



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Agrícola

JOÃO PAULO DA SILVA

**MODELO DE CARACTERIZAÇÃO DA DEGRADAÇÃO DE PASTAGENS
BASEADO EM DADOS DE FERTILIDADE DO SOLO E DE SENSORIAMENTO
REMOTO**

**PASTURE DEGRADATION CHARACTERIZATION MODEL BASED ON
FERTILITY AND REMOTE SENSING DATA**

CAMPINAS

2024

JOÃO PAULO DA SILVA

**MODELO DE CARACTERIZAÇÃO DA DEGRADAÇÃO DE PASTAGENS
BASEADO EM DADOS DE FERTILIDADE DO SOLO E DE SENSORIAMENTO
REMOTO**

Tese apresentada à Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Agrícola, na Área de Agricultura Digital.

Orientador: Dr. Jurandir Zullo Junior.
Coorientadora: Dr^a. Luciana Alvim Santos Romani

ESTE TRABALHO CORRESPONDE À
VERSÃO FINAL DA TESE DEFENDIDA
PELO ALUNO JOÃO PAULO DA SILVA,
E ORIENTADA PELO PROF. DR.
JURANDIR ZULLO JUNIOR.

CAMPINAS

2024

FICHA CATALOGRÁFICA

Ficha catalográfica
Universidade Estadual de Campinas (UNICAMP)
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

Si38m Silva, João Paulo da, 1991-
Modelo de caracterização da degradação de pastagens baseado em dados de fertilidade do solo e de sensoriamento remoto / João Paulo da Silva. – Campinas, SP : [s.n.], 2024.

Orientador: Jurandir Zullo Junior.
Coorientador: Luciana Alvim Santos Romani.
Tese (doutorado) – Universidade Estadual de Campinas (UNICAMP), Faculdade de Engenharia Agrícola.

1. Sensoriamento remoto. 2. Radar de abertura sintética. 3. Aprendizado de máquina. 4. Clima. 5. Solos. I. Zullo Junior, Jurandir, 1963-. II. Romani, Luciana Alvim Santos. III. Universidade Estadual de Campinas (UNICAMP). Faculdade de Engenharia Agrícola. IV. Título.

Informações Complementares

Título em outro idioma: Pasture degradation characterization model based on fertility and remote sensing data

Palavras-chave em inglês:

Remote sensing

Synthetic aperture radar

Machine learning

Climate

Soils

Área de concentração: Agricultura Digital

Titulação: Doutor em Engenharia Agrícola

Banca examinadora:

Jurandir Zullo Junior [Orientador]

José Teixeira Filho

Renata Ribeiro do Valle Gonçalves

Glaucia Miranda Ramirez

Edson Eyji Sano

Data de defesa: 23-08-2024

Programa de Pós-Graduação: Engenharia Agrícola

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0002-0695-9111>

- Currículo Lattes do autor: <https://lattes.cnpq.br/5431196146146601>

FOLHA DE APROVAÇÃO

Este exemplar corresponde à redação final da Tese de Doutorado defendida por João Paulo da Silva, aprovada pela Comissão Julgadora em 23 de agosto de 2024, na Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas.

Prof. Dr. Jurandir Zullo Junior – Presidente e Orientador

Prof. Dr. José Teixeira Filho – Membro Titular

Dr^a. Renata Ribeiro do Valle Gonçalves – Membro Titular

Prof^a. Dr^a. Glaucia Miranda Ramirez – Membro Titular

Dr. Edson Eyji Sano – Membro Titular

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

DEDICATÓRIA

A Deus,
Aos meus pais, Iria e Antônio (*in memoriam*),
À minha esposa, Amanda,
Aos amigos fiéis,
À Sociedade Brasileira,
dedico.

AGRADECIMENTOS

Em primeiro lugar a Deus, que me permitiu o dom da vida e a resiliência necessária para superar os inúmeros obstáculos enfrentados durante a execução deste trabalho.

A toda a minha família, por sempre acreditarem em mim e por não me deixarem esmorecer nos momentos mais desafiadores. A minha mãe e meu pai, pelo esforço e abdicção para que eu pudesse estudar. Só depois de adulto entendi a dadiva de ter vocês como pais. À Amanda, minha esposa amada que decidiu compartilhar comigo essa aventura chamada vida, tudo é mais leve e bonito ao seu lado. A todos vocês, espero um dia ser digno do seu perdão pela minha ausência constante.

Aos meus orientadores, Prof. Dr. Jurandir Zullo Junior e Dr^a. Luciana Alvim Santos Romani, nenhum passo teria sido dado sem o incentivo, direcionamento, paciência e amizade durante o mestrado e agora durante o doutorado. Além da competência técnica, vocês são exemplos do tipo de ser humano que pretendo me tornar um dia.

À Profa. Dr^a. Maria Leonor Ribeiro Casimiro Lopes Assad, a grande responsável por plantar a semente que frutificou nesta tese quando me abriu as portas e me incentivou a experimentar um estágio na Embrapa, e ao Dr. Eduardo Delgado Assad, por todas as oportunidades ao longo dos anos e por me ensinar os caminhos a serem percorridos na busca por uma agricultura sustentável aliada a um meio ambiente saudável. A perspectiva de toda a minha vida foi transformada quando vocês me estenderam a mão.

À toda a equipe do Cepagri/Unicamp pelo suporte ao longo desses anos em que me permitiram um local para desenvolver minhas atividades acadêmicas e, não menos importante, a amizade e palavras de conforto nos momentos desafiadores. Meu agradecimento especial à Dr^a. Renata Ribeiro do Valle Gonçalves e à Dr^a. Priscila Pereira Coltri por sempre me oferecerem ajuda, me incluírem em projetos e, principalmente, por acreditarem em mim e me transmitirem palavras encorajadoras. Agradeço também às ex-servidoras Solange Kahl, pelos ensinamentos sobre a vida, Edilene Carneiro, por me ensinar a fazer café (para mim foi muito importante) e ao servidor Claudir Rodrigues Cruz, pelo bom humor de sempre que mudou a minha forma de encarar a luta diária.

À equipe da Coordenadoria de Pós-Graduação (CPG) da Feagri/Unicamp, em especial à Valéria Altmann Ferreira e aos ex-servidores Cláudio e Ritinha por toda a paciência

que tiveram em me ajudar com documentos, prazos e solução de problemas. Eu reconheço as dores de cabeça que causei e peço desculpas por tudo.

Aos amigos de Leme-SP, que torceram por mim durante o período de execução da tese. Aos amigos do CCA/UFSCar (Araras-SP), com quem mantenho os laços vivos e que fazem parte dessa jornada. Aos meus amigos da República Só-k-bota, com quem convivi e onde foi minha casa durante a graduação. Aos amigos da república Zero71, que me acolheram em Campinas-SP e com os quais dividi tantos momentos importantes ao longo dessa jornada. À Vanessa Pugliero, que esteve comigo em tantos e desafiadores projetos e se tornou uma amiga especial.

As professoras, professores e colegas de sala que me acompanharam ao longo de toda a vida, desde a Creche Sagrada Família (Leme-SP), passando pelo Sesi-208 (Leme-SP), ETEC Dep. Salim Sedeh (Leme-SP), CCA/UFSCar (Araras-SP) e por fim na Universidade Estadual de Campinas. A educação é uma ferramenta que transforma e liberta.

As “Marias” e aos “Josés” de todo o Brasil que sofrem com os pesados impostos que lhes são cobrados para financiar um Estado que quase sempre retribui de forma indevida. Vocês ajudaram a financiar minha educação quase integralmente e a vocês eu dedico e dedicarei cada dia do meu trabalho na busca por um país melhor e na esperança de um dia poder me sentir satisfeito em ter retribuído, ainda que minimamente, o privilégio que a sociedade brasileira me deu. Reconheço ainda haver muito a ser feito.

