muito alto ($> 6,00$)	84,02	41,45
CTC (mmol/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo ($\leq 1,60$)	0,00	0,00
Baixo (1,61 – 4,30)	0,00	0,00
Médio (4,31 – 8,60)	3,42	1,69
Alto (8,61 – 15,00)	46,21	22,80
Muito alto ($> 15,00$)	153,04	75,51
MO (mmol/dm³)		
Classe	Área (km ²)	Porcentual na BHRS (%)
Muito baixo ($\leq 7,0$)	1,37	0,68
Baixo (7,1 – 20,00)	103,01	50,82

Médio (20,10 – 40,00)	96,37	47,55
Alto (40,10 – 70,00)	1,92	0,95
Muito alto (> 70)	0,00	0,00

Fonte: Elaborado pelo autor (2024).

Em relação ao V%, nota-se que a BHRS é classificada por apresentar médio-baixo teor em relação ao cultivo de olerícolas, com destaque para a classe baixa, que compõe o percentual de quase 50% da extensão territorial da bacia. Já as classes de alto e muito alto apresentaram aproximadamente 6% da área da BHRS.

O DvP de $\pm 17,99$ indica uma discrepância significativa na espacialidade desse parâmetro na BHRS, refletindo a heterogeneidade nas características do solo. Essa variação sugere que um manejo uniforme pode não ser eficaz, enfatizando a necessidade de práticas específicas adaptadas a cada área, visando maximizar a eficiência no uso de insumos e melhorar a saúde do solo, impactando no seu potencial agrícola.

Essa desigualdade também é corroborada ao se analisar as concentrações obtidas na distribuição espacial da área, em que o intervalo entre os valores máximos e mínimos é de quase 90%. Ainda assim, considerando o valor médio de distribuição (39%) é apontado como sendo de baixo teor para esse cultivo.

Contudo, diante do potencial fértil para com a atividade de olericultura encontrada na área, essa situação pode ser explicada pelo fato de que o conceito de V% está associado ao fornecimento de bases (Ca, Mg e K) em níveis ótimos para o desenvolvimento das plantas (MCLEAN, 1977; EMBRAPA, 2010), de forma a criar relações ideais para a produção máxima das culturas.

Nesse sentido, Tiecher *et al.* (2022) e Rabel *et al.* (2018) mencionam que a maior parte da agricultura tropical e subtropical da América do Sul desenvolveu-se em solos com baixos níveis de nutrientes trocáveis, sendo resultado da intensidade do intemperismo do solo.

Validando tal informação, é notório que existe uma similaridade entre os pontos da bacia em que ocorre a maior concentração de Ca e de V%, ou seja, nesses locais, em que existe a maior quantidade de cátions trocáveis, ocorre os maiores valores de V%. Essa situação é similar, também, aos teores de alto e muito alto Mg.

Nesse viés, é válido destacar aqui o comportamento do pH na BHRS, haja vista que esse parâmetro, nos solos, relaciona-se com o grau de V%, aumentando à medida que o outro aumenta (RAIJ *et al.*, 1968; KABAŁA; LABAZ, 2018). Nessa perspectiva, em se tratando dos teores de classe para o plantio de olericultura, as porcentagens de teor alto e muito alto foram

mínimas frente às classes de muito baixo e baixo teor, enquanto o DvP de $\pm 0,42$ do aponta para uma variação relativamente pequena nos valores ao longo da bacia hidrográfica.

Em vista da extensão territorial, o solo da BHRS é composto por mais de 120 km² das classes majoritárias, enquanto as minoritárias estão presentes em aproximadamente 20 km² de toda a área. Nesse hiato, encontra-se os teores médios, compondo aproximadamente 30% da bacia.

Em relação aos valores apresentados, o pH apresentou valor médio de aproximadamente 5. Ressalta-se que o comportamento das classes acima supracitadas foram correlatas, conforme destacado pelo Boletim 100 do IAC, que aponta que esses parâmetros apresentam estreita correlação entre si. Dessa forma, é válido frisar a faixa em que ocorre, na BHRS, os maiores teores de Ca, o que acarreta variações de V% e, conseqüentemente, no pH do solo naquela região (EMBRAPA, 2010).

Nessa vertente, o pH do solo é considerado como um indicador da condição fértil do solo, pois afeta suas reações e seus processos químicos (SPARKS, 2003). Contudo, não pode ser utilizado para prever ou estimar a disponibilidade de nutrientes para as plantas, haja vista que essas respondem e se interagem de forma diferente (MAREK; RICHARDSON, 2020).

Ademais, o pH do solo pode influenciar na solubilidade, forma iônica e na mobilidade de alguns nutrientes, afetando assim, e de forma conseqüente, a sua disponibilidade, e o pH ideal para o crescimento das plantas depende de qual nutriente é o mais limitante do local (BARROW, 2017).

É importante destacar que a homogeneidade no pH, apresentada em seu DvP, exige uma análise aprofundada, especialmente considerando que as classes de teor alto e muito alto são mínimas em comparação às de muito baixo e baixo teor. A relação entre pH e V% reforça a necessidade de um manejo adequado, pois níveis subótimos de pH podem comprometer a disponibilidade de nutrientes essenciais para a olericultura. Portanto, uma gestão minuciosa desse parâmetro é recomendada na BHRS, a fim de se garantir a fertilidade agrícola.

Nessa perspectiva, em relação a concentração de Al^{3+} no BHRS, nota-se que as maiores concentrações estão entre as classes de teor muito baixo e médio, com predominância de mais de 92% da extensão territorial no local, com destaque para a classe baixa, que apresentou mais de 1/3 dessa área, aproximadamente.

Em oposição a isso, as classes de alto e muito alto teor apresentaram menos de 15 km² do total da área, com destaque para uma pequena concentração ao sul e ao leste da bacia, onde se encontra os valores de pH mais baixos. Em se tratando de concentração desse parâmetro, o

valor máximo encontrado na BHRS foi de 20,00 mmol_c/dm³, enquanto a média foi de 4,44, corroborando ao fato da supremacia da classe baixa na região.

Nessa perspectiva, há de se destacar que a presença de Al³⁺ no solo possui as suas cargas dependentes do teor do pH, pois, com esse parâmetro baixo, o hidrogênio atua nos minerais, liberando íons de Al, que ficam retidos nas cargas negativas do solo. Dessa forma, entende-se que, à medida que o solo fica mais ácido, aumenta-se a quantidade de Al³⁺ em solução no solo (BOHEM, 1995).

Sendo assim, e diante da concentração espacial de Al³⁺ na BHRS, Foy (1974) ressalta que, apesar desse parâmetro, quando verificado em excesso, ocasionar em danos à fertilidade agrícola, o elemento pode ocasionar benefícios quando verificados em baixas concentrações, como na BHRS, estimulando o desenvolvimento de algumas espécies.

O DvP de $\pm 3,47$ mmol_c/dm³ evidencia uma distribuição moderada nas concentrações do parâmetro ao longo da bacia hidrográfica, o que é importante para avaliar a toxicidade potencial desse nutriente no solo da BHRS, principalmente nos locais que apresentam os teores mais altos, indicando a necessidade de correções para garantir um ambiente favorável ao cultivo de olerícolas.

Nesse sentido, é válido mencionar o comportamento espacial do H+Al na BHRS, pois o Al é considerado como um dos componentes mais importantes que impactam nesse parâmetro (BOHEN, 1995), que apresentou, de forma majoritária, a predominância de alto e muito alto teor.

Analizados conjuntamente, essas concentrações representam mais de 90% da extensão territorial da bacia, ao passo que as classes de muito baixo e baixo teor não retratam 2% da área, com concentrações em aproximadamente 4km² da bacia.

Portanto, há de se destacar ainda o hiato existente entre o valor máximo e mínimo da sua distribuição espacial, apresentando um intervalo de 91 mmol_c/dm³. Por fim, ao se considerar o seu valor médio (51,11 mmol_c/dm³), nota-se que existe a predominância da classe alta desse parâmetro na BHRS.

De maneira geral, os resultados apontam para uma necessidade de correção do solo na BHRS, uma vez que o H+Al se relaciona com o cálculo da dose de calcário necessária para que ocorra a neutralização da acidez do solo (NOLLA; ANGHINONI, 2004), pois, para se corrigir tal acidez, deve-se utilizar um elemento que libere ânion e que forme um ácido fraco com esse H (EMBRAPA, 2010).

Diante da variabilidade observada pelo DvP ($\pm 18,40$ mmol_c/dm³), é fundamental que se implemente práticas de manejo adequadas no solo da BHRS, que inclui a correção da acidez

por meio da calagem, neutralizando os níveis elevados de H^+Al . Ademais, acredita-se que essa abordagem não só melhorará a saúde do solo, mas também aumentará a disponibilidade de nutrientes essenciais para o crescimento das culturas.

Diante do exposto, é importante destacar que a correção em solos tropicais deve influir sobre os teores de concentração do SB, de forma a elevar a disponibilidade dos nutrientes e aumentar as trocas para com as plantas (EMBRAPA, 2010), pois esse parâmetro indica o número de cargas negativas dos colóides do solo que está ocupado pelos básicos trocáveis.

Portanto, analisando a disponibilidade espacial desse parâmetro na BHRS, nota-se que, por mais que ocorra a presença de todas as classes para a análise da fertilidade do solo, existe a predominância do alto e muito alto teor dessa medida, representando mais de 70% da extensão territorial da bacia.

O DvP do SB de $\pm 19,95 \text{ mmol}_c/\text{dm}^3$ revela variações significativas na concentração de bases trocáveis ao longo da bacia hidrográfica, indicando que algumas áreas podem apresentar quantidade insuficiente de nutrientes essenciais. Além do mais, essa variação acentua a importância de uma avaliação correta dessas regiões para determinar as intervenções necessárias para potencializar a fertilidade do solo.

As classes de baixo e muito baixo teor de SB representam menos de 30 km^2 da área. B. Ainda assim, é válido ressaltar o hiato entre o valor máximo e mínimo, o que corresponde a $112 \text{ mmol}_c/\text{dm}^3$. Além disso, o valor superior apresentou-se ser mais de 200% acima da média encontrada na BHRS, representando a discrepância de concentração entre as classes de baixo e alto teor desse parâmetro, fato que pode acarretar diretamente no tipo de manejo e nas proporções de correção.

Vale destacar ainda que o SB possui a capacidade de indicar o número de cargas negativas dos colóides do solo que estão ocupadas pelos cátions básicos trocáveis, de forma que, se o parâmetro é considerado como baixo, aponta-se para uma reduzida concentração de K, Ca e Mg na área, e, quando é alto, apresenta-se para uma alta concentração desses parâmetros trocáveis no solo (SILVA; LIMA, 2004).

Já em relação ao CTC do solo da BHRS, notou-se a presença apenas das classes de médio a muito alto teor, com destaque para a última classe, que, de forma predominante, apresentou um percentual de mais de 75% da área. Somada a classe de alto teor, tem-se aproximadamente 200 km^2 da bacia. Além disso, há de se destacar o valor médio de $88,73 \text{ cmol}_c/\text{dm}^3$, fato que indica a predominância da classe de muito bom teor dessa medida no solo da BHRS.

Contudo, é preciso ressaltar que, diante do potencial de acidez elevada da BHRS, fato que prejudica a disponibilidade dos nutrientes, devido à, principalmente, baixo V% e elevado H+Al, acredita-se que as altas concentrações de CTC possam estar relacionados entre a predominância de Ca e a presença de H+Al, conforme abordado por Malavolta (2006), pois há indícios de que o V% baixo aponta para pequenas quantidades de cátions trocáveis, e que a maioria dos coloides está sendo neutralizadas por H+Al (EMBRAPA, 2010).

Por mais que a BHRS tenha apresentado maiores valores de argila no solo, em alguns pontos ocorre altas concentrações de areia, fato que influencia nos valores de CTC, haja vista a possibilidade de lixiviação de cátions, o que influencia diretamente na disponibilidade dos nutrientes (LOPES, 1998).

Portanto, o DvP da CTC de $\pm 16,27$ mmolc/dm³ indica variações significativas nas concentrações desse parâmetro na BHRS. A ausência de classes de muito baixo e baixo teor sugere diferenças na capacidade de troca de cátions, influenciadas por fatores como a presença de Ca, H+Al e a lixiviação em áreas arenosas. Essas discrepâncias são cruciais para o desenvolvimento de estratégias de manejo adequadas, visando otimizar a fertilidade e a saúde do solo.

Nessa perspectiva, é possível verificar, por meio dos valores de MO do solo da BHRS que, em relação as suas classes de teor de fertilidade, existe a predominância de baixo e médio valor desse parâmetro, com leve discrepância (3%) do menor teor para o médio. Contudo, analisados conjuntamente, esses parâmetros estão presentes em aproximadamente 98% da extensão territorial da bacia.

Contrapondo-se a isso, as concentrações das classes de muito baixo e alto teor foram, praticamente, irrisórias frente às predominantes. Essa situação se estende para a classe alta de MO, em que não houve a presença desse teor. O DvP da MO de $\pm 4,90$ g/dm³ sugere que, embora haja variação moderada nas concentrações desse parâmetro ao longo da BHRS, a predominância de classes de baixo e médio teor pode limitar a fertilidade do solo. Portanto, um manejo voltado para a melhoria dos teores de MO é fundamental para garantir a eficiência na produção agrícola de olericultura na bacia hidrográfica.

Em vista do valor médio espacial da BHRS, a concentração de 20,12 g/dm³ apresenta-se no limite de separação entre o baixo e médio teor, corroborando a notória presença dessas classes na bacia. Porém, acredita-se que essa situação seja normal, pois, juntamente com o P e K, a MO é considerada como um dos parâmetros mais limitantes da produção de culturas no Brasil (CHIODINI, 2013).

Entretanto, para que o solo possa suprir todas as suas necessidades nutricionais de suas respectivas culturas, necessita-se não somente apresentar teores adequados desses parâmetros, mas possuir condições ideais que possam absorvê-las, sendo que Prado (2008) ressalta que, diante desses, a MO é o mais importante.


Vale destacar que a MO, por ser um indicador de qualidade do solo e uma fonte de carbono, possui propriedades coloidais com alta reatividade, fato que evita a lixiviação de cátions como Ca, Mg e K, além de realizar o controle térmico e melhorar a retenção de água no solo. Ademais, assim como as argilas, a MO contribui diretamente para a CTC do solo (FAGEA, 1989; BRADY; WEIL, 2009).

Portanto, acredita-se que as concentrações dessa medida apresentados na BHRS possam estar sendo úteis para a fertilidade de olericulturas, mas que, diante da predominância de médio e baixo teor, necessitam de adubação, fato que poderá interferir na disponibilidade de parâmetros como o K e P, influenciando em parâmetros como a CTC e V%, conforme destacado pela Embrapa (2004).

6.5 Modelagem da aptidão agrícola da BHRS com base no algoritmo RF

O resultado da PCA, apresentado na Figura 14, revela a distribuição dos parâmetros físico-químicos em relação às diferentes classes de textura do solo encontrados na bacia hidrográfica.

Figura 14 – PCA dos parâmetros físico-químicos entre as classes de textura do solo na BHRS.



Fonte: Elaborado pelo autor (2024).

O gráfico com a PCA revela que o Primeiro Componente Principal (PC1) explica aproximadamente 43% da variabilidade dos dados, enquanto o Segundo Componente Principal (PC2) contribui com cerca de 18% desses. Conjuntamente, ambos os componentes capturam cerca de 61% da variabilidade total dos parâmetros físico-químicos do solo da BHRS, permitindo uma representação simplificada das diferenças mais relevantes entre os diversos tipos de estrutura do solo na área de estudo.

No PC1, é relevante destacar a espacialização dos vetores de pH, SB, Ca e Mg, que possuem alta magnitude e estão orientados na mesma direção, sugerindo uma correlação positiva significativa entre esses parâmetros, os quais podem estar relacionados à base de saturação do solo, embora não seja possível inferir diretamente sua influência na fertilidade agrícola.

Em oposição a esses, o vetor do HAI orienta-se no sentido oposto, indicando uma relação inversa, ou seja, à medida que os níveis de cátions (SB, Ca, Mg) aumentam, o HAI tende a diminuir, refletindo as dinâmicas de correção da acidez do solo.


Esses resultados são corroborados por Bailey *et al.* (2021), que demonstram que a recuperação dos cátions de base, como o Ca e Mg, após a redução da deposição ácida, está diretamente relacionada à diminuição dos níveis de HAl. Portanto, essa relação evidencia a importância do equilíbrio entre esse parâmetro e os cátions de base para a manutenção da fertilidade agrícola e o potencial produtivo do solo.

Em vista do P-resina, embora não tão influente quanto pH e SB, também possui um vetor considerável no PC1, indicando uma contribuição relevante para a variabilidade dos dados. Estudos, como Zheng *et al.* (2003), indicam a maior retenção de P em solos argilosos, fato evidenciado na PCA, especialmente quando considerado o papel da MO, que também contribui moderadamente, sendo mais influente no PC2.

A relação entre MO e P-resina reforça o papel do primeiro parâmetro na estabilização de nutrientes e na retenção de P, especialmente em solos argilosos, como destacado por Oades (1988).


Convém destacar que a disposição vetorial dos parâmetros, de forma geral, demonstra que há uma complexidade nas interações físico-químicas do solo na BHRS, o que exige uma análise de contraste mais detalhada, conforme a Figura 15, Figura 16 e Figura 17, a fim de se refinar a identificação dos parâmetros mais influentes nas diferentes classes texturais de solo, pois neste estudo, a PCA fornece apenas uma visão descritiva das variáveis analisadas, não permitindo inferências causais ou relações diretas entre os parâmetros.

Figura 15 – Resultados estatísticos para a escolha dos parâmetros na modelagem final: micronutrientes.