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

EPÍGRAFE

“Não há caminho, o caminho se faz ao caminhar”

Antonio Machado (26/07/1875 – 22/02/1939)

RESUMO

Melhorias nas tecnologias de produção e estratégia de manejo potencializaram a lotação dos pastos brasileiros. Entretanto, estudos mostram que grande parte deles ainda se encontra sob degradação e subaproveitados. Assim, diagnosticar a degradação é importante, e informações de análises de solo e dados remotos ajudam a atingir este objetivo. Resultados de análise de solo, se analisadas de forma integrada, também podem favorecer a relação entre agropecuaristas, prestadores de serviços e fornecedores de insumos. No caso dos dados remotos, o monitoramento de pastagens utilizando sistemas de Radar de Abertura Sintética (SAR) ainda é um desafio que precisa ser mais explorado, inclusive utilizando técnicas de aprendizado de máquina. Os objetivos deste trabalho envolvem: (i) investigar se o perfil de fertilidade do solo, como indutor de degradação, permite distinguir as condições da pastagem de outros sistemas de uso da terra; e (ii) testar se parâmetros relacionados à penalização da produtividade, como indicadores de degradação, podem ser extraídos de dados remotos obtidos por tecnologia SAR. Para isso, (i) foram aplicadas técnicas de análise multivariada em análises de solo e (ii) construídos modelos preditivos para classificação do padrão de desenvolvimento e penalização da produtividade em áreas de pastagem com base na produtividade sazonal no período de máximo desenvolvimento e disponibilidade hídrica, com ambas as abordagens concentradas principalmente nos biomas Cerrado e Mata Atlântica. No caso da penalização da produtividade, a distinção entre as áreas amostrais foi analisada segundo o balanço hídrico climatológico, que condiciona seu potencial produtivo, e conforme o desenvolvimento observado utilizando índices de vegetação. Os modelos preditivos utilizam o Vetor de Stokes, um produto polarimétrico e coerente de imagens SAR que permite inferir sobre as condições dielétricas e estruturais do alvo. Os resultados mostram Perfis de Fertilidade do Solo (PFS) definidos pelas características de fertilidade e acidez. Na comparação estratificada dos PFS por sistema de uso da terra, diferenças na acidez entre pastagem e vegetação nativa concentram-se nas camadas superficiais de solos arenosos. Na comparação entre grupos texturais, diferenças na fertilidade acentuam-se na camada superficial, enquanto para acidez essas diferenças concentram-se em camadas mais profundas. Na comparação geral, a maior heterogeneidade na fertilidade da camada 20-30cm de solos arenosos mostra que a amostragem de solo deve ser mais detalhada nesse perfil para evitar sub ou superdimensionamento da adubação. Os sistemas de produção pecuária (SPP) dos municípios de Goiás e Mato Grosso do Sul têm a maior ocupação relativa por pasto, enquanto os de Mato Grosso têm a maior área absoluta sob pasto e menor lotação, e os de São Paulo apresentam as maiores taxas de lotação e maior acesso à orientação técnica, especialmente de cooperativas. O potencial da pecuária a pasto nessa região

é muito dependente das condições climáticas, e efeitos da estiagem colocam em risco cerca de 25% do rebanho nacional. Na região estudada há entre 30% e 60% de quebra na produtividade potencial, e modelos preditivos baseados em *Random Forest* (RF) conseguiram atingir acurácia de até 94% na detecção dessa penalização utilizando parâmetros polarimétricos extraídos de dados SAR.

Sensoriamento remoto; Radar de abertura sintética; Aprendizado de máquina; Clima; Solos

ABSTRACT

Improvements in production technologies and management strategies have increased the stocking capacity of Brazilian pastures. However, studies show that a large part of them is still degraded and underutilized. Therefore, diagnosing degradation is important, and information from soil analysis and remote data help to achieve this goal. Soil analysis results, if analyzed in an integrated manner, can also favor the relationship between farmers, service providers and input suppliers. In the case of remote data, monitoring pastures using Synthetic Aperture Radar (SAR) systems is still a challenge that needs to be further explored, including using machine learning techniques. The objectives of this work involve: (i) investigating whether the soil fertility profile, as an inducer of degradation, allows distinguishing pasture conditions from other land use systems; and (ii) testing whether parameters related to productivity penalties, such as degradation indicators, can be extracted from remote data obtained by SAR technology. For this purpose, (i) multivariate analysis techniques were applied to soil analyses and (ii) predictive models were constructed to classify the development pattern and productivity penalty in pasture areas based on seasonal productivity during the period of maximum development and water availability, with both approaches focusing mainly on the Cerrado and Atlantic Forest biomes. In the case of productivity penalty, the distinction between sample areas was analyzed according to the climatological water balance, which determines their productive potential, and according to the observed development using vegetation indices. The predictive models use the Stokes Vector, a polarimetric and coherent product of SAR images that allows inferences about the dielectric and structural conditions of the target. The results show Soil Fertility Profiles (SFP) defined by fertility and acidity characteristics. In the stratified comparison of SFP by land use system, differences in acidity between pasture and native vegetation are concentrated in the surface layers of sandy soils. In the comparison between textural groups, differences in fertility are more pronounced in the surface layer, while for acidity these differences are concentrated in deeper layers. In the general comparison, the greater heterogeneity in fertility in the 20-30 cm layer of sandy soils shows that soil sampling should be more detailed in this profile to avoid under- or over-fertilization. The livestock production systems (LPS) of the municipalities of Goiás and Mato Grosso do Sul have the highest relative pasture occupancy, while those of Mato Grosso have the largest absolute area under pasture and the lowest stocking rate, and those of São Paulo have the highest stocking rates and the greatest access to technical guidance, especially from cooperatives. The potential for pasture-based livestock farming in this region is highly dependent on climate conditions, and the effects of drought put approximately 25% of the national herd at risk. In the region studied, there is between 30% and 60% drop in

potential productivity, and predictive models based on Random Forest (RF) managed to achieve accuracy of up to 94% in detecting this penalty using polarimetric parameters extracted from SAR data.

Remote sensing; Synthetic aperture radar; Machine learning; Climate; Soils

LISTA DE ILUSTRAÇÕES

Figura 1 — Fluxograma geral do desenvolvimento do trabalho.	41
Figura 2 — Distribuição espacial amostral das áreas de pastagem (P), sistema integrado (SI) e vegetação nativa (VN). As classes de solos mostradas são apenas aquelas com intersecção com os solos dos locais de amostragem. Alguns símbolos podem estar sobrepostos devido à proximidade entre os pontos amostrais.	43
Figura 3 — Delineamento do experimento sobre o impacto do nível de degradação da pastagem. Os itens em azul são etapas intermediárias tratadas com maior detalhamento no decorrer do texto.	47
Figura 4 — Distribuição dos polígonos das áreas de pastagem (LAPIG, 2023) ao longo da área de estudo.	48
Figura 5 — Redução relativa da inércia em função do número de <i>clusters</i> (SPP) gerados. A coluna destacada representa a redução da inércia para o número de <i>KSP</i> assumido para as etapas subsequentes.	51
Figura 6 — Seleção aleatória de áreas representativas dos SPP. O nome atribuído a cada célula corresponde ao nome do município com maior sobreposição.	56
Figura 7 — Parâmetros sazonais extraídos da ferramenta Timesat referentes ao (a) início (data e valor), (b) fim (data e valor), (c) duração (meses), (d) valor base, (e) data do ponto de produtividade máxima, (f) valor máximo, (g) amplitude (entre os pontos de base [d] e máximo [f]), (h) produção acumulada a partir da base e (i) produção acumulada total.	59
Figura 8 — Fluxograma de processamento das imagens SAR para gerar as variáveis empregadas na construção do modelo preditivo. Os nomes das etapas de processamento estão em inglês para facilitar a localização destas no menu de opções da ferramenta SNAP. As etapas destacadas em azul estão descritas com maior detalhamento a seguir.	61
Figura 9 — Geração do mosqueamento (<i>speckle</i>) pela interferência de vários alvos dentro da célula de resolução retroespalhando o sinal incidente.	64
Figura 10 — Fluxograma do modelo de classificação dos dados SAR para a penalização da produtividade potencial das pastagens.	69
Figura 11 — Hiperplano de separabilidade entre as classes.	75

Figura 12 — Distribuição dos PFS no plano das CPs retidas. As setas e eixos em vermelho representam os atributos da análise de solo e sua importância na constituição de cada CP.81

Figura 13 — Comparação do sistema de uso da terra (Pastagem – P, Sistema Integrado – SI e Vegetação Nativa – VN) segmentado por profundidade amostral e agrupado pela textura. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo textural.....82

Figura 14 — Comparação do grupo textural segmentado por sistema de uso da terra e agrupado pela profundidade amostral. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo de profundidade amostral.83

Figura 15 — Comparação da profundidade amostral segmentada por sistema de uso da terra e agrupada por grupo textural. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo textural.....84

Figura 16 — Distribuição das diferenças significativas para cada sistema de uso da terra (Pastagem, Sistema Integrado e Vegetação Nativa), grupo textural e profundidade amostral das dimensões de fertilidade e acidez do solo.87

Figura 17 — Espacialização (i) dos Sistemas Produtivos Pecuários (SPP) obtidos por análise de agrupamento e (ii) dos municípios considerados *outliers*. Municípios vizinhos pertencentes a um mesmo SPP tiveram sua área dissolvida.....90

Figura 18 — Distribuição proporcional dos atributos dos Sistemas Produtivos Pecuários (SPP) na composição dos estados.91

Figura 19 — Valores médios dos atributos de cada Sistema Produtivo Pecuário (SPP). As linhas verticais em vermelho representam o desvio padrão de cada atributo em torno do centroide.93

Figura 20 — Parcela de produtores rurais que dispõe de alguma área de pastagem por município, que declararam receber algum tipo de orientação técnica.94

Figura 21 — Séries temporais dos modelos de produtividade observada (*NDVI*) e potencial (grupos U1 e C1) com escala temporal de 16 dias e seus coeficientes de correlação (*r*). As cores indicam o SPP dos pontos amostrados.98

Figura 22 — Frequência da temperatura mínima mensal média (1986-2015) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 99

Figura 23 — Frequência da soma da precipitação mensal média (1986-2015) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 100

Figura 24 — Frequência da def. hídrica mensal (*DEFcad50*) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 101

Figura 25 — Frequência da def. hídrica mensal (*DEFcad125*) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 102

Figura 26 — Frequência do arm. de água mensal (*ARMcad50*) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 103

Figura 27 — Frequência do arm. de água mensal (*ARMcad125*) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente. 104

Figura 28 — Variáveis meteorológicas e parâmetros resultantes do balanço hídrico (THORNTHWAITE e MATHER, 1955), para a região estudada, entre 1986 e 2015. As cores das amostras representam os Sistemas Produtivos Pecuários (SPP) descritos previamente. . 106

Figura 29 — Relação entre os parâmetros climáticos (1986-2015) e a produção acumulada observada de matéria seca. As linhas vermelhas são os autovetores das Componentes Principais e os valores no título dos eixos representam a variância explicada por cada CP. 108

Figura 30 — Distribuição das condições climatológicas nos SPP. As linhas brancas representam a posição mediana.	108
Figura 31 — Acurácia geral dos diferentes modelos de classificação sobre as amostras dos SPP.....	115
Figura 32 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando todas as classes geradas a partir dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1).	116
Figura 33 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando todas as classes geradas a partir dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1).	117
Figura 34 — Distribuição das áreas de pastagem classificadas pela análise de agrupamento para o município de Tesouro-MT, representando o grupo genotípico U1.	120
Figura 35 — Distribuição das áreas de pastagem classificadas pela análise de agrupamento para o município de Porto Murtinho-MS, representando o grupo genotípico C1.	120
Figura 36 — Acurácia geral da classificação excluindo as classes de distribuição local marginal nas áreas de pastagem utilizando o algoritmo <i>Random Forest</i> sobre as amostras dos SPP.....	121
Figura 37 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando apenas as classes com melhor desempenho prévio geradas a partir dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo genotípico U1).	122
Figura 38 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando apenas as classes com melhor desempenho prévio geradas a partir dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo genotípico C1).	123
Figura 39 — Importância dos parâmetros polarimétricos no desempenho do modelo pelo Decréscimo Médio da Impureza (<i>DMI</i>) para o grupo genotípico U1. Os parâmetros representam o sinal retornado à antena e representam o vetor de Stokes (g_0 - g_3), os graus de polarização (<i>GP</i>), de depolarização (<i>GD</i>), de elipticidade (ϵ), a elevação (<i>Elev</i>), a razão de polarização circular (<i>RPC</i>) e o ângulo de incidência local (θ).....	126

Figura 40 — Importância dos parâmetros polarimétricos no desempenho do modelo pelo Decréscimo Médio da Impureza (<i>DMI</i>) para o grupo genotípico C1. Os parâmetros representam o sinal retornado à antena e representam o vetor de Stokes (g_0 - g_3), os graus de polarização (<i>GP</i>), de depolarização (<i>GD</i>), de elipticidade (ϵ), a elevação (<i>Elev</i>), a razão de polarização circular (<i>RPC</i>) e o ângulo de incidência local (θ).....	127
Figura 41 — Composição RGB do sinal retroespalhado pelos parâmetros do vetor de Stokes (g_0 , g_1 , g_2) com maior relevância no desempenho da classificação pelo algoritmo RF.	128
Figura 42 — Amostras de municípios e sua área total, em mil hectares, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).....	170
Figura 43 — Amostras de municípios e sua área total de pastagem, em mil hectares, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).....	171
Figura 44 — Amostras de municípios e seu rebanho bovino médio, em mil cabeças, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).....	172
Figura 45 — Amostras de municípios e sua ocupação relativa por pastagem, em porcentagem, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).	173
Figura 46 — Amostras de municípios e sua taxa de lotação, em cabeças/hectare, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).....	174
Figura 47 — Distribuição da produção sazonal acumulada estimada pelo modelo de produtividade observada no período 2015-2016. A linha vermelha indica a posição do valor médio na região amostral.....	176
Figura 48 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Ponta-Porã-MS.	177
Figura 49 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Ponta-Porã-MS.....	178
Figura 50 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Tesouro-MS.	179
Figura 51 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Tesouro-MT.	180

Figura 52 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Avaré-SP.....	181
Figura 53 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Avaré-SP.....	182
Figura 54 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Água Fria de Goiás-GO.	183
Figura 55 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Água Fria de Goiás-GO.	184
Figura 56 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Itaporã-MS.....	185
Figura 57 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Itaporã-MS.....	186
Figura 58 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Rio Verde-GO.....	187
Figura 59 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Rio Verde-GO.....	188
Figura 60 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Birigui-SP.	189
Figura 61 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Birigui-SP.	190
Figura 62 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os <i>clusters</i> para a região de Campo Novo do Parecis-MT.	191
Figura 63 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os <i>clusters</i> para a região de Campo Novo do Parecis-MT.	192