Fonte: Elaborado pelo autor (2024).

Figura 16 – Resultados estatísticos para a escolha dos parâmetros na modelagem final: macronutrientes.



Fonte: Elaborado pelo autor (2024).

Figura 17 – Resultados estatísticos para a escolha dos parâmetros na modelagem final: demais parâmetros influentes na fertilidade agrícola.



Fonte: Elaborado pelo autor (2024).


Os resultados demonstram que a variação nos parâmetros de CTC, Mg, S e V% entre as classes de textura do solo na BHRS está associada ao potencial do solo para reter nutrientes. Nesse contexto, os locais com maior teor de argila apresentam uma CTC superior, o que aumenta a disponibilidade de nutrientes, como o Mg, favorecendo, assim, os cultivos em solos mais argilosos (NUNES *et al.*, 2023; FERREIRA *et al.*, 2023; BARBOSA *et al.*, 2023).

Além disso, áreas com maior teor de argila também retêm melhor o S e possuem maior V%, enquanto os locais com alta concentração de areia, e, consequentemente, com menor CTC, apresentam baixa capacidade de retenção de Ca e K, reduzindo sua aptidão para cultivos como a olericultura (DAVI *et al.*, 2022; YANG *et al.*, 2024).

Esses resultados evidenciam as variações na aptidão agrícola entre os tipos de textura solo na BHRS, ressaltando a necessidade de um manejo adequado para se maximizar a produtividade em solos arenosos, conforme preconizado pela AP. Além disso, é crucial otimizar o potencial agrícola dos solos argilosos, que apresentam maior capacidade de retenção de nutrientes (CARNEIRO *et al.*, 2024; FERREIRA *et al.*, 2023; BARBOSA *et al.*, 2023).

Nessa perspectiva, a Figura 18 complementa esses resultados, apresentando as classes de aptidão agrícola em relação à distância dos corpos hídricos e à declividade.

Figura 18 – Classes de aptidão agrícola em função da distância das áreas em relação aos corpos hídricos (a) e do nível de declividade (b).



Fonte: Elaborado pelo autor (2024).

Na Tabela 17, apresenta-se a área e o percentual das segmentações das classes de declividade e distância dos corpos hídricos em relação à aptidão agrícola.

Tabela 17 – Área e porcentagem das classes de declividade e distância dos corpos hídricos relacionadas à aptidão agrícola.

Declividade		
Classe	Área (km ²)	Porcentual na BHRS (%)
Mais apta	25,90	12,78
Medianamente apta	15,20	7,50
Menos apta	161,57	79,72
Distância dos corpos hídricos		
Classe	Área (km ²)	Porcentual na BHRS (%)
Mais apta	105,70	52,15
Medianamente apta	76,37	37,69

Menos apta	20,60	10,16
------------	-------	-------

Fonte: Elaborado pelo autor (2024).

Os resultados da análise de declividade e da distância das áreas em relação aos recursos hídricos evidenciam que os locais com menor aptidão para o cultivo, no que tange à inclinação do terreno, representam 79,72% da BHRS, enquanto os mais aptos compõem 12,78%. Já em termos de proximidade com os corpos d'água, 52,15% da extensão territorial da bacia hidrográfica é considerada como mais favorável ao cultivo agrícola.

Essa relação destaca a importância da disponibilidade de água para a olericultura, que demanda de elevada disponibilidade hídrica e também de solos com boas condições de retenção. Nessa perspectiva, Parkash; Singh (2020), ao discutirem indicadores de estresse hídrico em cultivos vegetais, corroboram essa necessidade, ressaltando que a gestão adequada dos recursos hídricos é essencial para se garantir a fertilidade agrícola e a sustentabilidade ambiental.

Diante dessa importância, a avaliação precisa da aptidão agrícola torna-se fundamental para se otimizar o uso dos recursos naturais. Nesse sentido, a integração de métodos tradicionais, como a Análise Hierárquica de Processos (AHP), com o uso de algoritmos de ML, como o RF, é crescente. Agrawal *et al.* (2024) demonstram que essa abordagem permite incorporar variáveis topográficas e edáficas, facilitando uma predição eficiente da adequação das áreas para diferentes tipos de cultivos, proporcionando subsídio para a tomada de decisões agrícolas.

Neste ponto, convém destacar o papel do manejo conservacionista na otimização da aptidão agrícola, especialmente em áreas que, assim como na BHRS, à primeira vista, poderiam ser classificadas como menos aptas ao cultivo agrícola, mas que possuem grande potencial fértil, alavancados pelas características físico-químicas do seu solo.

Sathiyamurthi *et al.* (2024) apontam, nesse sentido, que a aplicação de práticas adequadas, com destaque para a correção do pH, controle da erosão do solo e a adição de MO, bem como o uso de corretivos, podem transformar significativamente tais limitações.

Já Mucida *et al.* (2022) reforçam que, além das práticas de manejo conservacionistas, a avaliação do potencial de uso do solo pode identificar áreas com aptidão subestimada para o cultivo agrícola, permitindo um planejamento mais eficaz da área. Essa abordagem integrada pode maximizar a produtividade agrícola e promover a conservação dos recursos naturais, alinhando-se à necessidade de práticas sustentáveis em regiões como a BHRS.


Nessa perspectiva, a AP, com o suporte do SR, das técnicas de geoprocessamento e das modelagens implementadas pela IA, tem permitido uma análise mais detalhada do solo e

do terreno, de forma a garantir que o manejo agrícola seja específico para cada parcela de uso, e não considerando a área agrícola como um local homogêneo, identificando locais que necessitam de maior tratamento, seja esse para correção do solo, controle de erosão ou maior irrigação (HOSSEINI *et al.*, 2024).

Assim, essa abordagem otimiza a utilização de insumos e maximiza a produtividade agrícola, promovendo um uso sustentável e eficiente dos recursos naturais. Além disso, permite o manejo de áreas previamente consideradas menos favoráveis, como as com alto grau de inclinação na BHRS, por exemplo, visando alcançar seu potencial máximo de fertilidade, conforme evidenciado por Shah e Wu (2019).

Nessa perspectiva, a Figura 19 apresenta os locais mais e menos aptos para o cultivo de olerícolas na BHRS, com base nos parâmetros físicos-químicos do solo, da declividade do terreno e da distância das áreas em relação aos corpos hídricos, utilizando o algoritmo RF.

Figura 19 – Classificação da aptidão agrícola na BHRS com base no algoritmo RF.



Fonte: Elaborado pelo autor (2024).

A Tabela 18 apresenta a área e extensão das classes de aptidão agrícola na BHRS, enquanto a Figura 20 demonstra a importância das variáveis para a geração do modelo de


aptidão agrícola. A Tabela 19 apresenta a estatística das classes de aptidão agrícola na BHRS, com a Figura 21 exibindo o erro OOB em relação ao número de árvores no treinamento do modelo.

Tabela 18 – Distribuição espacial das classes de aptidão agrícola na BHRS.

Classe	Área (km ²)	Porcentual na BHRS (%)
Menos apto para o cultivo	57,20	28,22
Medianamente apta	31,97	15,78
Mais apto para o cultivo	113,50	56,00

Fonte: Elaborado pelo autor (2024).

Figura 20 – Importância das variáveis para a geração do modelo de aptidão agrícola.



Sendo hidrografia a representação da distância euclidiana entre os corpos hídricos na BHRS.

Fonte: Elaborado pelo autor (2024).


Tabela 19 – Estatística das classes de aptidão agrícola na BHRS.

Estatística	Classe		
	Menos apta	Medianamente apta	Mais apta
Sensitivity	0,94	1,00	1,00
Specificity	0,85	0,90	0,95

Pos. Pred. Value	0,83	1,00	1,00
Neg. Pred. Value	0,90	0,95	0,90
Balanced Accuracy	0,88	0,96	0,96

Fonte: Elaborado pelo autor (2024).

Figura 21 – Erro OOB em função do número de árvores no treinamento do modelo.



Fonte: Elaborado pelo autor (2024).

Do total de 390 amostras coletadas, 273 foram alocadas para o treinamento do modelo. Dentre essas, 109 foram categorizadas como menos aptas, 56 na classe intermediária e 108 como mais aptas, resultando em um erro total de 0,05 na classe menos apta.

A distribuição das amostras nos estratos foi proporcional, com 198 amostras provenientes do classe de textura do solo A, 111 do AAr, 18 do FAAr e 59 do MA. Assim, cada um dos 10 parâmetros utilizados foi proporcionalmente amostrado entre as diferentes classes, assegurando uma representação adequada das características de cada tipo de estrutura do solo no modelo.

Durante a validação do modelo, observou-se um desempenho ideal, com zero erros na classificação das classes intermediária e mais apta, indicando uma detecção eficaz da aptidão agrícola diante das diversas características físico-químicas e morfológicas da BHRS.

Contudo, a classe "menos apta" apresentou 6 classificações incorretas, o que sugere que a complexidade das interações nas variáveis ou a variabilidade do solo possa ter

influenciado essa classificação. Esse desempenho pode ser atribuído à capacidade do modelo RF em capturar interações complexas entre as variáveis consideradas, conforme abordado por Liu *et al.* (2022).

A declividade emergiu como a variável mais influente nas decisões do algoritmo para a geração do modelo final, o que, de fato, reflete sua importância em contextos agrícolas, haja vista que a inclinação do terreno tem implicações diretas na produtividade das culturas e na sustentabilidade agrícola e ambiental, uma vez que um solo em declive tende a aumentar a perda de nutrientes e comprometer a capacidade produtiva daquele local em casos de manejo inadequado (AHMED *et al.*, 2016).

Sabljić *et al.* (2024) destacam que a inclinação do terreno tem um impacto significativo na drenagem e na erosão do solo, fatores que afetam diretamente a fertilidade e a eficácia das práticas agrícolas. Terrenos planos são vantajosos, pois facilitam a mecanização e a irrigação, otimizando o cultivo. Em oposição a isso, áreas com alta declividade, quando submetidas a práticas não conservacionistas, tornam-se suscetíveis à erosão e à diminuição da capacidade de retenção de água, comprometendo a produtividade agrícola.

Nesse sentido, em vista do fato de que essas tendências podem ser mitigadas por meio de práticas de conservação ambiental, especialmente com o uso de áreas verdes, que auxiliam na redução do arraste de partículas do solo e contribuem para que as atividades agrícolas sejam realizadas de maneira sustentável, vale destacar que na BHRS existe uma predominância de áreas com baixo potencial de perda de solo, correspondendo a aproximadamente 85% da extensão territorial. Já as áreas de potencial médio representam 14,7%, enquanto as de alto potencial somam apenas 0,3% (ARANTES, 2023).

Esses dados, além de corroborar os resultados obtidos neste estudo, indicam que a declividade exerce uma influência limitada no arraste de partículas do solo nessa área, sugerindo que, apesar da presença de declives acentuados, as práticas de conservação implementadas na região são eficazes. Assim, acredita-se que a sustentabilidade agrícola na BHRS ocorre de forma garantida por grande parte de sua extensão territorial, principalmente diante das estratégias conservacionistas adotadas.

Esse cenário é evidenciado em alguns pontos da bacia hidrográfica, como demonstrado na Figura 22, nas proximidades do Ponto de coleta nº 16. Nessa área de alto declive, o cultivo de olerícolas, cercado por floresta, corrobora ao fato de que a cobertura vegetal atenua os efeitos negativos da inclinação do terreno, permitindo o desenvolvimento adequado desse tipo de cultivo.

Figura 22 - Cultivo de olerícolas cercado por vegetação em área de declive acentuado.



Fonte: Elaborado pelo autor (2024).

A distância dos corpos hídricos também foi um parâmetro crucial nas decisões do algoritmo, o que corrobora a realidade de que a água é essencial para a irrigação e disponibilidade hídrica de diferentes culturas. Desta (2024) ressalta que a adequação da terra para a agricultura irrigável está intimamente relacionada à acessibilidade a fontes hídricas, evidenciando a importância da gestão hídrica na maximização do potencial agrícola.

Em um contexto global, embora a irrigação possa ser a melhor opção para muitas regiões, a dependência de sistemas pluviais ainda é predominante. Logo, essa dinâmica sublinha a necessidade de estratégias de desenvolvimento que considerem a relação entre a topografia, a disponibilidade hídrica e as práticas agrícolas, otimizando, assim, a produção alimentar (DESTA, 2024).

Em vista disso, considerando em escala micro (BHRS), estratégias para a implementação de técnicas de conservação de solo, como o terraceamento e plantio em contorno, que minimizam a erosão; o uso de sistemas de irrigação eficiente, como a irrigação por gotejamento, que maximiza a utilização racional da água; e a adoção de cultivos de

cobertura para aumentar a retenção hídrica e a fertilidade do solo, conforme abordado por Naganjali *et al.* (2024) e Kumar (2024), devem ser, além de implementados, otimizados.

Portanto, diante dos resultados, a proximidade a corpos hídricos, combinada com práticas de manejo adequadas em áreas com declives acentuados, pode potencializar a eficiência agrícola e a sustentabilidade da produção na BHRS.

Esse cenário foi observado *in loco*, próximo ao Ponto de Coleta 5 (Figura 23), onde o cultivo de olerícolas ocorre em terreno com alto grau de declividade e nas proximidades de recursos hídricos, propícios para a irrigação, evidenciando a influência positiva da disponibilidade hídrica e do manejo adequado em áreas com desafios topográficos.

Figura 23 – Cultivo de olerícolas com sistema de irrigação em área de declive acentuado, próximo ao corpo hídrico.



Fonte: Elaborado pelo autor (2024).

Em vista da importância dos parâmetros para com a geração do modelo, convém destacar que os teores de Mg, Cu e Zn também foram identificados como relevantes para as decisões do algoritmo, refletindo e corroborando à necessidade de um solo com teores equilibrados desses parâmetros para garantir a aptidão agrícola.

Holb; Nagy (2009) observaram que a disponibilidade desses nutrientes em sistemas de cultivo influencia diretamente a saúde das plantas e, consequentemente, seu potencial de produtividade. Os autores ressaltam ainda que o aumento contínuo de Mg e a dinâmica sazonal dos micronutrientes, como Cu e Zn, evidenciam que a adequação desses elementos no solo é crucial para se maximizar o rendimento agrícola.

Em oposição a isso, o P-resina e a CTC demonstraram baixa relevância para a geração do modelo de aptidão agrícola na BHRS, possivelmente devido a distribuição espacial das classes de teor desses parâmetros para a olericultura e à dinâmica e importância de fatores mais influentes, como a declividade e a distância dos corpos hídricos.

Vale destacar que a predominância de teores muito baixos de P-resina sugere uma limitação na disponibilidade desse parâmetro na BHRS. No entanto, acredita-se que a eficiência do uso desse nutriente pode ser compensada por práticas de manejo adequadas e pela presença de outros nutrientes essenciais no solo.

Quanto à CTC, é válido destacar que a sua presença em níveis elevados não garante necessariamente a aptidão agrícola, uma vez que sua eficácia depende da interação com outros parâmetros, como a fertilidade do solo e as condições hídricas. Dessa forma, a sua baixa relevância para a geração do modelo pode ser atribuída, assim como o P-resina, à predominância de fatores que impactam diretamente a produtividade agrícola na BHRS.

Em relação ao desempenho do modelo, com acurácia geral de 0,93 e kappa de 0,96, a análise das inconsistências indicou pequenos desafios na distinção entre áreas de aptidão medianamente apta e menos apta. A classe de menor aptidão apresentou uma SSV de 0,94, indicando que, apesar de um pequeno erro de classificação, o modelo foi eficaz na detecção das áreas menos aptas. Em oposição, as classes medianamente apta e mais apta não registraram erros durante o treinamento, apresentando uma SSV de 1,00.

Isso sugere que, embora o modelo tenha apresentado ótimo desempenho na classificação geral, pode existir dificuldades relacionadas à similaridade das características do solo nas classes intermediárias, principalmente quando aplicado em outros locais, com características morfológicas e físico-químicas distintas, pois o erro OOB de 0,187 reflete a possibilidade de superajuste. Diante disso, recomenda-se que estudos futuros possam incluir aprimoramentos adicionais, tais como a otimização dos hiperparâmetros do modelo e a utilização de técnicas de validação cruzada.

As estatísticas de desempenho demonstram variações na SSV e no PPV entre as classes. A de maior aptidão apresentou a maior SSV (1,00), enquanto a medianamente apta teve uma SSV de 1,00, refletindo um desempenho ideal na classificação.

Em oposição, a classe menos apta apresentou uma SSV de 0,94, indicando uma pequena dificuldade na detecção correta dessa categoria. Essas diferenças refletem a homogeneidade das condições favoráveis na classe mais apta para o cultivo, em que as características do solo e o manejo são mais adequados para a produção agrícola. Por outro lado,

a classe de aptidão medianamente apta inclui uma maior diversidade de fatores que influenciam a produtividade agrícola, resultando em desafios para a correta identificação dessas áreas.

Vale ressaltar que essa variação destaca a complexidade das interações ambientais e a necessidade de uma análise mais aprofundada das características do solo e da dinâmica hídrica na BHRS, haja vista que o equilíbrio na distribuição de erros e o desempenho geral do modelo enfatizam a importância de abordagens integradas que combinem modelagem estatística com conhecimento agronômico, territorial e ambiental.

O gráfico do erro OOB em função do número de árvores revela que, a partir de 80 árvores, os erros se estabilizam, indicando que o aumento do número de árvores além desse ponto não resulta em melhorias significativas no desempenho do modelo. Tal fato sugere que o algoritmo RF alcançou um ponto de saturação, onde o conjunto de decisões já é capaz de capturar adequadamente os padrões nas classes de aptidão agrícola.