Figura 64 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Rondonópolis-MT.....	193
Figura 65 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Rondonópolis-MT.....	194
Figura 66 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Naviraí-MS.	195
Figura 67 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Naviraí-MS.	196
Figura 68 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Crixás-GO.....	197
Figura 69 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Crixás-GO.	198
Figura 70 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Piracanjuba-GO.	199
Figura 71 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Piracanjuba-GO.....	200
Figura 72 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Campo Grande-MS.....	201
Figura 73 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Campo Grande-MS.	202
Figura 74 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Canarana-MT.....	203
Figura 75 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Canarana-MT.	204
Figura 76 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Serranópolis-GO.....	205
Figura 77 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Serranópolis-GO.	206

Figura 78 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Porto Murtinho-MS.....	207
Figura 79 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Porto Murtinho-MS.....	208
Figura 80 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Alcinópolis-MS.....	209
Figura 81 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Alcinópolis-MS.....	210
Figura 82 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Montes Claros de Goiás-GO.	211
Figura 83 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Montes Claros de Goiás-GO.	212
Figura 84 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Aparecida do Taboado-MS.	213
Figura 85 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Aparecida do Taboado-MS.	214
Figura 86 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo U1) que configuram os clusters para a região de Porangatu-GO.	215
Figura 87 — Parâmetros sazonais dos modelos de produtividade observada (<i>NDVI</i>) e potencial (grupo C1) que configuram os clusters para a região de Porangatu-GO.	216

LISTA DE TABELAS

Tabela 1 — Resumo descritivo da área de pastagem e do rebanho bovino por estado e para todo o Brasil. Os valores por estado são um recorte, em escala de município, da área de abrangência desse trabalho que excluiu os municípios dos biomas Amazônia (MT) e Pantanal (MS).....	49
Tabela 2 — Configurações originais dos conjuntos de dados utilizados nos modelos de balanço hídrico e de produtividade.....	55
Tabela 3 — Descrição geral da plataforma e do instrumento (antena) SAR de envio e recebimento de sinal.	62
Tabela 4 — Número de pontos das amostras empregadas na construção dos modelos preditivos dos grupos de pastagem referentes ao genótipo U1.....	71
Tabela 5 — Número de pontos das amostras empregadas na construção dos modelos preditivos dos grupos de pastagem referentes ao genótipo C1.....	72
Tabela 6. Constituição das CPs retidas por cada atributo de análise do solo. Os valores entre parênteses representam a quantidade de variância contabilizada por cada um...	80
Tabela 7 — Parcela dos produtores rurais que declararam receber cada categoria de orientação técnica, por SPP.	95
Tabela 8 — Parcela dos produtores rurais que declararam receber cada categoria de orientação técnica, por estado.....	95
Tabela 9 — Distribuição da diferença relativa entre os modelos de produtividade observada e potencial (<i>PRP</i>) para o grupo U1. As colunas representam os percentuais encontrados nas posições de mínimo (Mín.), de 25% (Q1), da mediana (Q2), de 75% (Q3), máximo (Máx.) e o desvio padrão (D.P.).	111
Tabela 10 — Distribuição percentual da diferença relativa entre os modelos de produtividade observada e potencial (<i>PRP</i>) para o grupo C1. As colunas representam os percentuais encontrados nas posições de mínimo (Mín.), de 25% (Q1), da mediana (Q2), de 75% (Q3), máximo (Máx.) e o desvio padrão (D.P.).	112
Tabela 11 — Valores médios dos atributos químicos e físicos resultantes de análise de solo estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais	

(GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).....	158
--	-----

Tabela 12 — Desvio padrão dos atributos químicos e físicos resultantes de análise de solo estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais (GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).....	161
--	-----

Tabela 13 — Média e desvio padrão dos indicadores de fertilidade e acidez extraídos do modelo PCA estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais (GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).	164
---	-----

Tabela 14 — Parâmetros de configuração da ferramenta Timesat para configuração do modelo sazonal extraído das séries temporais de produtividade.....	168
--	-----

Tabela 15 — Descrição do conjunto de municípios classificados como <i>outliers</i> no escopo deste trabalho.....	169
--	-----

Tabela 16 — Área de pastagem total, em 2015, por Sistema Produtivo Pecuário (SPP) e por estado (UF).....	175
--	-----

Tabela 17 — Rebanho bovino médio, entre 2015 e 2018, por Sistema Produtivo Pecuário (SPP) e por estado (UF).....	175
--	-----

LISTA DE ABREVIATURAS E SIGLAS

PCA	<i>Principal Components Analysis</i> (Análise de Componentes Principais)
ANA	Agência Nacional de Águas
C1	Grupo genotípico <i>Cynodon</i> spp. (cvs. Tifton-85 e Estrela)
Cepagri	Centro de Pesquisas Climáticas e Meteorológicas Aplicadas à Agricultura
CP	Componente Principal
DEM	<i>Digital Elevation Model</i> (Modelo digital de elevação)
DETER	Sistema de Detecção do Desmatamento em Tempo Real na Amazônia
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
GEE	Gases de Efeito Estufa
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
IW	<i>Interferometric Wide Swath</i>
kNN	<i>k-Nearest Neighbor</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSI	<i>MultiSpectral Instrument</i>
Nasa	<i>National Aeronautics and Space Administration</i>
NB	<i>Naive Bayes</i>
OLI	<i>Operational Land Imager</i>
PDP	Perfis de Degradação de áreas de Pastagem
PFS	Perfil de Fertilidade do Solo
Plano ABC	Plano Setorial de Mitigação e Adaptação às Mudanças Climáticas para a Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura
PNMC	Política Nacional sobre Mudança do Clima
Power	<i>Prediction of Worldwide Energy Resources</i>

PPCDAm	Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal
PPCerrado	Plano de Ação para a Prevenção e Controle do Desmatamento e das Queimadas no Cerrado
PRODES	Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite
RF	<i>Random Forest</i>
SAR	<i>Synthetic Apperture Radar</i> (Radar de Abertura Sintética)
SLC	<i>Single Look Complex</i>
SNAP	<i>Sentinel Application Platform</i>
SPP	Sistema Produtivo Pecuário
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	<i>Support Vector Machine</i>
TM	<i>Thematic Mapper</i>
U1	Grupo genotípico <i>Urochloa</i> spp. (cvs. Marandu, Basilisk e Arapoty)
UA	Unidade Animal
Unicamp	Universidade Estadual de Campinas
VH	Emissão vertical e Recepção horizontal da polarização da onda eletromagnética
VV	Emissão vertical e Recepção vertical da polarização da onda eletromagnética

SUMÁRIO

1 INTRODUÇÃO	27
2 REVISÃO BIBLIOGRÁFICA	29
2.1 DEGRADAÇÃO DE PASTAGENS E O PANORAMA DA PECUÁRIA BRASILEIRA	29
2.2 MANEJO DA FERTILIDADE DOS SOLOS SOB PASTAGEM	31
2.3 MODELAGEM E MONITORAMENTO DE PASTAGENS	32
2.3.1 Modelagem agrometeorológica	33
2.3.2 Sensoriamento remoto utilizando sensores óticos.....	35
2.3.3 Sensoriamento remoto por Radar de Abertura Sintética	36
2.3.4 Aprendizado de Máquina aplicada no monitoramento de pastagens com dados remotos	38
3 MATERIAL E MÉTODOS	41
3.1 CARACTERIZAÇÃO DA FERTILIDADE DAS PASTAGENS BRASILEIRAS	41
3.1.1 Área de estudo e design da amostragem do solo	41
3.1.2 Caracterização do Perfil de Fertilidade do Solo (PFS).....	45
3.1.3 Heterogeneidade dos perfis de fertilidade	46
3.2 AVALIAÇÃO DO IMPACTO DA DEGRADAÇÃO NO POTENCIAL PRODUTIVO NAS PASTAGENS	47
3.2.1 Área e período de estudo	48
3.2.2 Segmentação dos Sistemas Produtivos Pecuários (SPP).....	49
3.2.3 Estimativa de produtividade das pastagens e modelagem do clima regional....	52
3.2.4 Modelagem sazonal e elaboração do conjunto de dados de referência.....	58
3.2.5 Preparação do conjunto de dados de Radar de Abertura Sintética (SAR)	60
3.2.6 Modelagem preditiva de penalização da produtividade	68
4 RESULTADOS E DISCUSSÃO	79
4.1 CARACTERIZAÇÃO DA FERTILIDADE DAS PASTAGENS BRASILEIRAS	79
4.1.1 Caracterização dimensional do perfil de fertilidade em áreas de pastagens	79
4.1.2 Heterogeneidade dos perfis de fertilidade	86