A variação dos erros entre as classes também reflete a complexidade na separação dessas categorias. Assim, para estudos futuros, recomenda-se a utilização de 100 árvores, considerando a variabilidade e espacialidade dos parâmetros físico-químicos em diferentes biomas, bem como as variações ambientais que ocorrem de área para área. A adoção dessa quantidade de árvores pode proporcionar resultados eficazes e que possam subsidiar a gestão territorial agrícola e ambiental.

Todavia, os resultados aqui apresentados não apenas evidenciam a eficácia do modelo na identificação da aptidão agrícola da BHRS, mas também ressaltam a importância das práticas de conservação implementadas na região. Isso é corroborado por Arantes *et al.* (2023), que desenvolveram um índice de potencial de degradação ambiental para a área e os resultados indicam que a maioria das sub-bacias da BHRS apresenta uma classificação de baixo a médio potencial de degradação, enfatizando a eficácia das medidas de conservação adotadas.

O entendimento dessas interações é crucial para o desenvolvimento de estratégias que aumentem a produtividade agrícola, minimizando os impactos ambientais negativos e promovendo práticas agrícolas sustentáveis, assim como apontado por Chiaka *et al.* (2024) ao verificarem a adequação das terras à aptidão agrícola, sugerindo que a elaboração de mapas de adequação pode ser uma estratégia eficaz para o desenvolvimento de programas de segurança alimentar.

Nesse contexto, os resultados obtidos neste estudo reforçam a importância de se compreender as interações entre as variáveis ambientais, as práticas de manejo do solo e as características morfológicas do local, pois esses, a partir de uma modelagem, geram resultados que, assim como esses, podem ser utilizados para a formulação de políticas públicas voltadas à

gestão territorial, agrícola e ambiental, visando a otimização do uso da terra, a implementação de sistemas de irrigação mais eficientes e a mitigação de impactos ambientais negativos.

Além disso, os dados aqui apresentados fornecem subsídios essenciais para o planejamento de programas de segurança alimentar, tanto em escalas locais quanto regionais, integrando a gestão agrícola e a sustentabilidade ambiental.

7 CONCLUSÃO

Diante dos resultados apresentados foi possível concluir que na BHRS ocorre uma discrepância em relação às classes granulométricas, com locais apresentando a predominância de um componente físico e baixo teor de outro (argila e areia), sendo intermediários com as partículas de silte.

Analizados com o fator topográfico, há indícios de que ocorre no local uma gestão de uso da terra sustentável e com práticas conservacionistas efetivas. Contudo, não é obstante que órgãos fiscalizadores e de monitoramento ambiental e agrícola exijam a criação de áreas verdes em pontos estratégicos, principalmente nos locais com predominância das partículas mais finas.

O algoritmo RF mostrou-se eficiente para geração das classes de textura do solo da BHRS, com erros mínimos e boa discrepância entre essas categorias, sendo o resultado correlato à distribuição espacial dos pixels amostrados no diagrama de textura do solo.

Os resultados apresentados neste trabalho permitem concluir que, tratando-se de fertilidade agrícola, a BHRS é caracterizada por possuir médio-baixo pH, fato que acarreta diretamente na concentração e disponibilidade de nutrientes para as plantas. Sob tal perspectiva, os micronutrientes apresentaram boa distribuição espacial pela bacia hidrográfica, principalmente o Mn e o Cu, seguidos do Zn.

De maneira oposta, o B e o Fe foram caracterizados por apresentar uma predominância das classes de baixo e alto teor, respectivamente. Entretanto, o cenário é condizente ao pH da BHRS e das concentrações granulométricas da área, havendo a necessidade de correção do solo em alguns pontos específicos.

Em relação aos macronutrientes, pode-se concluir que há a necessidade de se monitorar alguns parâmetros com maior intensidade, com destaque para o P-resina e o K, essenciais para as aptidões agrícolas do solo e que não apresentaram teor de alto e muito alto de fertilidade.

Já o Ca, S e Mg, estão mais distribuídos pela bacia hidrográfica, com destaque para as altas concentrações do primeiro e do último parâmetros, que foram caracterizados por apresentar muito alto teor fértil para esses macros.

Em vista dos demais parâmetros analisados que influenciam na aptidão agrícola do solo, notou-se que esse possui grandes áreas de baixo teor fértil por meio da concentração de V%, correlatas aos teores de baixo pH e altas concentrações de H+Al. O Al caracterizou-se por apresentar valores de médio-baixo no solo, e o SB, apesar de ter apresentado boa concentração

espacial desses parâmetros, foi caracterizado pelas classes de alto e muito alto teor, o que pode estar correlato às concentrações de Ca.

Em relação às concentrações de CTC e de MO, enquanto a primeira caracterizou-se por apresentar classes de alto e muito alto teor, a segunda foi definida pelos teores de médio e baixo nível, correlatas às concentrações de pH do solo. Por um lado, acredita-se que as concentrações de CTC podem estar relacionadas aos teores de Al e Ca.

Os resultados obtidos por meio da PCA indicam que os parâmetros físico-químicos do solo na BHRS apresentam interações complexas e que influenciam diretamente na fertilidade agrícola.

A contribuição significativa do primeiro componente principal e a identificação de correlações positivas entre pH, CTC, Ca, Mg e a relação inversa com o HAl evidenciam a dinâmica de correção da acidez do solo no local. Adicionalmente, a importância do teor de MO e do P-resina reforça a necessidade de um manejo adequado na bacia hidrográfica para se otimizar a fertilidade agrícola do solo para o cultivo de olerícolas.

A análise da variabilidade dos parâmetros, como CTC, Mg, S e V%, evidencia que os tipos de solos mais argilosos na BHRS têm maior capacidade de retenção de nutrientes, o que é crucial para o cultivo de olerícolas. Em oposição, locais arenosos demonstram limitações na retenção de cátions, refletindo a necessidade de estratégias específicas para se potencializar a produtividade agrícola nesses locais.

Os resultados acerca da distância em relação aos corpos d'água e a declividade do terreno ressaltam a relevância dos recursos hídricos na olericultura, com 52,15% da BHRS apresentando condições favoráveis para o cultivo. Além disso, a implementação de práticas conservacionistas em áreas inclinadas, juntamente com a proximidade a fontes de água, é essencial para se otimizar a produtividade agrícola na bacia hidrográfica.

O modelo de aptidão agrícola ao cultivo de olerícolas por meio do algoritmo RF demonstrou eficácia na previsão das diferentes classes analisadas, apontando que a declividade é um fator determinante para a modelagem e tomadas de decisão. Portanto, práticas de manejo conservacionista, como controle da erosão e uso de cobertura vegetal, principalmente em locais de alto declive e que possuem práticas agrícolas, mostraram-se cruciais para que se possa otimizar o potencial produtivo e a sustentabilidade da BHRS, permitindo que áreas inicialmente consideradas menos favoráveis alcancem seu potencial máximo.

Em face dos desafios encontrados para cumprir o objetivo proposto, ressalta-se a heterogeneidade das classes granulométricas e a complexidade das interações entre os

parâmetros físico-químicos do solo, pois a identificação precisa das áreas de aptidão agrícola foi dificultada pela variabilidade dessas características.

Em relação à metodologia, a utilização do algoritmo RF demonstrou eficácia na classificação das texturas do solo, embora indique a necessidade de ajustes e calibrações adicionais para aprimorar a precisão das previsões. Embora o modelo final de aptidão agrícola, gerado por meio do RF, tenha se mostrado menos oneroso e custoso em comparação com abordagens convencionais, sua implementação envolveu um processo laborioso, que demandou um tratamento significativo dos dados e uma validação criteriosa.

Para estudos futuros, recomenda-se a comparação dos resultados obtidos com outros algoritmos de ML para avaliar a robustez e a precisão das análises realizadas. Adicionalmente, recomenda-se a implementação da otimização dos hiperparâmetros e o uso de técnicas de validação cruzada. Também sugere-se a realização de uma metodologia segmentada por sub-bacia, com o objetivo de hierarquizá-las para fins de gestão territorial, permitindo uma compreensão mais aprofundada das dinâmicas locais e facilitando a tomada de decisões.

De forma conclusiva, os resultados deste estudo têm o potencial de fornecer uma base sólida para apoiar a gestão territorial, agrícola e ambiental da BHRS. Além disso, estão alinhados com os ODS da ONU, especificamente o 2 (Fome Zero), 12 (Consumo e Produção Sustentáveis) e 13 (Ação Contra a Mudança Global do Clima), apresentando resultados capazes de orientar políticas e práticas que promovam a sustentabilidade e o bem-estar tanto das comunidades locais quanto do meio ambiente.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGRAWAL, Neelam; GOVIL, Himanshu; KUMAR, Tarun. Agricultural land suitability classification and crop suggestion using machine learning and spatial multicriteria decision analysis in semi-arid ecosystem. **Environment, Development And Sustainability**, [S.L.], p. 1-15, 4 fev. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10668-023-04440-1>.
- AHMED, Goma Bedawi; SHARIFF, Abdul Rashid M.; BALASUNDRAM, Siva Kumar; ABDULLAH, Ahmad Fikri Bin. Agriculture land suitability analysis evaluation based multi criteria and GIS approach. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 37, p. 012044, jun. 2016. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/37/1/012044>.
- AHMED, Nazir; ZHANG, Baige; CHACHAR, Zaid; LI, Juan; XIAO, Gengsheng; WANG, Qin; HAYAT, Faisal; DENG, Lansheng; NAREJO, Mehar-Un-Nisa; BOZDAR, Bilquees. Micronutrients and their effects on Horticultural crop quality, productivity and sustainability. **Scientia Horticulturae**, [S.L.], v. 323, p. 112512, jan. 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.scienta.2023.112512>.
- AKBAR; JUMIATI; A RUMALLANG,. Sustainability of agribusiness institutions (case study on horticultural agribusiness farmer groups in Bantaeng Regency). **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 1302, n. 1, p. 012123, 1 fev. 2024. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/1302/1/012123>.
- ALABI, Tunrayo R.; ABEBE, Abush T.; CHIGEZA, Godfree; FOWOBAJE, Kayode R.. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. **Remote Sensing Applications: Society and Environment**, [S.L.], v. 27, p. 100782, ago. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rsase.2022.100782>.
- ALLEONI, Luís Reynaldo Ferracciú; IGLESIAS, Cindy Silva Moreira; MELLO, Otávio Antônio de Camargo; CASAGRANDE, José Carlos; LAVORENTI, Norberto Antonio. Atributos do solo relacionados à adsorção de cádmio e cobre em solos tropicais. **Acta Scientiarum. Agronomy**, [S.L.], v. 27, n. 4, p. 729-737, dez. 2005. Sistema de Información Científica Redalyc ®. <https://www.redalyc.org/articulo.oa?id=303026560022>.
- ANDRADE, Renata; SILVA, Sérgio Henrique Godinho; FARIA, Wilson Missina; POGGERE, Giovana Clarice; BARBOSA, Julierme Zimmer; GUILHERME, Luiz Roberto Guimarães; CURI, Nilton. Proximal sensing applied to soil texture prediction and mapping in Brazil. **Geoderma Regional**, [S.L.], v. 23, p. 1-15, dez. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.geodrs.2020.e00321>.
- ARANTES, Leticia Tondato; ARANTES, Bruno Henrique Tondato; SACRAMENTO, Bruna Henrique; COSTA, Hetiany Ferreira da; OLIVEIRA, Renan Angrizani de; SIMONETTI, Vanessa Cezar; SILVA, Darllan Collins da Cunha e; LOURENÇO, Roberto Wagner. Application of spatial environmental indicators in the assessment of degradation potential of water resources in water basins. **Environmental Monitoring and Assessment**, v. 195, art. 931, 2023. Springer. <https://link.springer.com/article/10.1007/s10661-023-10011-3>.

ARANTES, Leticia Tondato; SANTOS, Arthur Pereira dos; SILVA, Camille Vasconcelos; NERY, Liliane Moreira; TOLEDO, Mayra Vannessa Lizcano; SIMONETTI, Vanessa Cezar; SILVA, Darllan Collins da Cunha e; LOURENÇO, Roberto Wagner. Socioeconomic spatial analysis through fuzzy system as a tool for territorial planning applied to watersheds.

International Journal Of River Basin Management, [S.L.], p. 1-17, 19 ago. 2024. Informa UK Limited. <http://dx.doi.org/10.1080/15715124.2024.2387579>.

ARANTES, Leticia Tondato. **Elaboração de uma metodologia baseada em redes neurais artificiais para o zoneamento ecológico-econômico em bacias hidrográficas**. Sorocaba, 2023. 158 p. Tese (Doutorado) - Universidade Estadual Paulista (Unesp), Instituto de Ciência e Tecnologia, Sorocaba. Disponível em: <https://repositorio.unesp.br/items/bb9776e6-a5b4-4b2e-a988-94f81047cfec>. Acesso em: 18 set. 2024.

ARAÚJO, Humberto Sampaio; QUADROS, Bárbara Rodrigues de; CARDOSO, Antonio Ismael Inácio; CORRÊA, Carla Verônica. Doses de potássio em cobertura na cultura da abóbora. **Pesquisa Agropecuária Tropical**, [S.L.], v. 42, n. 4, p. 469-475, dez. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1983-40632012000400004>.

AREAL, Francisco J.; JONES, Philip J.; MORTIMER, Simon R.; WILSON, Paul. Measuring sustainable intensification: combining composite indicators and efficiency analysis to account for positive externalities in cereal production. **Land Use Policy**, [S.L.], v. 75, p. 314-326, jun. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.landusepol.2018.04.001>.

ASADU, C.L.A; DIXON, A.G.O; OKECHUKWU, R. Comparative evaluation of the contributions of soil physicochemical properties to variations in the yields of four major staple food crops in eastern Nigeria. **Soil And Tillage Research**, [S.L.], v. 65, n. 2, p. 141-155, maio 2002. Elsevier BV. [http://dx.doi.org/10.1016/s0167-1987\(01\)00276-8](http://dx.doi.org/10.1016/s0167-1987(01)00276-8).

ASMAR JUNIOR, João; SANTOS, Felipe Corrêa Veloso dos; DORES, Anne Louise de Melo; BARBALHO, Maria Gonçalves da Silva. Chemical attributes as indicators of soil quality when applied to the cerrado biome: a literature review. **Águas e Florestas: desafios para conservação e utilização**, [S.L.], p. 131-148, 2021. Editora Científica Digital. <http://dx.doi.org/10.37885/210404155>.

Badraoui, M., Soudi, B., Moujahid, Y., Bennani, F., Bouhlassa, S. and Mikou, M. (1997) Mineralogical Consideration in Soil Fertility Management in Morocco. In: Ryan, J., Ed., Accomplishments and Future Challenges in Dry Land Soil Fertility Research in the Mediterranean Area, **Proc. of the Soil Fertility Workshop**, November 1995, ICARDA, Aleppo, Syria. <https://www.scirp.org/reference/referencespapers?referenceid=2593268>.

BAILEY, Scott W.; LONG, Robert P.; HORSLEY, Stephen B.. Forest Soil Cation Dynamics and Increases in Carbon on the Allegheny Plateau, PA, USA Following a Period of Strongly Declining Acid Deposition. **Soil Systems**, [S.L.], v. 5, n. 1, p. 16, 12 mar. 2021. MDPI AG. <http://dx.doi.org/10.3390/soilsystems5010016>.

BARBOSA, Larissa Macelle de Paulo; SANTOS, Tayanne de Paula da Silva; ROCHA, Sandra Mara Barbosa; SANTOS, Theuldes Oldenrique da Silva; OLIVEIRA, Louise Melo de Souza; ALCÂNTARA NETO, Francisco de; ARAÚJO, Ademir Sérgio Ferreira de; SOUZA, Henrique Antunes de; NUNES, Luís Alfredo Pinheiro Leal; SOUSA, Ricardo Silva de. Composts from bovine rumen and chicken litter improve soil fertility and promote the growth

of pepper (*Capsicum chinense* Jacq.). **Research Square**, [S.L.], p. 1, 14 jun. 2023. Research Square Platform LLC. <http://dx.doi.org/10.21203/rs.3.rs-3046861/v1>.

BARROW, N. J.. The effects of pH on phosphate uptake from the soil. **Plant And Soil**, [S.L.], v. 410, n. 1-2, p. 401-410, 2 set. 2016. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11104-016-3008-9>.

BATISTELLA, Danielli; MODOLO, Alcir José; CAMPOS, José Ricardo da Rocha; LIMA, Vanderlei Aparecido de. Comparative analysis of orbital sensors in soybean yield estimation by the random forest algorithm. **Ciência e Agrotecnologia**, [S.L.], v. 47, p. 1-15, 2023. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1413-7054202347002423>.

Bauer, ME; Cipra, JE. Identification of Agricultural Crops by Computer Processing of ERTS MSS Data. **Tecnologia LARS. Purdue University: West Lafayette**. 1973, 20, 205–212.

BEM AYED, Rayda; HANANA, Mohsen. Artificial Intelligence to Improve the Food and Agriculture Sector. **Journal Of Food Quality**, [S.L.], v. 2021, p. 1-7, 22 abr. 2021. Hindawi Limited. <http://dx.doi.org/10.1155/2021/5584754>.

BENINNI, Elisabete R. Y.; TAKAHASHI, Hideaki Wilson; NEVES, Carmen Silvia V.J.. Manejo do cálcio em alface de cultivo hidropônico. **Horticultura Brasileira**, [S.L.], v. 21, n. 4, p. 605-610, dez. 2003. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0102-05362003000400005>.

BENTON, Tim G.; BAILEY, Rob. The paradox of productivity: agricultural productivity promotes food system inefficiency. **Global Sustainability**, [S.L.], v. 2, p. 1-15, 2019. Cambridge University Press (CUP). <http://dx.doi.org/10.1017/sus.2019.3>.

BERHANE, Tedros; LANE, Charles; WU, Qiusheng; AUTREY, Bradley; ANENKHONOV, Oleg; CHEPINOGA, Victor; LIU, Hongxing. Decision-Tree, Rule-Based, and Random Forest Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory. **Remote Sensing**, [S.L.], v. 10, n. 4, p. 580-595, 9 abr. 2018. MDPI AG. <http://dx.doi.org/10.3390/rs10040580>.

BERNARDI, A. C. de C., P. L. O. de A. MACHADO, e C. A. SILVA. Fertilidade Do Solo E Demanda Por Nutrientes No Brasil. 2002. In: MANZATTO, C. V.; FREITAS JUNIOR, E. de; PERES, J. R. R. (Ed.). **Uso agrícola dos solos brasileiros**. Rio de Janeiro: Embrapa Solos, 2002. cap. 6, p. 61-77. <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/215165/1/Fertilidade-do-solo-e-demanda-por-nutrientes-no-Brasil-2002.pdf>.

BEZERRA, Marta Motinho. **Monitoramento de agrotóxicos em solo de produção orgânica, convencional e hidropônica e correlação com o controle químico de hortaliças cultivadas em Ibiuna**. Dissertação (Mestrado em Sanidade, Segurança Alimentar e Ambiental no Agronegócio) – Programa de Pós-Graduação, Instituto Biológico, São Paulo, 2022.

BIJEESH, T. V.; NARASIMHAMURTHY, K. N.. Surface water detection and delineation using remote sensing images: a review of methods and algorithms. **Sustainable Water**

Resources Management, [S.L.], v. 6, n. 4, p. 1, 9 jul. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s40899-020-00425-4>.

BISWAS, Hrittick; RATTAN, R.K.; DATTA, S.P.; SINGH, A.K.. Adsorption and translocation of sulfur in some tropical acid soils. **Journal Of Plant Nutrition And Soil Science**, [S.L.], v. 166, n. 4, p. 519-524, ago. 2003. Wiley. <http://dx.doi.org/10.1002/jpln.200320245>.

BATTOOL, Aaliya; ZAHRA, Noreen; IRSHAD, Azha; NASEER, Rubina; MAJID, Syeda Maria; AHMAD, Bilal; KAUSAR, Abida; SHAHZAD, Sobia. Effect of macronutrients management on nutrients uptake, partitioning, growth, and yield attributes in plants. **Essential Minerals In Plant-Soil Systems**, [S.L.], p. 129-144, 2024. Elsevier. <http://dx.doi.org/10.1016/b978-0-443-16082-0.00015-1>.

BOHNEN, H. Acidez e calagem. In: GIANELLO, C., BISSANI, C.A., TEDESCO, M.J. (eds.) **Princípios de fertilidade de solo**. Porto Alegre: Dep. de Solos. Fac. de Agronomia. UFRGS, 1995. p.51-76.

BORGES, C.; DEUNER, C.; RIGO, G.; OLIVEIRA, S.; MORAES, D. O estresse salino afeta a qualidade fisiológica de sementes de rúcula?. **ENCICLOPEDIA BIOSFERA**, [S. l.], v. 10, n. 19, 2014. Disponível em: <https://conhecer.org.br/ojs/index.php/biosfera/article/view/2370>.

BOTTINELLI, N.; JOUQUET, P.; CAPOWIEZ, Y.; PODWOJEWSKI, P.; GRIMALDI, M.; PENG, X.. Why is the influence of soil macrofauna on soil structure only considered by soil ecologists? **Soil And Tillage Research**, [S.L.], v. 146, p. 118-124, mar. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2014.01.007>.

BOWMAN, R. A.; REEDER, J. D.; LOBER, R. W.. Changes in soil properties in a central plains rangeland soil after 3, 20, and 60 years of cultivation1. **Soil Science**, [S.L.], v. 150, n. 6, p. 851-857, dez. 1990. Ovid Technologies (Wolters Kluwer Health). <http://dx.doi.org/10.1097/00010694-199012000-00004>.

BRADFELD, E.G.; GUTTRIDGE, C.G.. Effects of night-time humidity and nutrient solution concentration on the calcium content of tomato fruit. **Scientia Horticulturae**, [S.L.], v. 22, n. 3, p. 207-217, fev. 1984. Elsevier BV. [http://dx.doi.org/10.1016/0304-4238\(84\)90054-2](http://dx.doi.org/10.1016/0304-4238(84)90054-2).

BRADY, N. C. **Natureza e Propriedades dos Solos**. 7.ed. Rio de janeiro: Freitas Bastos, 1989. 878p.

BRADY, N. C.; WEIL, R. R. **Elementos da natureza e propriedades dos solos**. 3. ed. Rio de janeiro: Bookman Editora, 2009. 715p.

BREIMAN, Leo. Random forests. **Machine Learning**, [S.L.], v. 45, n. 1, p. 5-32, 2001. Springer Science and Business Media LLC. <http://dx.doi.org/10.1023/a:1010933404324>.

CABRAL, João Batista Pereira. Estudo do processo de assoreamento em reservatórios. **Caminhos de geografia**, [S.L.], v. 6, n. 14, p. 62-69, 2005. Instituto de Geografia UFU. http://www.ig.ufu.br/caminhos_de_geografia.html.

CARNEIRO, Marina Pedroso; SOUZA, Zigomar Menezes de; FARHATE, Camila Viana Vieira; CHERUBIN, Maurício Roberto; PANOSSO, Alan Rodrigo. Effect of cover crops and tillage systems on soil quality and sugarcane yield. **Soil Use And Management**, [S.L.], v. 40, n. 2, p. 1, abr. 2024. Wiley. <http://dx.doi.org/10.1111/sum.13048>.

CEAGESP – Companhia de Entrepósitos e Armazéns Gerais de São Paulo. **CEAGESP comemora 50 anos como importante distribuidor de alimentos**. Disponível em: <https://ceagesp.gov.br/comunicacao/noticias/ceagesp-comemora-50-anos-como-importante-distribuidor-de-alimentos/>. Acesso em: 21 set. 2023.

CHIAKA, Jeffrey Chiwukem; ZHEN, Lin; XIAO, Yu; HU, Yunfeng; WEN, Xin; MUHIRWA, Fabien. Spatial Assessment of Land Suitability Potential for Agriculture in Nigeria. **Foods**, [S.L.], v. 13, n. 4, p. 568, 14 fev. 2024. MDPI AG. <http://dx.doi.org/10.3390/foods13040568>.

CHEN, Jia; XIAO, Haibing; LI, Zhongwu; LIU, Cheng; WANG, Danyang; WANG, Lingxia; TANG, Chongjun. Threshold effects of vegetation coverage on soil erosion control in small watersheds of the red soil hilly region in China. *Ecological Engineering*, [S.L.], v. 132, p. 109-114, jul. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.ecoleng.2019.04.010>.

CHIODINI, Bruna Muller; DA SILVA, Adriana Guimarães; NEGREIROS, Aline Barbosa; MAGALHÃES, Leonarda Bezerra. Matéria orgânica e a sua influência na nutrição de plantas. **Revista Cultivando o Saber**, [S.L.], v. 6, n. 1, p. 181-190, 2013. <https://cultivandosaber.fag.edu.br/index.php/cultivando/article/view/506>.

CIRIC, Vladimir; PREKOP, Nenad; SEREMESIC, Srdjan; VOJNOV, Bojan; PEJIC, Borivoj; RADOVANOVIC, Dragan; MARINKOVIC, Dragana. The implication of cation exchange capacity (cec) assessment for soil quality management and improvement. **Journal Agriculture and Forestry**, [S.L.], v. 69, n. 4, p. 1, 15 dez. 2023. Journal Agriculture and Forestry. <http://dx.doi.org/10.17707/agricultforest.69.4.08>.

COURAULT, Dominique; SEGUIN, Bernard; OLIOSO, Albert. Review on estimation of evapotranspiration from remote sensing data: from empirical to numerical modeling approaches. **Irrigation And Drainage Systems**, [S.L.], v. 19, n. 3-4, p. 223-249, nov. 2005. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10795-005-5186-0>.

CUNHA NETO, Felipe Vieira da; PEREIRA, Marcos Gervasio; LELES, Paulo Sérgio dos Santos; ABEL, Elton Luiz da Silva. Atributos químicos e físicos do solo em áreas sob diferentes coberturas florestais e pastagem em Além Paraíba - MG. **Ciência Florestal**, [S.L.], v. 28, n. 1, p. 13-24, 2 abr. 2018. Universidad Federal de Santa Maria. <http://dx.doi.org/10.5902/1980509831569>.

DAVI, João E. A.; NOGUEIRA, Bruna K. A.; GASQUES, Letícia R.; CÔRT, Andressa S. dalla; CAMARGO, Tatiane A. de; PACHECO, Leandro P.; SILVA, Laércio S.; SOUZA, Edicarlo D. de. Diversified production systems in sandy soils of the Brazilian Cerrado: nutrient dynamics and soybean productivity. **Journal Of Plant Nutrition**, [S.L.], v. 46, n. 8, p. 1650-1667, 30 jun. 2022. Informa UK Limited. <http://dx.doi.org/10.1080/01904167.2022.2093744>.

DELGADO, Daniel; SADAUI, Mahrez; LUDWIG, Wolfgang; MENDEZ, Williams. Depth of the pedological profile as a conditioning factor of soil erodibility (RUSLE K-Factor) in Ecuadorian basins. **Environmental Earth Sciences**, [S.L.], v. 82, n. 12, p. 1-15, 24 maio 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12665-023-10944-w>.

DESA, U. N. World population prospects 2019: Highlights. New York (US): United Nations Department for Economic and Social Affairs, 2019.

DESTA, Hailu Shiferaw. Modelling land suitability and development potential options for irrigable and rainfed agricultural scenarios in Ethiopia. **Irrigation And Drainage**, [S.L.], v. 73, n. 3, p. 1168-1191, 30 jan. 2024. Wiley. <http://dx.doi.org/10.1002/ird.2929>.

DEXTER, A.R.. Advances in characterization of soil structure. **Soil And Tillage Research**, [S.L.], v. 11, n. 3-4, p. 199-238, jun. 1988. Elsevier BV. [http://dx.doi.org/10.1016/0167-1987\(88\)90002-5](http://dx.doi.org/10.1016/0167-1987(88)90002-5).

DEXTER, A.R. Soil physical quality: part ii. friability, tillage, tilth and hard setting. **Geoderma**, [S.L.], v. 120, n. 3-4, p. 215-225, jun. 2004. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2003.09.005>.

DHALIWAL, S. S.; NARESH, R. K.; MANDAL, Agniva; WALIA, M. K.; GUPTA, Raj K.; SINGH, Rajveer; DHALIWAL, M. K.. Effect of manures and fertilizers on soil physical properties, build-up of macro and micronutrients and uptake in soil under different cropping systems: a review. **Journal Of Plant Nutrition**, [S.L.], v. 42, n. 20, p. 2873-2900, 13 set. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/01904167.2019.1659337>.

DIAZ-ZORITA, M. Disruptive methods for assessing soil structure. **Soil And Tillage Research**, [S.L.], v. 64, n. 1-2, p. 3-22, fev. 2002. Elsevier BV. [http://dx.doi.org/10.1016/s0167-1987\(01\)00254-9](http://dx.doi.org/10.1016/s0167-1987(01)00254-9).

DONAGEMMA, Guilherme Kangussu; FREITAS, Pedro Luiz de; BALIEIRO, Fabiano de Carvalho; FONTANA, Ademir; SPERA, Silvio Túlio; LUMBRERAS, José Francisco; VIANA, João Herbert Moreira; ARAÚJO FILHO, José Coelho de; SANTOS, Flávia Cristina dos; ALBUQUERQUE, Manoel Ricardo de. Characterization, agricultural potential, and perspectives for the management of light soils in Brazil. **Pesquisa Agropecuária Brasileira**, [S.L.], v. 51, n. 9, p. 1003-1020, set. 2016. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-204x2016000900001>.

DORAISWAMY, Paul C.; SINCLAIR, Thomas R.; HOLLINGER, Steven; AKHMEDOV, Bakhyt; STERN, Alan; PRUEGER, John. Application of MODIS derived parameters for regional crop yield assessment. **Remote Sensing Of Environment**, [S.L.], v. 97, n. 2, p. 192-202, jul. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2005.03.015>.

DORAN, J.W.; JONES, A.J. (Eds.). Methods for assessing soil quality. Madison, Wisconsin, USA: **Soil Science Society of America**, 1996. 409 p.

DUBREUIL, Vincent; PECHUTTIÉ FANTE, Karime; PLANCHON, Olivier; SANT'ANNA NETO, João Lima. Les types de climats annuels au Brésil : une application de la classification

de köppen de 1961 à 2015. **Echogéo**, [S.L.], n. 41, p. 1-27, 28 set. 2017. OpenEdition. <http://dx.doi.org/10.4000/echogeo.15017>.

EL BEHAIRY, Radwa A.; EL BAROUDY, Ahmed A.; IBRAHIM, Mahmoud M.; MOHAMED, Elsayed Said; KUCHER, Dmitry E.; SHOKR, Mohamed S.. Assessment of Soil Capability and Crop Suitability Using Integrated Multivariate and GIS Approaches toward Agricultural Sustainability. *Land*, [S.L.], v. 11, n. 7, p. 1027, 6 jul. 2022. MDPI AG. <http://dx.doi.org/10.3390/land11071027>.

ELI-CHUKWU, N. C.. Applications of Artificial Intelligence in Agriculture: a review. **Engineering, Technology & Applied Science Research**, [S.L.], v. 9, n. 4, p. 4377-4383, 10 ago. 2019. Engineering, Technology & Applied Science Research. <http://dx.doi.org/10.48084/etasr.2756>.

ELLIOTT, E. T.; COLEMAN, D. C. Let the soil work for us. **Ecol. Bull.**, v. 39, p. 23-32, 1988. <https://www.jstor.org/stable/20112982>.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Amostragem e cuidados na coleta de solo para fins de fertilidade** / Murilo Rodrigues de Arruda... [et al.] – Manaus: Embrapa Amazônia Ocidental, 2014. 18 p. – (Documentos / Embrapa Amazônia Ocidental, ISSN 1517-3135; 115).

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. In: TEIXEIRA, P. C.; DONAGEMMA, G. K.; FONTANA, A.; TEIXEIRA, W. G. (Ed.). **Manual de métodos de análise de solo**. 3. ed. rev. e ampl. Brasília, DF: Embrapa, 2017. pt. 1, cap. 19, p. 184-197.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Manual de métodos de análise de solo**. Rio de Janeiro, Serviço Nacional de Levantamento e Conservação de Solos, 1979. 247p.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Matéria orgânica do solo**. Luiz Fernando Carvalho Leite. – Teresina. Embrapa Meio-Norte. 2004. 31p.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. EMBRAPA. **Cultivo de Feijão - Boro**. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/feijao/producao/micronutrientes/boro>. Acesso em: 15 nov. 2023.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. In: SANTOS, H. G. dos; JACOMINE, P. K. T.; ANJOS, L. H. C. dos; OLIVEIRA, V. A. de; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. de; ARAUJO FILHO, J. C. de; OLIVEIRA, J. B. de; CUNHA, T. J. F. (Org). **Sistema Brasileiro de Classificação de Solos**. Brasília. 2018.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. EMBRAPA - **Conceitos de fertilidade do solo e manejo adequado para as regiões tropicais** / Carlos Cesar Ronquim. – Campinas: Embrapa Monitoramento por Satélite, 2010.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Conceitos de fertilidade do solo e manejo adequado para as regiões tropicais** / Carlos Cesar Ronquim. - 2.ed. - Campinas: Embrapa Territorial, 2020. 34 p.: il. ; (Boletim de Pesquisa e Desenvolvimento / Embrapa Territorial, ISSN 1806-3322; 35).

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. Sistema brasileiro de classificação de solos. Brasília, Serviço de Produção de Informação, 1999. 412p.
<https://www.embrapa.br/solos/sibcs>.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. Recomendações técnicas para o cultivo de hortaliças em agricultura familiar. Brasília, DF: **Embrapa Hortaliças**, 2007. 16 p. (Embrapa Hortaliças. Circular Técnica, 47). ISSN 1415-3033. Disponível em:
<https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/781607>. Acesso em: 01 set. 2024

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. Apostila Irrigação e fertirrigação em fruteiras e hortaliças: manejo da água de irrigação. Editores técnicos: Valdemício Ferreira de Sousa, Waldir Aparecido Marouelli, Eugênio Ferreira Coelho, José Maria Pinto, Maurício Antonio Coelho Filho. **Embrapa Informação Tecnológica**. Brasília, DF, 2011. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/907498/irrigacao-e-fertirrigacao-em-fruteiras-e-hortalicas>. Acesso em 11 set. 2024.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Manual de produção de hortaliças tradicionais**. Brasília, DF: Embrapa, 2013. Disponível em:
<https://www.embrapa.br/busca-de-publicacoes/-/publicacao/983087/manual-de-producao-de-hortalicas-tradicionais>. Acesso em: 18 set. 2024.

ERICKSON, Bruce; FAUSTI, Scott W.. The role of precision agriculture in food security. *Agronomy Journal*, [S.L.], v. 113, n. 6, p. 4455-4462, nov. 2021. Wiley.
<http://dx.doi.org/10.1002/agj2.20919>.

ESRI. **ArcGIS for Desktop**: Release 10.5. Redlands, CA: Environmental Systems Research Institute, 2016. Disponível em: <https://www.esri.com/en-us/home>. Acesso em: 11 abril 2023.

FAGERIA, N.K.; BALIGAR, V.C.; CLARK, R.B.. Micronutrients in Crop Production. **Advances In Agronomy**, [S.L.], p. 185-268, 2002. Elsevier.
[http://dx.doi.org/10.1016/s0065-2113\(02\)77015-6](http://dx.doi.org/10.1016/s0065-2113(02)77015-6).