4.2 IMPACTO DA DEGRADAÇÃO NA PRODUTIVIDADE POTENCIAL	89
4.2.1 Segmentação de Sistemas Produtivos Pecuários (SPP) baseados em pecuária extensiva	89
4.2.2 Estimativa de produtividade das pastagens e modelagem do clima regional....	96
4.2.3 Penalização da produtividade potencial utilizando dados de Radar de Abertura Sintética (SAR).....	109
5 CONCLUSÕES.....	132
REFERÊNCIAS BIBLIOGRÁFICAS	135
APÊNDICES	158
APÊNDICE 1 — “Estatística descritiva dos resultados das análises de solo estratificadas por uso da terra, grupo textural e profundidade”	158
APÊNDICE 2 — “Estatística descritiva dos resultados das análises de solo estratificadas por uso da terra, grupo textural e profundidade transformados em índices de fertilidade e acidez”	164
APÊNDICE 3 — “Parametrização do modelo sazonal das séries temporais de produtividade na ferramenta Timesat”	168
APÊNDICE 4 — “Estatística descritiva das características de uso da terra e rebanho dos municípios não incorporados (<i>outliers</i>) na análise de agrupamento de sistemas produtivos”	169
APÊNDICE 5 — “Espacialização, em escala de município, dos indicadores máximos e mínimos das propriedades territoriais e de rebanho bovino por sistema produtivo pecuário”	170
APÊNDICE 6 — “Agregados dos atributos dos Sistemas Produtivos Pecuários (SPP) em relação aos estados.”	175
APÊNDICE 7 — “Média espacial da produção de matéria seca por amostra e por SPP.”	176
APÊNDICE 8 — “Parâmetros sazonais dos modelos de produtividade observada e potencial.”	177

1 INTRODUÇÃO

Os desafios impostos para a sociedade atual, no contexto global, interseccionam (i) produção e fornecimento de alimentos suficientes para uma população em crescimento, (ii) o agravamento das mudanças climáticas que vem degradando o ecossistema global; e (iii) disputas geopolíticas que retomam tensões militares em nível semelhante à da Guerra Fria. Na base, os efeitos sobre os pilares social, ambiental e político tanto serão influenciados quanto influenciarão o sistema produtivo global, setor no qual o Brasil exerce liderança, emergindo questões acerca da sua eficiência e sustentabilidade em atender às demandas atual e projetada, e aliando proteção e recuperação de ambientes naturais com incremento vertical da produção (DELABY et al., 2020; MACIEL et al, 2020). No caso da pecuária, o objetivo maior é a transição de um sistema extensivo e ambientalmente ineficiente (GIANETTI e FERREIRA FILHO, 2024), para sistemas mais intensificados (REIS et al., 2021), transição que passa pelo manejo das pastagens que precisam ter sua condição de conservação conhecida e aperfeiçoada por meio de modelos de análise mais robustos, como os baseados na utilização de dados remotos por algoritmos de aprendizado de máquina e sistemas de inteligência artificial.

O sistema pecuário mundial se baseia na criação de gado bovino à pasto (RITCHIE et al., 2019). O Brasil também segue este padrão, e essa preferência se dá, entre outras razões: (i) pela grande extensão de suas áreas, com cerca de 160 milhões de hectares entre pastagens naturais e plantadas (IBGE, 2017); e (ii) aptidão climática para o seu cultivo, que favorecem o uso desse sistema e contribuem para que o país apresente um dos menores custos de produção do mundo quando comparado a países que adotam o sistema de confinamento (FERRAZ e FELÍCIO, 2010; DEBLITZ, 2012). Entre 1975 e 2017, data do último Censo Agropecuário realizado no Brasil, a área coberta por pastagens apresentou redução de 3%. Contudo, esforços para intensificar a produção possibilitaram um aumento de 116% na taxa de lotação média, passando de 0,62 cabeças/hectare para 1,34 cabeças/hectare (IBGE, 2017; IBGE, 2024). O adensamento da taxa de lotação das pastagens aliado a pressões por melhores práticas de produção e proteção dos recursos naturais vem despertando a consciência dos produtores para temas relacionados à eficiência produtiva (DIAS-FILHO, 2014). No entanto, estes indicadores ainda são baixos quando comparados a sistemas que recebem manejo intensificado e chegam a suportar até 2,5UA/hectare (Unidade Animal/hectare; 1UA = 500kg de peso vivo, segundo Allen et al., 2011) (DIAS-FILHO, 2010), o que mostra que ainda há espaço para aprimoramento da atividade pecuária no Brasil, cuja participação na produção mundial é de 13%, atrás apenas de Estados Unidos (17%) e da Europa (15%) (MEAT & LIVESTOCK AUSTRALIA, 2020).

Hipótese

Parâmetros biofísicos de pastagens, obtidos por dados de sensores remotos ativos, e de fertilidade do solo podem ser empregados na caracterização do seu nível de degradação a partir de técnicas estatísticas e de aprendizado de máquina.

Objetivos

1. Investigar se o perfil de fertilidade dos solos de pastagem, como indutor de degradação, permite distinguir as condições de pastagem com outros sistemas de uso da terra.
 - 1.1. Caracterizar o perfil de fertilidade dos solos de pastagens com base em atributos químicos e físicos.
 - 1.2. Testar se há diferenças significativas entre os perfis de fertilidade de solos sob pastagem e sob outros tipos de uso e cobertura do solo.
2. Testar se parâmetros relacionados à produtividade, como indicadores de degradação de pastagens, podem ser caracterizados a partir de dados remotos.
 - 2.1. Caracterizar sistemas produtivos pecuários a partir de dados de uso e cobertura do solo para pastagem e de rebanho em escala municipal
 - 2.2. Extrair parâmetros sazonais de séries temporais de índices de vegetação, obtidas por sensores óticos, e de modelos agrometeorológicos de produtividade, e agrupar as áreas estudadas áreas com base na semelhança destes parâmetros.
 - 2.3. Avaliar se há associação entre parâmetros sazonais de desenvolvimento das pastagens e dados remotos coletados por tecnologia SAR (Radar de Abertura Sintética).