FADL, Mohamed E.; ABDELRAHMAN, Mohamed A. E.; EL-DESOKY, Ahmed I.; SAYED, Yasser A.. Assessing soil productivity potential in arid region using remote sensing vegetation indices. **Journal Of Arid Environments**, [S.L.], v. 222, p. 105166, jun. 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.jaridenv.2024.105166>.

FAO. **Agricultura familiar e desenvolvimento sustentável na CPLP**. Disponível em:
https://www.fao.org/uploads/media/AF_CPLP_FAO.pdf. Acesso em 01 set. 2023

FAO, IFAD, UNICEF, WFP and WHO. 2022. **The State of Food Security and Nutrition in the World 2022**. Repurposing food and agricultural policies to make healthy diets more affordable. Rome, FAO. <https://doi.org/10.4060/cc0639en>

FARDEAU, J. C.. Dynamics of phosphate in soils. An isotopic outlook. **Fertilizer Research**, [S.L.], v. 45, n. 2, p. 91-100, 1995. Springer Science and Business Media LLC.
<http://dx.doi.org/10.1007/bf00790658>.

FAROOQ, Muhammad Shahbaz; UZAIR, Muhammad; RAZA, Ali; HABIB, Madiha; XU, Yinlong; YOUSUF, Muhammad; YANG, Seung Hwan; KHAN, Muhammad Ramzan. Uncovering the Research Gaps to Alleviate the Negative Impacts of Climate Change on Food Security: a review. **Frontiers In Plant Science**, [S.L.], v. 13, p. 1-15, 11 jul. 2022. Frontiers Media SA. <http://dx.doi.org/10.3389/fpls.2022.927535>.

FAQUIN, V. **Nutrição mineral de plantas**. Lavras: FAEPE. 1997, 227 p.

FOY, C. D. Effects of aluminum on plant growth. In: CARSON, E. W. (Ed.). **The plant root and its environment**. Charlottesville: University Press of Virginia, 1974. p. 601-642.

FRANCO, Tainara Ferrugem. **Metais pesados em solos de áreas de produção intensiva de hortaliças em Petrópolis - RJ. 2019**. 68 f. Dissertação (Mestrado em Engenharia Agrícola e Ambiental) - Instituto de Tecnologia, Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, 2019.

FERREIRA, Lusiane de Sousa; OLIVEIRA, Vinicius de Souza; MARCHIORI, Johnatan Jair de Paula; GOMES, Matheus de Paula; FERREIRA, Tatiane Cristovam; VARGENS, Fernanda Nery; BOLSONI, Evellyn Zuqui; CARRIÇO, Eduarda; HOLTZ, Anderson Mathias. Soil Fertility Indicators in Crop-Livestock-Forest Integration Systems. **International Journal Of Plant & Soil Science**, [S.L.], v. 35, n. 20, p. 1093-1104, 7 out. 2023. Sciencedomain International. <http://dx.doi.org/10.9734/ijpss/2023/v35i203906>.

GALLAGHER, M. L. Os nutrientes e seu metabolismo. Mahan LK, Stump SE, organizadores. **Krause, alimentos, nutrição e dietoterapia**. 12a Edição. Rio de Janeiro: Elsevier, p. 39–143, 2010.

GAMBILL, Daniel R. et al. Predicting USCS soil classification from soil property variables using Random Forest. **Revista de Terramecânica**, v. 65, p. 85-92, 2016. <https://doi.org/10.1016/j.jterra.2016.03.006>

GAUTAM, Pratibha; KUMAR, Vineet; KUMAR, Sunil. Challenges and Perspectives. **Solid Waste Treatment Technologies**, [S.L.], p. 29, 22 abr. 2024. CRC Press. <http://dx.doi.org/10.1201/9781003352396>.

GE, Yufeng; THOMASSON, J. Alex; SUI, Ruixiu. Remote sensing of soil properties in precision agriculture: a review. **Frontiers Of Earth Science**, [S.L.], v. 5, p. 229-238, 21 jun. 2011. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11707-011-0175-0>.

Gebbers, R.; Adamchuk, V. Precision agriculture and food security. **Ciência**. 2010, 327, 828–831. <http://dx.doi.org/10.1126/science.1183899>

GEETHA, V. et al. An effective crop prediction using random forest algorithm. In: 2020 International Conference on System, Computation, Automation and Networking (ICSCAN). **IEEE**, 2020. p. 1-5.

GLAROS, Alan G.; KLINE, Rex B.. Understanding the accuracy of tests with cutting scores: the sensitivity, specificity, and predictive value model. **Journal Of Clinical Psychology**,

[S.L.], v. 44, n. 6, p. 1013-1023, nov. 1988. Wiley. [http://dx.doi.org/10.1002/1097-4679\(198811\)44:63.0.co;2-z](http://dx.doi.org/10.1002/1097-4679(198811)44:63.0.co;2-z).

GUARESCHI, R. F.; BODDEY, R. M.; ALVES, B. J. R.; SARKIS, L. F.; MARTINS, M. D. R.; JANTALIA, C. P.; URQUIAGA, S. Balanço de nitrogênio, fósforo e potássio na agricultura da América Latina e o Caribe. **Terra Latinoamericana**, [S.L.], v. 37, n. 2, p. 105-119, 2019. FapUNIFESP (SciELO). <https://doi.org/10.28940/terra.v37i2.423>.

GU, Yingxin; BROWN, Jesslyn F.; VERDIN, James P.; WARDLOW, Brian. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, [S.L.], v. 34, n. 6, p. 1-15, mar. 2007. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2006gl029127>.

GUPTA, Umesh C.. Boron Nutrition Of Crops. **Advances In Agronomy**, [S.L.], p. 273-307, 1980. Elsevier. [http://dx.doi.org/10.1016/s0065-2113\(08\)60142-x](http://dx.doi.org/10.1016/s0065-2113(08)60142-x).

GOMES, D. M. **Mapeamento geotécnico para análise de feições erosivas concentradas na bacia do Córrego Ribeirão do Meio, São Pedro/SP na escala 1:20.000**. 2002. 242 f. Dissertação (Mestrado em Geotecnia), Universidade de São Paulo, São Carlos, 2000.

GOMES, Natalino M.; FARIA, Manoel A. de; SILVA, Antônio M. da; MELLO, Carlos R. de; VIOLA, Marcelo R.. Variabilidade espacial de atributos físicos do solo associados ao uso e ocupação da paisagem. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.L.], v. 11, n. 4, p. 427-435, ago. 2007. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-43662007000400013>.

GHOSH, Smriti Singhatiya Dr. Shivnath. A Review on Soil Property Detection using Machine Learning Approach. **Smart Moves Journal Ijoscience**, [S.L.], v. 4, n. 8, p. 6, 5 ago. 2018. Smart Moves. <http://dx.doi.org/10.24113/ijoscience.v4i8.152>.

HABIBI, Luthfan Nur; WATANABE, Tomoya; MATSUI, Tsutomu; TANAKA, Takashi S. T.. Machine Learning Techniques to Predict Soybean Plant Density Using UAV and Satellite-Based Remote Sensing. **Remote Sensing**, [S.L.], v. 13, n. 13, p. 1-15, 29 jun. 2021. MDPI AG. <http://dx.doi.org/10.3390/rs13132548>.

HAN, Hong; GUO, Xiaoling; YU, Hua. Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest. **2016 7Th Ieee International Conference On Software Engineering And Service Science (Icse)**, [S.L.], p. 1-15, ago. 2016. IEEE. <http://dx.doi.org/10.1109/icse.2016.7883053>.

HAMDAN, Mohd Fadhli; NOOR, Siti Nurfadhlin Mohd; ABD-AZIZ, Nazrin; PUA, Teen-Lee; TAN, Boon Chin. Green Revolution to Gene Revolution: technological advances in agriculture to feed the world. **Plants**, [S.L.], v. 11, n. 10, p. 1297-1, 12 maio 2022. MDPI AG. <http://dx.doi.org/10.3390/plants11101297>.

HAN, Hongzhu; BAI, Jianjun; YAN, Jianwu; YANG, Huiyu; MA, Gao. A combined drought monitoring index based on multi-sensor remote sensing data and machine learning. **Geocarto International**, [S.L.], v. 36, n. 10, p. 1161-1177, 27 jun. 2019. Informa UK Limited. <http://dx.doi.org/10.1080/10106049.2019.1633423>.

HAPL, Mahfouz; ABDEL-MAWGOUD, Ali; HAMED, Mahdy; ALDABAA, Abdalsamad Ali. Assessment of Soil Spatial Variability for Agricultural Potential in El-Dakhla Oasis, New Valley, Egypt. **New Valley Journal Of Agricultural Science**, [S.L.], p. 1, 22 abr. 2024. Egyptian Knowledge Bank.

<http://dx.doi.org/10.21608/nvjas.2024.261875.1271>.

HOSSEINI, Fatemeh Sadat; SEO, Myoung Bae; RAZAVI-TERMEH, Seyed Vahid; SADEGHI-NIARAKI, Abolghasem; JAMSHIDI, Mohammad; CHOI, Soo-Mi. Geospatial Artificial Intelligence (GeoAI) and Satellite Imagery Fusion for Soil Physical Property Predicting. **Sustainability**, [S.L.], v. 15, n. 19, p. 14125, 24 set. 2023. MDPI AG.

<http://dx.doi.org/10.3390/su151914125>.

HOUMMA, Ismaïguil Hanadé; GADAL, Sébastien; MANSOURI, Loubna El; GARBA, Maman; GBETKOM, Paul Gérard; BARKAWI, Mansour Badamassi Mamane; HADRIA, Rachid. A new multivariate agricultural drought composite index based on random forest algorithm and remote sensing data developed for Sahelian agrosystems. **Geomatics, Natural Hazards And Risk**, [S.L.], v. 14, n. 1, p. 1-2223384, 16 jun. 2023. Informa UK Limited.

<http://dx.doi.org/10.1080/19475705.2023.2223384>.

HOLB, I. J.; NAGY, P. T.. Availability of Calcium, Magnesium, Sulfur, Copper, Zinc, and Manganese in the Plant–Soil System of Integrated and Organic Apple Orchards.

Communications In Soil Science And Plant Analysis, [S.L.], v. 40, n. 1-6, p. 682-693, mar. 2009. Informa UK Limited. <http://dx.doi.org/10.1080/00103620802693326>.

HE, Yong; HOU, Lingling; WANG, Hong; HU, Kelin; MCCONKEY, Brian. A modelling approach to evaluate the long-term effect of soil texture on spring wheat productivity under a rain-fed condition. **Scientific Reports**, [S.L.], v. 4, n. 1, p. 1-5736, 30 jul. 2014. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/srep05736>.

HE, Feng; MOHAMADZADEH, Neda; SADEGHNEJAD, Mostafa; INGRAM, Ben; OSTOVARI, Yaser. Fractal Features of Soil Particles as an Index of Land Degradation under Different Land-Use Patterns and Slope-Aspects. **Land**, [S.L.], v. 12, n. 3, p. 1-615, 4 mar. 2023. MDPI AG. <http://dx.doi.org/10.3390/land12030615>.

IBGE – instituto brasileiro de geografia e estatística. Banco de Dados de Informações Ambientais. 2021. Disponível em: <https://bdiaweb.ibge.gov.br>. Acesso 09 jun 2023.

IBGE – instituto brasileiro de geografia e estatística. Censo Demográfico. Ibiúna. 2022. Disponível em: <https://cidades.ibge.gov.br/brasil/sp/ibiuna/panorama>. Acesso em: 27 dez 2023.

IBGE – instituto brasileiro de geografia e estatística. **Manual técnico de uso da terra**. Org.: Diretoria de Geociências. Ministério do Planejamento, Orçamento e Gestão. 3ª ed. Rio de Janeiro, Rio de Janeiro (RJ). 2013.

<https://biblioteca.ibge.gov.br/visualizacao/livros/liv81615.pdf>. Acesso 04 set. 2024.

IPCC – Intergovernmental Panel On Climate Change. Climate Change 2022 – Impacts, Adaptation and Vulnerability. **Cambridge University Press**, [S.L.], p. 1-3056, 22 jun. 2023. Cambridge University Press. <http://dx.doi.org/10.1017/9781009325844>.

IAC – Instituto Agronômico de Campinas. **Métodos de Análise Química, Mineralógica e Física de Solos do Instituto Agronômico de Campinas**. Org.: O. A. de CAMARGO; A.C. MONIZ; J. A. JORGE; J. M. A. S. VALADARES. Campinas, São Paulo (SP). 2009

JANAKIRAM, T; REDDY, Vijay Rakesh. Hill horticulture-status, problems and strategies. **Journal Of Hill Agriculture**, [S.L.], v. 7, n. 1, p. 1, 2016. Diva Enterprises Private Limited. <http://dx.doi.org/10.5958/2230-7338.2016.00003.3>.

JAMBO, Yilma; ALEMU, Abera; TASEW, Workalemahu. Impact of small-scale irrigation on household food security: evidence from ethiopia. **Agriculture & Food Security**, [S.L.], v. 10, n. 1, p. 1-16, 18 jul. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1186/s40066-021-00294-w>.

JHA, Kirtan; DOSHI, Aalap; PATEL, Poojan; SHAH, Manan. A comprehensive review on automation in agriculture using artificial intelligence. **Artificial Intelligence In Agriculture**, [S.L.], v. 2, p. 1-12, jun. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.aiia.2019.05.004>.

JONES, C. B.. The Implicit Triangulated Irregular Network and Multiscale Spatial Databases. **The Computer Journal**, [S.L.], v. 37, n. 1, p. 43-57, 1 jan. 1994. Oxford University Press (OUP). <http://dx.doi.org/10.1093/comjnl/37.1.43>.

JUMA, NG, 1993. Interrelationships between soil structure/texture, soil biota/soil organic matter and crop production. In: L. Brussaard e MJ Kooistra (Editores), Int. Workshop sobre Métodos de Pesquisa nas Inter-relações Estrutura do Solo/Biota do Solo. **Geoderma**, 57: 3–30. <https://doi.org/10.1016/B978-0-444-81490-6.50054-6>

JUNAID, Muhammad; SUN, Jianguo; IQBAL, Amir; SOHAIL, Mohammad; ZAFAR, Shahzad; KHAN, Azhar. Mapping LULC Dynamics and Its Potential Implication on Forest Cover in Malam Jabba Region with Landsat Time Series Imagery and Random Forest Classification. **Sustainability**, [S.L.], v. 15, n. 3, p. 1-1858, 18 jan. 2023. MDPI AG. <http://dx.doi.org/10.3390/su15031858>.

JUNG, Jinha; MAEDA, Murilo; CHANG, Anjin; BHANDARI, Mahendra; ASHAPURE, Akash; LANDIVAR-BOWLES, Juan. The potential of remote sensing and artificial intelligence as tools to improve the resilience of agriculture production systems. **Current Opinion In Biotechnology**, [S.L.], v. 70, p. 15-22, ago. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.copbio.2020.09.003>.

KABAŁA, Cezary; ŁABAZ, Beata. Relationships between soil pH and base saturation – conclusions for Polish and international soil classifications. **Soil Science Annual**, [S.L.], v. 69, n. 4, p. 206-214, 1 dez. 2018. Soil Science Society of Poland. <http://dx.doi.org/10.2478/ssa-2018-0021>.

KARATHANASIS, Anastasios D. (1985) Mineralogy and Soil Productivity. **Agronomy Notes**, 18, 1-4.

KARUNATHILAKE, E. M. B. M.; LE, Anh Tuan; HEO, Seong; CHUNG, Yong Suk; MANSOOR, Sheikh. The Path to Smart Farming: innovations and opportunities in precision agriculture. **Agriculture**, [S.L.], v. 13, n. 8, p. 1-1593, 11 ago. 2023. MDPI AG. <http://dx.doi.org/10.3390/agriculture13081593>.

Katsigiannis, P.; Galanis, G.; Dimitrakos, A.; Tsakiridis, N.; Kalopesas, C.; Alexandridis, T.; Chouzouri, A.; Patakas, A.; Zalidis, G.. Fusion of spatio-temporal UAV and proximal sensing data for an agricultural decision support system. **Fourth International Conference On Remote Sensing And Geoinformation Of The Environment (Rscy2016)**, [S.L.], p. 564-574, 12 ago. 2016. SPIE. <http://dx.doi.org/10.1117/12.2244856>.

KASHIWAR, Sumedh R.; KUNDU, Manik Chandra; DONGARWAR, Usha R.. Soil erosion estimation of Bhandara region of Maharashtra, India, by integrated use of RUSLE, remote sensing, and GIS. **Natural Hazards**, [S.L.], v. 110, n. 2, p. 937-959, 16 ago. 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11069-021-04974-5>.

KE, Chaoying; HE, Shu; QIN, Yigen. Comparison of natural breaks method and frequency ratio dividing attribute intervals for landslide susceptibility mapping. **Bulletin Of Engineering Geology And The Environment**, [S.L.], v. 82, n. 10, p. 1, 19 set. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10064-023-03392-0>.

KIRKBY, E. A.; RÖMHELD, V. Micronutrientes na fisiologia de plantas: funções, absorção e mobilidade. **Informações agrônômicas**, v. 118, n. 2, p. 1- 24, 2007.

KINGRA, P K; MAJUMDER, Debjyoti; SINGH, Som Pal. Application of Remote Sensing and Gis in Agriculture and Natural Resource Management Under Changing Climatic Conditions. **Agricultural Research Journal**, [S.L.], v. 53, n. 3, p. 295-302, 2016. Diva Enterprises Private Limited. <http://dx.doi.org/10.5958/2395-146x.2016.00058.2>.

KOGO, Benjamin Kipkemboi; KUMAR, Lalit; KOECH, Richard. Climate change and variability in Kenya: a review of impacts on agriculture and food security. **Environment, Development And Sustainability**, [S.L.], v. 23, n. 1, p. 23-43, 8 jan. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10668-020-00589-1>.

KOME, Georges Kogge; ENANG, Roger Kogge; TABI, Fritz Oben; YERIMA, Bernard Palmer Kfuban. Influence of Clay Minerals on Some Soil Fertility Attributes: a review. **Open Journal Of Soil Science**, [S.L.], v. 09, n. 09, p. 155-188, 2019. Scientific Research Publishing, Inc.. <http://dx.doi.org/10.4236/ojss.2019.99010>.

KUCUKER, Derya Mumcu; GIRALDO, Daniela Cedano. Assessment of soil erosion risk using an integrated approach of GIS and Analytic Hierarchy Process (AHP) in Erzurum, Turkiye. **Ecological Informatics**, [S.L.], v. 71, p. 1-15, nov. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.ecoinf.2022.101788>.

KULIMUSHI, Luc Cimusa; BASHAGALUKE, Janvier Bigabwa; PRASAD, Pankaj; HERIKAZI, Aimé B.; KUSHWAHA, Nand Lal; MASROOR, Md; CHOUDHARI, Pandurang; ELBELTAGI, Ahmed; SAJJAD, Haroon; MOHAMMED, Safwan. Soil erosion susceptibility mapping using ensemble machine learning models: a case study of upper congo river sub-basin. **Catena**, [S.L.], v. 222, p. 106858, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.catena.2022.106858>.

KRISHNA MURTHY, R. Impact of different land-use systems on soil physico-chemical properties. **Mysore Journal of Agricultural Sciences**, v. 57, n. 1, p. 15-25, 2023. <file:///C:/Users/simio/Downloads/26.pdf>

KUMAR, Prasann. Soil Conservation for Global Sustainability. **World Sustainability Series**, [S.L.], p. 103-128, 2024. Springer Nature Switzerland. http://dx.doi.org/10.1007/978-3-031-57456-6_6.

KUZICHEVA, Natalia Yu.; SOLOMAKHIN, Mikhail A.; KARAICHEV, Alexey S.; SHCHERBAKOV, Nikolai V.; KVOCHKIN, Alexander N.. Strategic Competitiveness Management Of Modern Horticulture: targets and directions. **European Proceedings Of Social And Behavioural Sciences**, [S.L.], p. 307-313, 1 fev. 2022. European Publisher. <http://dx.doi.org/10.15405/epsbs.2022.02.38>.

LANDIM, P.M.B. Análise estatística de dados geológicos. São Paulo, UNESP, 1998. 226p. (Ciência e Tecnologia).

LANDIM, P.M.B. Introdução aos métodos de estimação espacial para confecção de mapas. DGA, IGCE, UNESP/Rio Claro, Lab. **Geomatemática**. 2000.

LAPAZ, Allan de Marcos; YOSHIDA, Camila Hatsu Pereira; GORNI, Pedro Henrique; FREITAS-SILVA, Larisse de; ARAËJO, Talita de Oliveira; RIBEIRO, Cleberson. Iron toxicity: effects on the plants and detoxification strategies. **Acta Botanica Brasilica**, [S.L.], v. 36, p. 1-15, 2022. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0102-33062021abb0131>.

LEITE, Ricardo Figueiredo Cavaleiro; SCHUCH, Luis Osmar Braga; AMARAL, Ademir dos Santos; TAVARES, Lizandro Ciciliano. Rendimento e qualidade de sementes de arroz irrigado em função da adubação com boro. **Revista Brasileira de Sementes**, [S.L.], v. 33, n. 4, p. 785-791, 2011. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0101-31222011000400021>.

LI, Linchao; WANG, Bin; FENG, Puyu; LIU, De Li; HE, Qinsi; ZHANG, Yajie; WANG, Yakai; LI, Siyi; LU, Xiaoliang; YUE, Chao. Developing machine learning models with multi-source environmental data to predict wheat yield in China. **Computers And Electronics In Agriculture**, [S.L.], v. 194, p. 106790, mar. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2022.106790>.

LEPSCH, I. F. **Formação e Conservação dos Solos**: Para Uso Sustentável dos Solos. 2. ed. São Paulo: Oficina de Textos, 2011. Disponível em: <https://www.ofitexto.com.br/livro/formacao-e-conservacao-dos-solos>. Acesso em: 11 set. 2024.

LI, Wen; HAO, Sijia; ZHOU, Hao; LIU, Ying. Research on modeling method of continuous spectrum water quality online detection based on random forest. **Optoelectronics Letters**, [S.L.], v. 19, n. 2, p. 95-100, fev. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11801-023-2127-9>.

LI, Z.; ZHU, Q.; GOLD, C. **Digital terrain modeling: principles and methodology**. London: CRC PRESS, 2005. 323 p.

LIAW, Andy et al. Classification and regression by randomForest. **R news**, v. 2, n. 3, p. 18-22, 2002.

LIEß, Mareike; GLASER, Bruno; HUWE, Bernd. Incerteza na predição espacial da textura do solo: comparação dos modelos de árvore de regressão e Random Forest. **Geoderma**, v. 70-79, 2012. <https://doi.org/10.1016/j.geoderma.2011.10.010>

LIU, Xufei; ZHANG, Lin; YANG, Fuhui; ZHOU, Wei. Determining reclaimed water quality thresholds and farming practices to improve food crop yield: a meta-analysis combined with random forest model. **Science Of The Total Environment**, [S.L.], v. 862, p. 160774, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2022.160774>.

LOPES, ALFREDO SCHEID. **Manual Internacional de Fertilidade do Solo**. 2. ed. Piracicaba: Potafos, 1998. 177 p.

LÓKI, József. Agriculture: crop cultivation and horticulture. **Anthropogenic Geomorphology**, [S.L.], p. 55-67, 2010. Springer Netherlands. http://dx.doi.org/10.1007/978-90-481-3058-0_5.

MAIA JÚNIOR, Lauro Pessoa; LOURENÇO, Roberto Wagner. Impactos das mudanças no uso e cobertura da terra sobre a variabilidade do albedo na Bacia Hidrográfica do Rio Sorocabaçu (Ibiúna-SP). **Revista Brasileira de Climatologia**, [S.L.], v. 27, ago. 2020. <http://dx.doi.org/10.5380/abclima.v27i0.72761>.

LEMOS, R.C.; SANTOS, R.D. Manual de descrição e coleta de solo no campo. 3a ed. Campinas. **Sociedade Brasileira de Ciência do Solo**. 84 p. 1996.

LEMOS, R.C.; SANTOS, R.D. Manual de descrição e coleta de solo no campo. 2.ed. Campinas: **Sociedade Brasileira de Ciência do Solo**; Embrapa-SNLCS, 1984. 46p.

LOW, A. J.. The effect of cultivation on the structure and other physical characteristics of grassland and arable soils (194–970). **Journal Of Soil Science**, [S.L.], v. 23, n. 4, p. 363-380, dez. 1972. Wiley. <http://dx.doi.org/10.1111/j.1365-2389.1972.tb01668.x>.

LOPES, Thaís Cristina de Souza; PORTELA, Jeane Cruz; BATISTA, Rafael Oliveira; BANDEIRA, Diego José da Costa; LEITE, Isaque de Oliveira; RAMALHO, Lúirla Bento; GONDIM, Joaquim Emanuel Fernandes; COSTA, Joseane Dunga da; GURGEL, Marcelo Tavares; SOUZA, Carolina Malala Martins. Clay Fraction Mineralogy and Structural Soil Attributes of Two Soil Classes under the Semi-Arid Climate of Brazil. **Land**, [S.L.], v. 11, n. 12, p. 2192, 3 dez. 2022. MDPI AG. <http://dx.doi.org/10.3390/land11122192>.

LOWERY, B. Soil water parameters and soil quality. In: DORAN, J.W.; JONES, A.J. (Eds.). **Methods for assessing soil quality**. **Madison: Soil Science Society of America**, 1996. Cap.8, p.143-155.

MALAVOLTA, E. **Elementos de nutrição mineral de plantas**. São Paulo: Ceres, 1980. 251p.

MALAVOLTA, E. **Gesso Agrícola no ambiente e na nutrição da planta-perguntas e respostas**. 1992.

MALAVOLTA, E.; **Manual de nutrição mineral de plantas**. Ed. Agronômica Ceres. São Paulo, 2006. 638 p.

MALAVOLTA E; VITTI G.C; OLIVEIRA S.A. Avaliação do estado nutricional das plantas: princípios e aplicações. 2. ed. Piracicaba: **POTAFOS**. 1997. p 233-241

MAŁECKI, Jerzy J.; KADZIKIEWICZ-SCHOENEICH, Monika; SZOSTAKIEWICZ-HOŁOWNIA, Marzena. Concentration and mobility of copper and zinc in the hypergenic zone of a highly urbanized area. **Environmental Earth Sciences**, [S.L.], v. 75, n. 1, p. 1-15, 19 dez. 2015. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s12665-015-4789-5>.

MANNIGEL, Anny Rosi; CARVALHO, Morel de Passos e; MORETI, Dolorice; MEDEIROS, Luciano da Rosa. Fator erodibilidade e tolerância de perda dos solos do Estado de São Paulo. **Acta Scientiarum. Agronomy**, [S.L.], v. 24, p. 1335, 30 abr. 2008. Universidade Estadual de Maringa. <http://dx.doi.org/10.4025/actasciagron.v24i0.2374>.

Marek, R.S.; Richardson, J.B. Investigating Surficial Geologic Controls on Soil Properties, Inorganic Nutrient Uptake, and Northern Hardwood Growth in Western Massachusetts, USA. **J Solo Sci Planta Nutr**, [S.L.], v. 20(3):901–911. 2020. <https://doi.org/10.1007/s42729-020-00176-3>

MARTINEZ-TABOADA, Fernando; REDONDO, Jose Ignacio. The SIESTA (SEAAV Integrated evaluation sedation tool for anaesthesia) project: initial development of a multifactorial sedation assessment tool for dogs. **Plos One**, [S.L.], v. 15, n. 4, p. e0230799, 1 abr. 2020. Public Library of Science (PLoS). <http://dx.doi.org/10.1371/journal.pone.0230799>.

MCLEAN, E. O. Contrasting concepts in soil test interpretation: Sufficiency levels of available nutrients versus basic cation saturation ratios.. In: Stelly, M. (ed.) Soil testing: Correlating and interpreting the analytical results. Madison: **American. Society of Agronomy**, 1977. p.39-54.

MOEYS, Julien. The soil texture wizard: R functions for plotting, classifying, transforming and exploring soil texture data. CRAN. **R-Project**, p. 1-104, 2018. https://cran.ms.unimelb.edu.au/web/packages/soiltexture/vignettes/soiltexture_vignette.pdf.

MOHAMMED, Safwan; ALSAFADI, Karam; ALI, Haidar; MOUSAVI, Seyed Mohammad Nasir; KIWAN, Samer; HENNAWI, Sami; HARSANYIE, Endre; PHAM, Quoc Bao; LINH, Nguyen Thi Thuy; ALI, Rawshan. Assessment of land suitability potentials for winter wheat cultivation by using a multi criteria decision Support- Geographic information system (MCDS-GIS) approach in Al-Yarmouk Basin (Syria). **Geocarto International**, [S.L.], v. 37, n. 6, p. 1645-1663, 15 jul. 2020. Informa UK Limited. <http://dx.doi.org/10.1080/10106049.2020.1790674>.

MOHANTY, Lalita Kumar; SINGH, N K; RAJ, Pranav; PRAKASH, Aditya; TIWARI, Awanindra Kumar; SINGH, Vishal; SACHAN, Prashun. Nurturing Crops, Enhancing Soil Health, and Sustaining Agricultural Prosperity Worldwide through Agronomy. **Journal Of Experimental Agriculture International**, [S.L.], v. 46, n. 2, p. 46-67, 3 fev. 2024. Sciencedomain International. <http://dx.doi.org/10.9734/jeai/2024/v46i22308>.

MOUHAMAD, Raghad. Behavior of Potassium in Soil: a mini review. **Chemistry International**, [S.L.], p. 1-15, 2016. Unpublished.
<http://dx.doi.org/10.13140/RG.2.1.4830.7041>.

MELLO, Simone Costa; MENDONÇA, Jéssika Angelotti. **Nutrição de olerícolas**. Curitiba: SENAR-PR., 80 p. 2017.

METTERNICHT, Graciela. Land use and spatial planning: Enabling sustainable management of land resources. **Springer**, 2018. <https://link.springer.com/book/10.1007/978-3-319-71861-3>.

MIRANSARI, M.. Soil microbes and the availability of soil nutrients. **Acta Physiologiae Plantarum**, [S.L.], v. 35, n. 11, p. 3075-3084, 6 jul. 2013. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11738-013-1338-2>.

MOSTOFA, Mohammad Golam; RAHMAN, Md. Mezanur; GHOSH, Totan Kumar; KABIR, Ahmad Humayan; ABDELRAHMAN, Mostafa; KHAN, Md. Arifur Rahman; MOCHIDA, Keiichi; TRAN, Lam-Son Phan. Potassium in plant physiological adaptation to abiotic stresses. **Plant Physiology And Biochemistry**, [S.L.], v. 186, p. 279-289, set. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.plaphy.2022.07.011>.

Morsy E.M., Abdel-Kawi K.A., Khalil M.N.A. 2009. Efficiency of *Trichoderma viride* and *Bacillus subtilis* as biocontrol agents against *Fusarium solani* on tomato plants. *Egyptian Journal of Phytopathology* 37 (1): 47–57

MUCIDA, Danielle Piuza; GORGENS, Eric Bastos; RECH, André Rodrigo; CHRISTOFARO, Cristiano; SILVA, Ricardo Siqueira da; PEREIRA, Israel Marinho; MORAIS, Marcelino Santos de; COSTA, Adriana Monteiro da; FRANÇA, Luciano Cavalcante de Jesus. Designing optimal agrosilvopastoral landscape by the potential for conservation use in Brazil. **Sustainable Horizons**, [S.L.], v. 5, p. 100045, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.horiz.2022.100045>.

MUJIYO; NARIYANTI, Sari; SUNTORO; HERAWATI, Aktavia; HERDIANSYAH, Ganjar; IRIANTO, Heru; RIPTANTI, Erlyna Wida; QONITA, Aulia. Soil fertility index based on altitude: a comprehensive assessment for the cassava development area in indonesia. **Annals Of Agricultural Sciences**, [S.L.], v. 67, n. 2, p. 158-165, dez. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.aos.2022.10.001>.

NAGANJALI, K.; CHARITHA, N.; ASLAM, Sk.; SAIKISHORE, A.; SRAVANTHI, D.; SIDDAPPA, K.; MURTHY, K. Gopala Krishna; KUMAR, J. Hemantha; NEELIMA, P.; PAVANI, T.. Revamping Water Use in Agriculture: techniques and emerging innovations. **Journal Of Scientific Research And Reports**, [S.L.], v. 30, n. 7, p. 1055-1066, 13 jul. 2024. Sciencedomain International. <http://dx.doi.org/10.9734/jsrr/2024/v30i72215>.

NATASHA, Natasha; SHAHID, Muhammad; BIBI, Irshad; IQBAL, Jibran; KHALID, Sana; MURTAZA, Behzad; BAKHAT, Hafiz Faiq; FAROOQ, Abu Bakr Umer; AMJAD, Muhammad; HAMMAD, Hafiz Mohkum. Zinc in soil-plant-human system: a data-analysis review. **Science Of The Total Environment**, [S.L.], v. 808, p. 152024, fev. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2021.152024>.

NEWMAN, A. C. D.. The significance of clays in agriculture and soils. **Philosophical Transactions Of The Royal Society Of London. Series A, Mathematical And Physical Sciences**, [S.L.], v. 311, n. 1517, p. 375-389, 14 jun. 1984. The Royal Society.
<http://dx.doi.org/10.1098/rsta.1984.0035>.

NERY, Liliane Moreira; TONIOLO, Bruno Pereira; SANTOS, Arthur Pereira dos; MARTINS, Antônio César Germano; SILVA, Darllan Collins da Cunha e. Challenge of political integration in the territorial management of a protected area based on the analysis of land use and land cover change. **Journal Of Environmental Studies And Sciences**, [S.L.], p. 1, 23 out. 2024. Springer Science and Business Media LLC.
<http://dx.doi.org/10.1007/s13412-024-00990-6>.

NOLLA, Antonio; ANGHINONI, Ibanor. Métodos utilizados para a correção da acidez do solo no Brasil. **RECEN-Revista Ciências Exatas e Naturais**, v. 6, n. 1, p. 97-111, 2004.
<https://revistas.unicentro.br/index.php/RECEN/article/view/410>.

NOVAIS, R.F.; ALVAREZ V., V.H.; BARROS, N.F.; FONTES, R.L.F.; CANTARUTTI, R.B.; NEVES, J.C.L. **Fertilidade do solo**. Viçosa, MG, Universidade Federal de Viçosa, 2007. 1017p.

NOVAIS, R.F. & SMYTH, T.J. **Fósforo em solo e planta em condições tropicais**. Viçosa, MG, Universidade Federal de Viçosa, 1999. 399p.

NOI, Phan Thanh; KAPPAS, Martin. Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. **Sensors**, [S.L.], v. 18, n. 2, p. 18, 22 dez. 2017. MDPI AG.
<http://dx.doi.org/10.3390/s18010018>.