2 REVISÃO BIBLIOGRÁFICA

2.1 DEGRADAÇÃO DE PASTAGENS E O PANORAMA DA PECUÁRIA BRASILEIRA

Dentre os fatores limitantes para intensificação da pecuária brasileira, a degradação das pastagens é um dos principais e pode ser definido como “uma área com acentuada diminuição da produtividade agrícola ideal, podendo ou não ter perdido a capacidade de sustentar produtividade biológica significativa” (DIAS-FILHO, 2015). Essa degradação, de acordo com o mesmo autor, pode ainda ser classificada de duas maneiras: (i) degradação agrícola, quando há aumento da presença de plantas infestantes em competição com o capim ou com as forragens, o que diminui seu potencial nutritivo; e (ii) degradação biológica, na qual o solo perde a capacidade de sustentar a vegetação. No Brasil, a degradação agrícola é mais comum em locais onde o período seco não é tão severo, enquanto a degradação biológica tem maior incidência em regiões de clima mais seco, no qual a vegetação não consegue, naturalmente, se desenvolver de forma tão vigorosa. Assim, uma pastagem considerada degradada em determinada região pode não o ser em outra, e a caracterização de seus indicadores é dificultada pois não existe uma metodologia uniforme para essa finalidade. Estima-se que cerca de 70% das pastagens brasileiras apresentam algum grau de degradação, porém, a recuperação de todo esse montante não é necessária e seria inviabilizada por questões tanto técnicas (como a indisponibilidade de insumos suficientes para tal operação, por exemplo) quanto mercadológicas (pois não haveria rebanho em contingente suficiente para ocupar todas estas áreas e nem demanda pelos produtos, por exemplo) (DIAS-FILHO, 2015). Oliveira et al. (2022) observaram características de degradação agrícola como mais frequente que a degradação biológica em áreas de pastagens mais recentemente formadas (< 10 anos) ao analisar a variação no estoque de carbono em relação à vegetação nativa.

A intensificação da produtividade das pastagens a partir de bases sustentáveis pode ajudar a aumentar o alinhamento do Brasil com os objetivos de combater as mudanças climáticas (BUSTAMANTE et al., 2012; DIAS-FILHO, 2015; GREENWOOD, 2021). Em 2009, foi instituída no Brasil a Política Nacional sobre Mudança do Clima (PNMC), que reúne uma série de programas para promover a redução das emissões de gases de efeito estufa (GEE) provocadas por atividades antrópicas e traçar estratégias de adaptação para as mudanças no clima (BRASIL, 2016). Como exemplos, podem ser mencionados o Plano de Ação para a Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm) e o Plano de Ação para Prevenção e Controle do Desmatamento e das Queimadas no Cerrado (PPCerrado). Esses planos têm o objetivo de impedir a redução da área desses biomas e podem ser beneficiados por

iniciativas de monitoramento de pastagens degradadas que auxiliem a criação e implementação de programas de aumento da produtividade vertical dos pastos para consequente redução da pressão de desmatamento (BUSTAMANTE et al., 2012; MARTHA Jr. et al., 2012; DIAS-FILHO, 2015). Uma outra iniciativa, o Plano Setorial de Mitigação e Adaptação às Mudanças Climáticas para a Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura (Plano ABC), está mais conectada à sustentabilidade agropecuária e segurança alimentar. Esse plano dispõe de um programa específico para recuperação de pastagens degradadas que prevê a recuperação de 15 milhões de hectares e a mitigação de até 104 milhões de toneladas de dióxido de carbono equivalente (toneladas de CO_{2eq.}) até 2030 (BRASIL, 2012; BRASIL, 2016). Em trabalhos recentes, Oliveira et al. (2022) estimaram o potencial de estoque de carbono pela recuperação de 30 milhões de hectares de pastagens degradadas em ~306Tg¹ de CO₂ até 2030 entre 0-30cm de profundidade, seguindo o escopo definido nas Contribuições Nacionalmente Determinadas². Este valor que pode chegar a 3.445Tg CO₂, se considerados os 64 milhões de hectares considerados degradados na profundidade 0-100cm. Santos et al. (2024) pontuaram que esse aumento pode não ser viável em todas as áreas, sendo preciso adotar mais estratégias de mitigação de GEE quando considerado o balanço entre o sequestro de CO₂ e a emissão promovida pelo rebanho e pela aplicação de insumos (fertilizantes nitrogenados, por exemplo) no sistema. De acordo com Strassburg et al. (2014), um aumento de 20% na produtividade média das pastagens brasileiras bastaria para atender as demandas por carne bovina e direcionar o restante destas áreas para outras atividades (como agrícola, florestal e produção de biocombustíveis, por exemplo) sem a necessidade da abertura de novas áreas até 2040.

Melhorias nas técnicas e tecnologias de manejo ao longo do tempo aumentaram a produtividade das pastagens brasileiras e resultaram em uma economia de 525 milhões de hectares (MARTHA Jr. et al., 2012), que, de outra forma, seriam necessários adicionalmente aos 160 milhões de hectares já ocupados (IBGE, 2017) para sustentar a mesma produtividade. Além de reduzir a pressão por desmatamento, pastagens bem manejadas também reduzem as emissões líquidas de gases de efeito estufa (OLIVEIRA et al., 2022) ao mesmo tempo que aumentam a produtividade e as receitas dos agricultores (STRASSBURG et al., 2014; GARCIA et al., 2017; STABILE et al., 2020; SANTOS et al., 2024). Embora sejam menos eficientes em comparação com pastagens integradas com lavouras (REIS et al., 2021), ainda são o sistema

¹ 1Tg = 1 milhão de toneladas.

² Disponível em: <https://www.gov.br/mma/pt-br/assuntos/mudanca-do-clima/NDC>. Acesso em: 08/07/2024.

predominante no Brasil e, por isso, essa transição ainda terá que superar obstáculos técnicos, financeiros e políticos não negligenciáveis (GIANETTI e FERREIRA FILHO, 2024).

2.2 MANEJO DA FERTILIDADE DOS SOLOS SOB PASTAGEM

Melhorias no manejo de pastagens envolvem, entre outros fatores, a adoção de estratégias de adubação mais eficientes que apesar de ser uma tarefa relativamente custosa – cerca de 15% dos custos totais (ANDRADE e VALENTIM, 2006; DIAS-FILHO, 2015) – e com maior impacto para agricultores de baixa renda (BERNARDI et al., 2016), se não forem bem planejadas e executadas podem levar (i) à nutrição vegetal insuficiente, que diminui a rentabilidade agrícola e prejudicam a cadeia de abastecimento alimentar (FAY et al., 2015) ou (ii) à fertilização excessiva que prejudica a sustentabilidade econômica e ambiental do empreendimento (por exemplo, acidificação do solo e contaminação das águas subterrâneas) sem aumento efetivo da produtividade (PIRES et al., 2015).

Análises químicas e físicas do solo são ferramentas fundamentais no apoio aos agricultores e pecuaristas que visam melhorar a eficiência do levantamento e suplementação nutricional do solo. Sua adoção vem aumentando ao longo dos anos juntamente com o número de laboratórios capazes de realizar este tipo de serviço (CANTARELLA et al., 2022), impulsionado, principalmente, por preocupações com o aumento da produtividade e pela necessidade de usar as informações nutricionais do solo em práticas de manejo como aquelas preconizadas na gestão por técnicas de agricultura de precisão, um paradigma crescente especialmente nas novas gerações de agricultores (BERNARDI e INAMASU, 2014).

Do ponto de vista do agricultor, a análise do solo é, em geral, um recurso utilizado apenas na fase de planejamento e que, em termos práticos, não implica na necessidade de comparações temporais ou espaciais com seus vizinhos ou comunidade (i.e., todos os produtores de determinada cultura num escopo espacial mais amplo).

Para laboratórios, prestadores de serviços e fornecedores de fertilizantes, por outro lado, conhecer a distribuição dos resultados das análises de solo na sua área de atuação pode representar vantagem estratégica na identificação de oportunidades econômicas e operacionais para si e seus parceiros (produtores), como a identificação de tendências que venham a direcionar a gestão do seu portfólio de produtos e serviços.