NUNES, Fábio Carvalho; CARVALHO, Cláudia Cseko Nolasco de; ALVES, Lander de Jesus; PRASAD, Majeti Narasimha Vara. Clay Composites: physicochemical characterization. **Advances In Material Research And Technology**, [S.L.], p. 29-54, 2023. Springer Nature Singapore. http://dx.doi.org/10.1007/978-981-99-2544-5_2.
 NWOSU, Nkem Joseph; OSHUNSANYA, Suarau Odutola. Management of Agricultural Lands for Sustainable Crop Cultivation and Greenhouse Gas Reduction. **Handbook Of Climate Change Management**, [S.L.], p. 1-28, 2021. Springer International Publishing.
http://dx.doi.org/10.1007/978-3-030-22759-3_104-1.

OADES, J.M.. The role of biology in the formation, stabilization and degradation of soil structure. **Geoderma**, [S.L.], v. 56, n. 1-4, p. 377-400, mar. 1993. Elsevier BV.
[http://dx.doi.org/10.1016/0016-7061\(93\)90123-3](http://dx.doi.org/10.1016/0016-7061(93)90123-3).

OADES, J. M.. The retention of organic matter in soils. **Biogeochemistry**, [S.L.], v. 5, n. 1, p. 35-70, fev. 1988. Springer Science and Business Media LLC.
<http://dx.doi.org/10.1007/bf02180317>.

Organização das Nações Unidas. ONU. (2015) General Assembly Resolution A/RES/70/1. **Transforming Our World, the 2030 Agenda for Sustainable Development**.
https://www.un.org/en/development/desa/population/migration/generalassembly/docs/globalcompact/A_RES_70_1_E.pdf.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. ONU. **Transformando nosso mundo: a Agenda 2030 para o desenvolvimento sustentável**. Disponível em: <<https://nacoesunidas.org/pos2015/agenda2030/>>. Acesso em: 23 dez. 2018.

OR, Dani; KELLER, Thomas; SCHLESINGER, William H.. Natural and managed soil structure: on the fragile scaffolding for soil functioning. **Soil And Tillage Research**, [S.L.], v. 208, p. 104912, abr. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.still.2020.104912>.

PAIXÃO, Bruna Martins da. **O uso de geotecnologias em estudos integrados de variáveis físicas e socioambientais em bacias hidrográficas**. Dissertação de Mestrado. Programa de Pós-Graduação em Ciências Ambientais (PGCA/UNESP). 2021.

PANDITH, Vaishali; KOUR, Haneet; SINGH, Surjeet; MANHAS, Jatinder; SHARMA, Vinod. Performance Evaluation of Machine Learning Techniques for Mustard Crop Yield Prediction from Soil Analysis. **Journal Of Scientific Research**, [S.L.], v. 64, n. 02, p. 394-398, 2020. Banaras Hindu University. <http://dx.doi.org/10.37398/jsr.2020.640254>.

PARAJULI, Ranjan; THOMA, Greg; MATLOCK, Marty D.. Environmental sustainability of fruit and vegetable production supply chains in the face of climate change: a review. **Science Of The Total Environment**, [S.L.], v. 650, p. 2863-2879, fev. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2018.10.019>.

PAREETH, Sajid; KARIMI, Poolad; SHAFIEI, Mojtaba; FRAITURE, Charlotte de. Mapping Agricultural Landuse Patterns from Time Series of Landsat 8 Using Random Forest Based Hierarchical Approach. **Remote Sensing**, [S.L.], v. 11, n. 5, p. 601, 12 mar. 2019. MDPI AG. <http://dx.doi.org/10.3390/rs11050601>.

PARKASH, Ved; SINGH, Sukhbir. A Review on Potential Plant-Based Water Stress Indicators for Vegetable Crops. **Sustainability**, [S.L.], v. 12, n. 10, p. 3945, 12 maio 2020. MDPI AG. <http://dx.doi.org/10.3390/su12103945>.

PATEL, Govind Singh; RAI, Amrita; NARAYAN, Nripendra das; SINGH, R.P. Smart agriculture: emerging pedagogies of deep learning, machine learning and internet of things. **CRC Press**, 2021.

PATEL, Raj. The Long Green Revolution. **Journal Of Peasant Studies**, [S.L.], v. 40, n. 1, p. 1-63, jan. 2013. Informa UK Limited. <http://dx.doi.org/10.1080/03066150.2012.719224>.

PRADEBON, Leonardo Cesar; STEURER, Alexandre; CARVALHO, Ivan Ricardo; LORO, Murilo Vieira; SEGATTO, Thalia Aparecida; SANES, Fernanda San Martin; SARTURI, Marlon Vinícius; SFALCIN, Inaê Carolina; DEMARI, Gustavo Henrique. Soil attributes and their interrelationships in Rio Grande do Sul. **Agronomy Science And Biotechnology**, [S.L.], v. 9, p. 1-13, 11 jul. 2023. Editora Mecenass Ltda. <http://dx.doi.org/10.33158/asb.r191.v9.2023>.

POMBO, L.C.A.; KLAMT, E. Adsorção de zinco e cobre de dois solos do Estado do Rio Grande do Sul. **Revista Brasileira de Ciência do Solo**, Campinas, v. 10, p. 191-194, 1986.

QGIS DEVELOPMENT TEAM. **QGIS geographic information system**. Open Source Geospatial Foundation, 2024. Disponível em: <https://qgis.org>. Acesso em: 29 jun. 2024.

RAJBANSHI, Joy; DAS, Sharmistha; PAUL, Roni. Quantification of the effects of conservation practices on surface runoff and soil erosion in croplands and their trade-off: a meta-analysis. **Science Of The Total Environment**, [S.L.], v. 864, p. 161015, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2022.161015>.

RAIJ, B. van; ANDRADE, J.C.; CANTARELLA, H.; QUAGGIO, J.A. (Ed.). **Análise química para avaliação da fertilidade de solos tropicais**. Campinas: Instituto Agrônomo, 2001. 285p.

RAIJ, B. van; QUAGGIO, J. A.; CANTARELLA, H.; FERREIRA, M. E.; LOPES, A. S.; BATAGLIA, O. C. Análise química de solos para fins de fertilidade. Campinas: Fundação Cargill, 1987. 170 p.

RAIJ, Bernardo Van; SACCHETTO, Maria Thereza Dovichi; IGUE, Toshio. Correlações entre o pH e o grau de saturação em bases nos solos com horizonte B textural e horizonte B latossólico. **Bragantia**, [S.L.], v. 27, n. 1, p. 193-200, jan. 1968. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0006-87051968000100017>.

RAIMI, Adekunle R.; EZEOKOLI, Obinna T.; ADELEKE, Rasheed A. Soil nutrient management influences diversity, community association and functional structure of rhizosphere bacteriome under vegetable crop production. *Frontiers in Microbiology*, v. 14, 2023. Disponível em: <https://doi.org/10.3389/fmicb.2023.1229873>. Acesso em: 18 set. 2024.

RStudio Team (2023). RStudio: Integrated Development Environment for R. RStudio, PBC, Boston, MA URL <http://www.rstudio.com/>.

RABEL, Diego Oliveira; MOTTA, Antonio Carlos Vargas; BARBOSA, Julierme Zimmer; MELO, Vander Freitas; PRIOR, Stephen Arthur. Depth distribution of exchangeable aluminum in acid soils: a study from subtropical brazil. **Acta Scientiarum. Agronomy**, [S.L.], v. 40, n. 1, p. 39320, 15 maio 2018. Universidade Estadual de Maringá. <http://dx.doi.org/10.4025/actasciagron.v40i1.39320>.

RABOT, E.; WIESMEIER, M.; SCHLÜTER, S.; VOGEL, H.-J.. Soil structure as an indicator of soil functions: a review. **Geoderma**, [S.L.], v. 314, p. 122-137, mar. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2017.11.009>.

RAMALHO FILHO, A.; BEEK, K.J. Sistema de avaliação da aptidão agrícola das terras. 3.ed. rev. Rio de Janeiro: **EMBRAPA**, 1995. 65p.

RATHORE, Avinash Chandra; SINGH, Charan; JAYAPRAKASH, J.; GUPTA, Anand Kumar; DOHAREY, Vijay Kumar; JINGER, Dinesh; SINGH, Deepak; YADAV, Devideen; BARH, Anupam; ISLAM, Sadikul. Impact of conservation practices on soil quality and ecosystem services under diverse horticulture land use system. **Frontiers In Forests And Global Change**, [S.L.], v. 6, p. 1, 30 nov. 2023. Frontiers Media SA. <http://dx.doi.org/10.3389/ffgc.2023.1289325>.

REICHARDT, K. **A água em sistemas agrícolas**. São Paulo: Manole. 1987. 188p.

Resende, M., N. Curi, S. B. Resende & G. F. Corrêa. 1999. **Pedologia: base para distinção de ambientes**. 3. ed. NEPUT, Viçosa. 338 p.

RESENDE, Thalita Mendes; ROSOLEN, Vania. IMPACTOS DA CONVERSÃO DE USO E MANEJO DO SOLO DO CERRADO UTILIZANDO DADOS DE CARBONO TOTAL E ISOTÓPICO. **Geosp: Espaço e Tempo** (Online), [S.L.], n. 33, p. 39, 30 abr. 2013. Universidade de Sao Paulo, Agencia USP de Gestao da Informacao Academica (AGUIA). <http://dx.doi.org/10.11606/issn.2179-0892.geosp.2013.74300>.

RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ V, V. H. (Eds.) **Recomendações para uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação**. Viçosa, MG: CFSEMG/UFV, 1999. 359p.

RICHART, Alfredo; TAVARES FILHO, João; BRITO, Osmar Rodrigues; LLANILLO, Rafael Fuentes; FERREIRA, Rogério. Compactação do solo: causas e efeitos. **Semina: Ciências Agrárias**, v. 26, n. 3, p. 321-343, 2005. <https://www.redalyc.org/pdf/4457/445744077016.pdf>.

RILLIG, Matthias C.; MUMMEY, Daniel L.. Mycorrhizas and soil structure. **New Phytologist**, [S.L.], v. 171, n. 1, p. 41-53, 31 maio 2006. Wiley. <http://dx.doi.org/10.1111/j.1469-8137.2006.01750.x>.

RIZZO, Felipe Alexandre; SANTOS, Arthur; SILVA, Darllan Collins da Cunha e. Técnicas de geoprocessamento aplicadas para análise temporal do microclima na bacia hidrográfica do córrego do Pequiá, Maranhão. **Boletim Goiano de Geografia**, [S.L.], v. 44, n. 1, p. 1, 17 jun. 2024. Universidade Federal de Goias. <http://dx.doi.org/10.5216/bgg.v44i1.78032>.

ROMERO-RUIZ, Alejandro; LINDE, Niklas; KELLER, Thomas; OR, Dani. A Review of Geophysical Methods for Soil Structure Characterization. **Reviews Of Geophysics**, [S.L.], v. 56, n. 4, p. 672-697, dez. 2018. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/2018rg000611>.

ROSSI, Márcio. 2017. **Mapa pedológico do Estado de São Paulo: revisado e ampliado**. São Paulo: Instituto Florestal, 2017. V.1. 118p. Disponível em: https://www.infraestruturameioambiente.sp.gov.br/institutoflorestal/wp-content/uploads/sites/234/2017/11/Livro_Solos1.pdf. Acesso em: 01 set. 2024

ROY, Surendra; BHALLA, S. Kumar. Role of Geotechnical Properties of Soil on Civil Engineering Structures. **Scientific & Academic Publishing**, [s. l], v. 7, p. 103-109, 2017. <http://article.sapub.org/10.5923.j.re.20170704.03.html>.

R STUDIO TEAM. **RStudio: Integrated Development Environment for R**. Boston: RStudio, Inc., 2023. Disponível em: <https://www.rstudio.com/>. Acesso em: 12 ago. 2023.

RUTEBUKA, Jules; UWIMANZI, Aline Munyeshuli; NKUNDWAKAZI, Olive; KAGABO, Desire Mbarushimana; MBONIGABA, Jean Jacques Muhinda; VERMEIR, Pieter; VERDOODT, Ann. Effectiveness of terracing techniques for controlling soil erosion by water in Rwanda. **Journal Of Environmental Management**, [S.L.], v. 277, p. 111369, jan. 2021. Elsevier BV. <http://dx.doi.org/10.1016/j.jenvman.2020.111369>.

SABLJIĆ, Luka; LUKIĆ, Tin; BAJIĆ, Davorin; MARKOVIĆ, Rastko; SPALEVIĆ, Velibor; DELIĆ, Dragica; RADIVOJEVIĆ, Aleksandar R.. Optimizing agricultural land use: a gis-based assessment of suitability in the sana river basin, bosnia and herzegovina. **Open Geosciences**, [S.L.], v. 16, n. 1, p. 1, 1 jan. 2024. Walter de Gruyter GmbH. <http://dx.doi.org/10.1515/geo-2022-0683>.

SAKAMOTO, T; YOKOZAWA, M; TORITANI, H; SHIBAYAMA, M; ISHITSUKA, N; OHNO, H. A crop phenology detection method using time-series MODIS data. **Remote Sensing Of Environment**, [S.L.], v. 96, n. 3-4, p. 366-374, 30 jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2005.03.008>.

SANTANA, Felipe Bachion de; DE SOUZA, André Marcelo; POPPI, Ronei Jesus. Visible and near infrared spectroscopy coupled to random forest to quantify some soil quality parameters. **Spectrochimica Acta Parte A: Espectroscopia Molecular e Biomolecular**, v. 454-462, 2018. <https://doi.org/10.1016/j.saa.2017.10.052>

SANTOS, Arthur Pereira dos; ARANTES, Leticia Tondato; PAULA, Ana Laura de; SILVA, Darllan Collins da Cunha e. Avaliação da expansão agropecuária como forma de indicador de degradação ambiental na mesorregião Noroeste do estado de Minas. **Geofocus Revista Internacional de Ciencia y Tecnología de La Información Geográfica**, [S.L.], v. 33, p. 7-26, 29 jul. 2024a. Asociacion Espanola de Geografia. <http://dx.doi.org/10.21138/gf.839>.

SANTOS, Arthur Pereira dos; SIMIONATTO, Henzo Henrique; ARANTES, Leticia Tondato; SALAS, Angie Paola Santacruz; SILVA, Darllan Collins da Cunha e. Relación espacio-temporal de la temperatura superficial con el tipo de cobertura y uso del suelo, en los barrios del municipio de Paracatu, Mina Gerais, Brasil. **Anales de Geografía de La Universidad Complutense**, [S.L.], v. 44, n. 1, p. 235-249, 31 jan. 2024b. Universidad Complutense de Madrid (UCM). <http://dx.doi.org/10.5209/aguc.94211>.

SANTOS, Arthur Pereira dos; SIMIONATTO, Henzo Henrique; ARANTES, Letícia Tondato; SIMONETTI, Vanessa Cezar; OLIVEIRA, Renan Angrizani de; SALES, Jomil Costa Abreu; SILVA, Darllan Collins da Cunha e. The Influence of Land Use and Land Cover on Surface Temperature in a Water Catchment Sub-Basin. **Sociedade & Natureza**, [S.L.], v. 35, n. 1, p. 1, 2 ago. 2023. EDUFU - Editora da Universidade Federal de Uberlandia. <http://dx.doi.org/10.14393/sn-v35-2023-69161>.

SANTOS, Arthur; SIMIONATTO, Henzo. Methodological proposal for evaluating the transformation of urban microclimate in medium-sized cities: a case study in the urban mesh of the municipality of paracatu, minas gerais ∴ br. **Raega - O Espaço Geográfico em Análise**, [S.L.], v. 57, p. 46, 12 set. 2023. Universidade Federal do Parana. <http://dx.doi.org/10.5380/raega.v57i0.88156>.

SANTOS, Arthur; SIMIONATTO, Henzo. Spatial Analysis of the Impacts Caused by Changes in Land Use on the Estimation of Surface Temperature in the The City of Paracatu (MG). **Anuário do Instituto de Geociências**, [S.L.], v. 47, p. 1, 18 out. 2024. Universidade Federal do Rio de Janeiro. http://dx.doi.org/10.11137/1982-3908_2024_47_55194.

SANTOS, Gláucia Cecília Gabrielli dos; RODELLA, Arnaldo Antonio; ABREU, Cleide Aparecida de; COSCIONE, Aline Renée. Vegetable species for phytoextraction of boron, copper, lead, manganese and zinc from contaminated soil. **Scientia Agricola**, [S.L.], v. 67, n.

6, p. 713-719, dez. 2010. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-90162010000600014>.

SATHIYAMURTHI, Subbarayan; SARAVANAN, Subbarayan; SANKRITI, Ramanarayan; ALURU, Manjunath; SIVARANJANI, Sankaralingam; SRIVEL, Ravi. Integrated GIS and AHP techniques for land suitability assessment of cotton crop in Perambalur District, South India. **International Journal Of System Assurance Engineering And Management**, [S.L.], v. 15, n. 1, p. 267-278, 24 jun. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s13198-022-01705-2>.

SCHWAB, G.O.; FANGMEIER, D.D.; ELLIOT, W.J.; FREVERT, R.K. Soil and water conservation engineering. **New York, John Wiley & Sons**, 1993. 507 p.

SFREDO, G.J.; SARRUGE, J.R.; HAAG, H.P.. Absorção de nutrientes por duas cultivares de girassol (*Helianthus annuus*, L.) em condições de campo: iv. acúmulo de micronutrientes. **Anais da Escola Superior de Agricultura Luiz de Queiroz**, [S.L.], v. 40, n. 2, p. 1219-1245, 1983. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0071-12761983000200022>.

SHAH, Farooq; WU, Wei. Soil and Crop Management Strategies to Ensure Higher Crop Productivity within Sustainable Environments. **Sustainability**, [S.L.], v. 11, n. 5, p. 1485, 11 mar. 2019. MDPI AG. <http://dx.doi.org/10.3390/su11051485>.

SHAFIQUE, Hafiza Asma; SULTANA, Viqar; EHTESHAMUL-HAQUE, Syed; ATHAR, Mohammad. Management of soil-borne diseases of organic vegetables. *Journal Of Plant Protection Research*, [S.L.], v. 56, n. 3, p. 221-230, 1 jul. 2016. Walter de Gruyter GmbH. <http://dx.doi.org/10.1515/jppr-2016-0043>.

Sparks DL (2003) **Química ambiental do solo**, 2ª ed. Acadêmico, Amsterdã

SHARMA, Abhinav; JAIN, Arpit; GUPTA, Prateek; CHOWDARY, Vinay. Machine Learning Applications for Precision Agriculture: a comprehensive review. **Ieee Access**, [S.L.], v. 9, p. 4843-4873, 2021. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2020.3048415>.

SHANMUGAPRIYA, P.; RATHIKA, S.; RAMESH, T.; JANAKI, P. Applications of remote sensing in agriculture-A Review. *Int. J. Curr. Microbiol. Appl. Sci*, v. 8, n. 01, p. 2270-2283, 2019.

SILVA, Cristiane da. **Avaliação do uso e ocupação do solo sobre a qualidade da água em área de produção agrícola de hortaliças**. 2017. 95 f. Tese (Doutorado em Engenharia Agrícola e Ambiental) - Instituto de Tecnologia, Universidade Federal Rural do Rio de Janeiro, Seropédica-RJ, 2017.

SILVA, Samuel de Assis; LIMA, Julião Soares de Souza. Lógica fuzzy no mapeamento de variáveis indicadoras de fertilidade do solo. **Idesia (Arica)**, [S.L.], v. 27, n. 3, p. 41-46, dez. 2009. SciELO Agencia Nacional de Investigacion y Desarrollo (ANID). <http://dx.doi.org/10.4067/s0718-34292009000300007>.

SILVA, Michelangelo de Oliveira; VELOSO, Cássio Laurentino; NASCIMENTO, Denisson Lima do; OLIVEIRA, Jailson de; PEREIRA, Dalbert de Freitas; COSTA, Kleyton Danilo da Silva. Indicadores químicos e físicos de qualidade do solo. **Brazilian Journal Of Development**, [S.L.], v. 6, n. 7, p. 47838-47855, 2020. Brazilian Journal of Development. <http://dx.doi.org/10.34117/bjdv6n7-431>.

SHEPHERD, Trevor Graham et al. Visual soil assessment. horizons. **mw & Landcare Research**, 2000.

Skempton, A.W., The Colloidal activity of clays; Proc. 3rd. Int. Conf. **Soil Mechanics and Foundation Engineering** (London)., 1, 47–61, 1953.

SMITH, Dwight D.; WISCHMEIER, Walter H. **Rainfall erosion**. Advances in agronomy, v. 14, p. 109-148, 1962.

SMITH, Pete; POCH, Rosa M.; LOBB, David A.; BHATTACHARYYA, Ranjan; ALLOUSH, Ghiath; EUDOXIE, Gaius D.; ANJOS, Lúcia H.C.; CASTELLANO, Michael; NDZANA, Georges M.; CHENU, Claire. Status of the World's Soils. **Annual Review Of Environment And Resources**, [S.L.], p. 1, 3 set. 2024. Annual Reviews. <http://dx.doi.org/10.1146/annurev-environ-030323-075629>.

SONKA, Steve. Big Data: fueling the next evolution of agricultural innovation. **Journal Of Innovation Management**, [S.L.], v. 4, n. 1, p. 114-136, 4 maio 2016. University of Porto. http://dx.doi.org/10.24840/2183-0606_004.001_0008.

SOUSA, Cristina Soares de; BONETTI, Ana Maria; GOULART FILHO, Luiz Ricardo; MACHADO, Jane Rodrigues de Assis; LONDE, Luciana Nogueira; BAFFI, Milla Alves; RAMOS, Renato Graciliano; VIEIRA, Carlos Ueira; KERR, Warwick Estevam. Divergência genética entre genótipos de alface por meio de marcadores AFLP. **Bragantia**, [S.L.], v. 66, n. 1, p. 11-16, 2007. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0006-87052007000100002>.

SOUZA, Zigomar M.; MARQUES JÚNIOR, José; PEREIRA, Gener T.; BARBIERI, Diogo M.. Variabilidade espacial da textura de um latossolo vermelho eutroférico sob cultivo de cana-de-açúcar. **Engenharia Agrícola**, [S.L.], v. 24, n. 2, p. 309-319, ago. 2004. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-69162004000200009>.

STEPANOV, Alexey; DUBROVIN, Konstantin; SOROKIN, Aleksei; ASEEVA, Tatiana. Predicting Soybean Yield at the Regional Scale Using Remote Sensing and Climatic Data. **Remote Sensing**, [S.L.], v. 12, n. 12, p. 1936, 15 jun. 2020. MDPI AG. <http://dx.doi.org/10.3390/rs12121936>.

STIRZAKER, R.J.; SUTTON, B.G.; COLLIS-GEORGE, N.. SUSTAINABLE SYSTEMS OF SOIL MANAGEMENT IN VEGETABLE PRODUCTION. **Acta Horticulturae**, [S.L.], n. 247, p. 81-84, set. 1989. International Society for Horticultural Science (ISHS). <http://dx.doi.org/10.17660/actahortic.1989.247.13>.

SULEYMANOV, Azamat et al. Modelagem Florestal Aleatória de Propriedades do Solo em Áreas Semiáridas Salinas. **Agricultura**, v. 13, n. 5, pág. 976, 2023.

VIEIRA, P. S.; DOS SANTOS, R. L.; PEREIRA, E. C. G.; SANTOS, M. B. da C.; GUEDES, V. H. F. Amostragem de solo sob mata atlântica em regeneração para fins de fertilidade. **Revista Geama**, [S. l.], v. 6, n. 1, p. 5–11, 2020. Disponível em: <https://www.journals.ufrpe.br/index.php/geama/article/view/2686>. Acesso em: 2 maio. 2024.

TIBBITTS, T. W.; PALZKILL, D. A.. Requirement for root-pressure flow to provide adequate calcium to low-transpiring tissue. **Communications In Soil Science And Plant Analysis**, [S.L.], v. 10, n. 1-2, p. 251-257, jan. 1979. Informa UK Limited. <http://dx.doi.org/10.1080/00103627909366892>.

TAREK, Zahraa; ELSHEWEY, Ahmed M.; SHOHIEB, Samaa M.; ELHADY, Abdelghafar M.; EL-ATTAR, Noha E.; ELSEUOFI, Sherif; SHAMS, Mahmoud Y.. Soil Erosion Status Prediction Using a Novel Random Forest Model Optimized by Random Search Method. **Sustainability**, [S.L.], v. 15, n. 9, p. 7114, 24 abr. 2023. MDPI AG. <http://dx.doi.org/10.3390/su15097114>.

TIECHER, Tales; GATIBONI, Luke; SANTOS, Danilo Rheinheimer dos; BISSANI, Carlos Alberto; MARTINS, Amanda Posselt; GIANELLO, Clesio; DICK, Deborah Pinheiro; BORTOLUZZI, Edson Campanhola; ESCOSTEGUY, Pedro Alexandre Varella; SILVA, Leandro Souza da. Base saturation is an inadequate term for Soil Science. **Revista Brasileira de Ciência do Solo**, [S.L.], v. 46, p. 1-15, 2022. Revista Brasileira de Ciencia do Solo. <http://dx.doi.org/10.36783/18069657rbcs20220125>.

TIETJE, Olaf; HENNINGS, Volker. Accuracy of the saturated hydraulic conductivity prediction by pedo-transfer functions compared to the variability within FAO textural classes. **Geoderma**, [S.L.], v. 69, n. 1-2, p. 71-84, jan. 1996. Elsevier BV. [http://dx.doi.org/10.1016/0016-7061\(95\)00050-x](http://dx.doi.org/10.1016/0016-7061(95)00050-x).

TEAM, R. **Development Core. R**: A language and environment for statistical computing. (No Title), 2010. <https://www.gbif.org/tool/81287/r-a-language-and-environment-for-statistical-computing>.

TISDALL, J. M.; OADES, J. M.. Organic matter and water-stable aggregates in soils. **Journal Of Soil Science**, [S.L.], v. 33, n. 2, p. 141-163, jun. 1982. Wiley. <http://dx.doi.org/10.1111/j.1365-2389.1982.tb01755.x>.

TRANI, Paulo Espíndola, e outros. Hortaliças: recomendações de calagem e adubação para o Estado de São Paulo. Campinas, **CATI**, 2018. 88p. 28cm (Boletim Técnico, 251).

TSAI, Victor J. D.. Delaunay triangulations in TIN creation: an overview and a linear-time algorithm. **International Journal Of Geographical Information Systems**, [S.L.], v. 7, n. 6, p. 501-524, nov. 1993. Informa UK Limited. <http://dx.doi.org/10.1080/02693799308901979>.

VAN STRALEN, Karlijn J.; STEL, Vianda S.; REITSMA, Johannes B.; DEKKER, Friedo W.; ZOCCALI, Carmine; JAGER, Kitty J.. Diagnostic methods I: sensitivity, specificity, and other measures of accuracy. **Kidney International**, [S.L.], v. 75, n. 12, p. 1257-1263, jun. 2009. Elsevier BV. <http://dx.doi.org/10.1038/ki.2009.92>.

ILAR, Cesar Crispim; COSTA, Antonio Carlos Saraiva da; HOEPERS, Allan; SOUZA JUNIOR, Ivan Granemann de. Capacidade máxima de adsorção de fósforo relacionada a

formas de ferro e alumínio em solos subtropicais. **Revista Brasileira de Ciência do Solo**, [S.L.], v. 34, n. 4, p. 1059-1068, ago. 2010. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-06832010000400006>.

Wear, J.I., and Patterson, R.M. 1962. **Soil Sci. Soc. Am. Proc.** 26, 344-346

WEISS, M.; JACOB, F.; DUVEILLER, G.. Remote sensing for agricultural applications: a meta-review. **Remote Sensing Of Environment**, [S.L.], v. 236, p. 111402, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2019.111402>.

WEISS, S.M.; ZHANG, T. Performance analysis and evaluation. In: The handbook of Data Mining. Lawrence Erlbaum Associates Publishers, **Mahwah**, NJ, vol. 14, p. 425 – 440, 2003.

WESTFALL, James A.; PATTERSON, Paul L.; COULSTON, John W.. Post-stratified estimation: within-strata and total sample size recommendations. **Canadian Journal Of Forest Research**, [S.L.], v. 41, n. 5, p. 1130-1139, maio 2011. Canadian Science Publishing. <http://dx.doi.org/10.1139/x11-031>.

WILLIAMS, Hanna; COLOMBI, Tino; KELLER, Thomas. The influence of soil management on soil health: an on-farm study in southern sweden. **Geoderma**, [S.L.], v. 360, p. 114010, fev. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2019.114010>.

WISCHMEIER, Walter H.; SMITH, Dwight D. Rainfall energy and its relationship to soil loss. **Eos, Transactions American Geophysical Union**, [S.L.], v. 39, n. 2, p. 285-291, abr. 1958. American Geophysical Union (AGU). <http://dx.doi.org/10.1029/tr039i002p00285>.

XIAO; YANG; GUO, Bing; LU, Yuefeng; ZHANG, Rui; ZHANG, Dafu; ZHEN, Xiaoyan; CHEN, Shuting; WU, Hongwei; WEI, Cuixia. Spatial–temporal evolution patterns of soil erosion in the Yellow River Basin from 1990 to 2015: impacts of natural factors and land use change. **Geomatics, Natural Hazards And Risk**, [S.L.], v. 12, n. 1, p. 103-122, 24 dez. 2020. Informa UK Limited. <http://dx.doi.org/10.1080/19475705.2020.1861112>.

XIONG, Muqi; SUN, Ranhao; CHEN, Liding. Effects of soil conservation techniques on water erosion control: a global analysis. **Science Of The Total Environment**, [S.L.], v. 645, p. 753-760, dez. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.scitotenv.2018.07.124>.

YAMAMOTO, J. K. (1998) – A Review of Numerical Methods for the Interpolation of Geological Data: **Na. Acad. Bras. Ciências**, 70(1):91-116. <http://memoria.bn.br/DocReader/158119/35011>.

YAN, Bo; HOU, Ying. Effect of Soil Magnesium on Plants: a review. **Iop Conference Series: Earth and Environmental Science**, [S.L.], v. 170, p. 022168, jul. 2018. IOP Publishing. <http://dx.doi.org/10.1088/1755-1315/170/2/022168>.

YANG, Miaomiao; YANG, Qinke; ZHANG, Keli; WANG, Chunmei; PANG, Guowei; LI, Yuru. Effects of soil rock fragment content on the USLE-K factor estimating and its influencing factors. **International Soil And Water Conservation Research**, [S.L.], v. 11, n. 2, p. 263-275, jun. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.iswcr.2022.07.003>.

YANG, Mengyuan; ZHOU, Dongxian; HANG, Huixian; CHEN, Shuo; LIU, Hua; SU, Jikang; LV, Huilin; JIA, Huixin; ZHAO, Gengmao. Effects of Balancing Exchangeable Cations Ca, Mg, and K on the Growth of Tomato Seedlings (*Solanum lycopersicum* L.) Based on Increased Soil Cation Exchange Capacity. **Agronomy**, [S.L.], v. 14, n. 3, p. 629, 20 mar. 2024. MDPI AG. <http://dx.doi.org/10.3390/agronomy14030629>.

YANG, Zhongwei; ZHANG, Qian; JIANG, Yufeng; KONG, Weicheng; WANG, Wenjing; WU, Yingqin. Study on the Adsorption Process and Mechanism of Oxytetracycline in Different Loess: roles of soil characteristics and influencing factors. **Water, Air, & Soil Pollution**, [S.L.], v. 235, n. 7, p. 1, 12 jun. 2024. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11270-024-07240-z>.

YAO, Yao; LI, Guang; LU, Yanhua; LIU, Shuainan. Modelling the impact of climate change and tillage practices on soil CO₂ emissions from dry farmland in the Loess Plateau of China. **Ecological Modelling**, [S.L.], v. 478, p. 110276, abr. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.ecolmodel.2023.110276>.

YOSHIOKA, Maria Harumi; LIMA, M. R. Experimentoteca de solos: infiltração e retenção da água no solo. **Arquivos da APADEC**, Maringá, v. 8, n. 1, p. 63-66, 2004. http://www.gestaoescolar.diaadia.pr.gov.br/arquivos/File/solo_escola/experimentotecasolos8.pdf.

ZAABOUBI, Siham; KHIARI, Lotfi; ABDESSELAM, Salah; GALLICHAND, Jacques; KEBEDE, Fassil; KERRACHE, Ghouati. Particle Size Imbalance Index from Compositional Analysis to Evaluate Cereal Sustainability for Arid Soils in Eastern Algeria. **Agriculture**, [S.L.], v. 10, n. 7, p. 296, 14 jul. 2020. MDPI AG. <http://dx.doi.org/10.3390/agriculture10070296>.

ZHANG, Hankui K.; ROY, David P.. Using the 500 m MODIS land cover product to derive a consistent continental scale 30 m Landsat land cover classification. **Remote Sensing Of Environment**, [S.L.], v. 197, p. 15-34, ago. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.rse.2017.05.024>.

ZHANG, Jingcheng; HUANG, Yanbo; PU, Ruiliang; GONZALEZ-MORENO, Pablo; YUAN, Lin; WU, Kaihua; HUANG, Wenjiang. Monitoring plant diseases and pests through remote sensing technology: a review. **Computers And Electronics In Agriculture**, [S.L.], v. 165, p. 104943, out. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2019.104943>.

ZHANG, Naigian; WANG, Maohua; WANG, Ning. Precision agriculture—a worldwide overview. **Elétron. Agrícola**. 2002, 36, 113–132. [https://doi.org/10.1016/S0168-1699\(02\)00096-0](https://doi.org/10.1016/S0168-1699(02)00096-0)

ZHANG, Siwen; ZHU, Qichao; VRIES, Wim de; ROS, Gerard H.; CHEN, Xiaohui; MUNEEER, Muhammad Atif; ZHANG, Fusuo; WU, Liangquang. Effects of soil amendments on soil acidity and crop yields in acidic soils: a world-wide meta-analysis. **Journal Of Environmental Management**, [S.L.], v. 345, p. 118531, nov. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.jenvman.2023.118531>.

ZHENG, Z.; PARENT, L. E.; MACLEOD, J. A.. Influence of soil texture on fertilizer and soil phosphorus transformations in Gleysolic soils. **Canadian Journal Of Soil Science**,

[S.L.], v. 83, n. 4, p. 395-403, 1 ago. 2003. Canadian Science Publishing.
<http://dx.doi.org/10.4141/s02-073>.

ZHU, Yuanyuan; WANG, Ziwei; ZHU, Xiaohua. New reflections on food security and land use strategies based on the evolution of Chinese dietary patterns. **Land Use Policy**, [S.L.], v. 126, p. 106520, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.landusepol.2022.106520>.

ZUDE-SASSE, M.; FOUNTAS, S.; GEMTOS, T.A.; ABU-KHALAF, N.. Applications of precision agriculture in horticultural crops. **European Journal Of Horticultural Science**, [S.L.], v. 81, n. 2, p. 78-90, 20 abr. 2016. International Society for Horticultural Science (ISHS). <http://dx.doi.org/10.17660/ejhs.2016/81.2.2>.

ZULUAGA, Monica Yorlady Alzate; CARDARELLI, Mariateresa; ROUPHAEL, Youssef; CESCO, Stefano; PII, Youry; COLLA, Giuseppe. Iron nutrition in agriculture: from synthetic chelates to biochelates. **Scientia Horticulturae**, [S.L.], v. 312, p. 111833, mar. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.scienta.2023.111833>.