Técnicas de sensoriamento remoto e por dispositivos proximais são uma opção para o levantamento indireto dessas informações (LU et al., 2019; PHAM et al., 2021), mas não

conseguem atingir a mesma precisão que as tradicionais análises realizadas em laboratório. Além disso, o avanço do conhecimento científico também poderia se beneficiar da maior disponibilidade desses dados de referência para a criação e avaliação de modelos mais precisos (SIRSAT et al., 2017; GOLIC et al., 2020; HELFER et al., 2020). Mason et al. (2023), em trabalho recente, refletem sobre a relevância do intercâmbio de informações entre agentes da cadeia produtiva em diferentes posições e níveis hierárquicos (agentes governamentais, cientistas, prestadores de serviços e agricultores). Com isso, estratégias de integralização mais abrangentes desses dados podem ajudar a superar o desafio da transformação digital do agronegócio (MASSRUHÁ et al., 2020) e melhorar a eficiência e direcionamento das práticas adubação (FOLEY et al., 2011). Iniciativa semelhante faz parte do plano de prioridades do solo já em curso na União Europeia visando a neutralidade climática até 2050 (PANAGOS et al., 2022).

No contexto da gestão da fertilidade dos solos e da interrelação entre os elementos resultantes da análise de solo em áreas agrícolas, a literatura científica que aborda as inter-relações dos nutrientes do solo (i.e., estequiométricas) é abundante em combinações de nitrogênio, carbono e fósforo (BERTRAND et al., 2019). Informações mais aprofundadas também podem ser extraídas de interações mais complexas e sistemáticas entre vários elementos (DAHMARDEH e HODIANI, 2016; PHAM et al., 2021). Fay et al. (2015) sugeriram o uso da avaliação de múltiplos nutrientes da fertilidade das pastagens em escala de ecossistema. Balesdent et al. (2018) adotaram e sugeriram uma avaliação de solo multicamadas. Moody et al. (2008) sugeriram um esforço para criar ferramentas de apoio à decisão para avaliar e gerir os recursos naturais em direção a uma agropecuária mais sustentável.

2.3 MODELAGEM E MONITORAMENTO DE PASTAGENS

Conhecer a distribuição e a situação das pastagens é fundamental para avaliar a efetividade de programas e políticas para melhorar o planejamento e aumentar a sustentabilidade do uso da terra no cumprimento dos compromissos firmados para redução das emissões de GEE em 43% até 2030 (BUSTAMENTE et al., 2012; LAPOLA et al., 2014; BRASIL, 2016). Porém, em razão da grande extensão das áreas de pastagens no Brasil, ficam evidentes os desafios dessa operação em nível nacional (ALI et al., 2016). Nesse caso, a adoção de técnicas de sensoriamento remoto tem se mostrado uma alternativa viável, e estudos dessa natureza têm sido adotados inclusive: (i) como referência para levantamentos de órgãos governamentais (RUDORFF et al., 2010; AGUIAR et al., 2011; VALERIANO et al., 2016a; VALERIANO et al., 2016b; ASSIS et al., 2019); (ii) ou como subsídio para avaliar a eficiência

de programas de combate ao desmatamento, como o PPCDAm e o PPCerrado (ALENCAR et al., 2020); ou (iii) de promoção da sustentabilidade agropecuária, como o Plano ABC (SANTOS et al., 2022). No caso das pastagens, Parente et al. (2017) e Parente e Ferreira (2018) foram precursores de uma série de trabalhos de monitoramento desse tipo de cobertura em escala nacional que deram origem a bases de distribuição das áreas de pastagem no território brasileiro e que hoje compõem as coleções da iniciativa MapBiomass³ (SOUZA et al., 2020). Nesses trabalhos, os autores observaram um padrão expansionista sobre os biomas Cerrado e Amazônia até 2005, a partir do qual houve estabilização desse crescimento e contração das áreas de pastagem na Mata Atlântica. O deslocamento das áreas de pastagem para a região Amazônica, contudo, ainda se mostra preocupante e reforça a demanda pela intervenção do poder público para incentivar o crescimento vertical da produção dada a correlação positiva observada entre a evolução da área de pastagem e do rebanho (PARENTE e FERREIRA, 2018). Esse efeito revela uma intensificação da produção agrícola, com conversão das áreas de pastagem para agricultura, como demonstrado por Lapola et al. (2014) e, mais recentemente, por Caballero et al. (2023), utilizando classificação de imagens de satélite.

A partir destes e de outros estudos análogos (FONSECA et al., 2021), as iniciativas seguintes avançaram na extração de dados sobre a situação das áreas de pastagem sob diversos critérios e objetivos. Arantes et al. (2018) utilizaram dados do vigor vegetativo das pastagens extraídos de imagens de satélite combinados com dados censitários do rebanho nacional para identificar o potencial médio de intensificação da taxa de lotação das pastagens do país em 2,63UA/hectare. Pereira et al. (2018) estudaram a degradação de pastagens e conseguiram correlacionar a ocorrência desse fenômeno com fatores ligados à vulnerabilidade socioeconômica regional. Em Santos et al. (2022), séries temporais de imagens de satélite foram utilizadas na discriminação da degradação em três níveis. Eles mostraram um aumento da área de pastagem não degradada, sendo creditada, principalmente, a propriedades maiores e com maior tecnificação, observando a persistência de uma grande parcela do território (~44 milhões de hectares) ainda como pastagem degradada.

2.3.1 Modelagem agrometeorológica

As condições climáticas são o primeiro limitante ao dimensionamento do rebanho por área, enquanto as condições do tempo podem afetar o rendimento e as atividade de manejo no curto e curtíssimo prazo. Como exemplo, é possível citar a necessidade, por parte dos

³ Disponível em: <https://brasil.mapbiomas.org/>. Acesso em: 08/07/2024.

pecuaristas, de oferecer alimentação suplementar em períodos de seca e/ou ocorrência de veranicos, o que pode ter impactos significativos na rentabilidade da atividade.

No contexto das mudanças climáticas, além da produtividade, estima-se que seus efeitos impactem também a resistência e a recuperação do vigor vegetativo das pastagens (WHITE et al., 2020; ZHANG et al., 2021; PEREIRA-FLORES et al., 2023). E essas alterações, principalmente no regime hídrico, aumentam a instabilidade das pastagens brasileiras nas principais regiões onde a pecuária é praticada (SLOAT et al., 2018).

É importante frisar, no entanto, que é a variação das chuvas ao longo do ano que exerce maior influência no desempenho das pastagens (ALVES et al., 2020; ZHANG et al., 2021), e que essa sensibilidade é maior em locais secos do que em locais úmidos (ZHANG et al., 2021; PEREIRA-FLORES et al., 2023). A maior precipitação, por sua vez, pode favorecer a degradação agrícola da pastagem pela promoção da sucessão vegetativa (PITTARELLO et al., 2020).

Se por um lado a correlação com parâmetros meteorológicos e climáticos mostram a susceptibilidade da atividade agropecuária ao clima, por outro permite também modelar o comportamento esperado para antecipar intervenções ou melhorar o planejamento da atividade. Como pontuado em White et al. (2020), conhecer os cenários hipotéticos é importante para direcionar o planejamento das atividades agrícolas, sendo a produtividade potencial um parâmetro referencial importante de ser conhecido.

Na região Sudeste do Brasil, equações de produtividade de pastagens baseadas em regressão foram propostas por Tonato et al. (2010). Eles parametrizaram modelos de produtividade potencial considerando o suprimento hídrico acima de 50% com o objetivo de estimar a produtividade potencial para os três principais gêneros de pastagens gramíneas cultivados no país: (*Urochloa* spp., *Cynodon* spp. e *Panicum* spp.). Com isso, conseguiram obter valores para o coeficiente de determinação (r^2) entre 60% e 70% da variação para *Urochloa* spp., entre 55 e 60% para *Cynodon* spp. e até 40% para *Panicum* spp. Posteriormente, Pezzopane et al. (2013), relacionando a taxa de acúmulo de matéria seca do capim Mombaça (*Panicum maximum* Jacq. cv. Mombaça) com diversos parâmetros meteorológicos, melhoraram o modelo para a pastagem não irrigada obtida pela temperatura mínima adicionando uma correção pelo armazenamento de água no solo.

2.3.2 Sensoriamento remoto utilizando sensores óticos

O monitoramento agroambiental é impactado positivamente pelo aumento expressivo da disponibilidade de dados coletados por sensores remotos, que vêm evoluindo na geração de informações cada vez mais precisas e frequentes.

Utilizando dados dessa natureza, pesquisas vêm sendo direcionadas no levantamento de produção da biomassa (HANDCOCK et al., 2007; ROSA e SANO, 2013; SERRANO et al., 2016), área de cobertura vegetal (McINNES et al., 2015; PARENTE et al., 2017; JAKIMOW et al., 2018; PARENTE e FERREIRA, 2018) e degradação (AGUIAR et al., 2010; SURIGA et al., 2012; PEREIRA et al., 2018; ARANTES et al., 2018; SANTOS et al., 2022).

No caso da degradação em pastagens, a última consequência desse processo é a perda de valor econômico do pasto, podendo ocorrer pelo processo agrícola ou biológico (DIAS-FILHO, 2015). Invariavelmente, porém, os impactos serão observados na produtividade, e a partir dessa premissa, o desafio do sensoriamento remoto utilizando sensores óticos está em correlacionar da forma mais precisa possível a resposta espectral da superfície e produtividade das pastagens.

Em Pereira et al. (2018) e Santos et al. (2022), os autores utilizaram séries temporais de índice de vegetação dos satélites Terra-MODIS (*MODerate resolution Imaging Spectroradiometer*) e Landsat5-TM (*Thematic Mapper*) e Landsat8-OLI (*Operational Land Imager*), respectivamente, para extrair um diagnóstico sobre a presença ou não do fenômeno da degradação, com base no comportamento e na tendência das séries temporais.

Em Muro et al. (2022), os autores utilizaram séries temporais do satélite Sentinel-2-MSI (*MultiSpectral Instrument*) para monitorar a diversificação de espécies (i.e., degradação agrícola) em áreas de pastagem nativa e pontuaram a necessidade de seguir regras estabelecidas em protocolos de amostragem dos dados e validação das análises (OLOFSSON et al., 2014; PONTIUS Jr., 2022) para melhorar a precisão dos resultados em função da heterogeneidade espacial que os alvos ou superfícies apresentam.

Em Buhvald et al. (2022), a estratégia foi identificar a intensidade de pastejo utilizando séries temporais. Diferentemente dos trabalhos anteriores, que utilizaram séries completas, agregados sazonais ou tendência, estes autores obtiveram melhores resultados pela seleção de amostras temporais específicas relativas ao início da fase de crescimento da

vegetação. O ponto de convergência nesses trabalhos está na importância da informação temporal para aplicações de monitoramento.

Por fim, Stumpf et al. (2020) utilizaram séries temporais do satélite Sentinel-2-MSI para qualificar a intensidade de pastejo e a diversidade de espécies em diferentes configurações topográficas.

Diagnosticar a qualidade das pastagens apenas por meio de índices de vegetação pode enviesar a interpretação dos resultados obtidos por não considerar as características biofísicas da espécie. Dessa forma, a parametrização de modelos que levem em conta dados coletados em campo e direcionem os resultados para uma espécie específica podem trazer maior valor científico à aplicação, permitindo a estimativa não só da biomassa, mas também de outros componentes importantes para a atividade agropecuária (PULLANAGARI et al., 2011; OLIVEIRA et al., 2020; CHEN et al., 2021; DE ROSA et al., 2021). Esses modelos, quando desenvolvidos em condições experimentais e espacialmente restritas, apresentam bons resultados também pela homogeneidade das condições ambientais para onde foram desenvolvidos. Em aplicações mais abrangentes, contudo, é preciso incluir na parametrização as condições meteorológicas e/ou de solos já relatadas e que influenciam no desenvolvimento vegetal potencial.

Nesse caso, a exemplo dos modelos exclusivamente agrometeorológicos, o desempenho de modelos dessa natureza em condições distintas daquelas para as quais foram desenvolvidos será prejudicado, sendo necessário restringir sua aplicação ou calibrá-lo para outros locais. Nas condições do Centro-Oeste brasileiro, o modelo proposto por Rosa e Sano (2013) contribui na modelagem da produção de matéria seca em pastagens formadas por *Brachiaria* spp, sendo adotado na estimativa de acúmulo de matéria seca em trabalhos mais recentes, como em Veloso et al. (2020).

2.3.3 Sensoriamento remoto por Radar de Abertura Sintética

Diferentemente dos sensores que operam no espectro ótico (e.g., Sentinel-2-MSI, Landsat-TM, Landsat-OLI, Terra-MODIS), sistemas radares que operam na faixa de micro-ondas, como o Radar de Abertura Sintética (*Synthetic Aperture Radar* ou SAR, em inglês), e permitem o levantamento de informações estruturais e dielétricas (i.e., umidade) do alvo, servindo, portanto, como uma fonte de dados distinta e complementar aos sensores óticos. Duas vantagens importantes desses sistemas estão na sua capacidade de: (i) imagear a superfície mesmo sob cobertura de nuvens, devido à menor frequência em que operam (entre 300MHz e

20GHz, aproximadamente) que implicam em maior comprimento de onda (entre 1m e 15mm, respectivamente); e (ii) imagear independentemente do período do dia (dia ou noite) em função da sua fonte de energia própria embarcada (RICHARDS, 2009). De forma prática, esses sistemas permitem o monitoramento em regiões e períodos de maior umidade, como na Floresta Amazônica, onde grande parte do imageamento por sensores óticos é prejudicada.

Trabalhos de monitoramento agrícola e ambiental têm adotado dados SAR de forma complementar aos dados de sensores óticos a fim de melhorar a acurácia da classificação da superfície terrestre (CAMPOS-TABERNER et al., 2019; SONG et al., 2021; KORDI e YOUSEF, 2022; PRUDENTE et al., 2022; ASADI e SHAMSODDINI, 2024; NAJEM et al., 2024). Uma característica constante nestes trabalhos, assim como naqueles utilizando exclusivamente sensores óticos, é o uso de séries temporais nos experimentos, mas que, nesse caso, avançam pela combinação dessas duas fontes de dados.

Aplicações de classificação de uso da terra, dependendo da configuração da paisagem imageada, frequentemente obtém desempenho superior em função das diferenças significativas da resposta espectral dos alvos, como na distinção entre corpos hídricos, superfície florestal e área agrícola. Quando essa abordagem está em torno de subclassificar um mesmo tipo de cobertura ou extrair dados de qualidade do alvo, o desafio de se obter um grau de separabilidade aceitável é maior e a performance geralmente é menor, como pode ser observado em Domenech et al. (2020) na extração de parâmetros do solo, em Raab et al. (2020) e Muro et al. (2022) na estimativa de matéria seca, em Zhang e Ren (2023) na estimativa de altura do pasto, dentre outros. Em pastagens, as aplicações mais frequentes utilizando SAR envolvem a extração de parâmetros biofísicos (ALI et al., 2017; MURO et al., 2022; ZHANG e REN, 2023), intensidade ou distinção de práticas de manejo (ALI et al., 2016), e diversidade de espécies (CRABBE et al., 2021; MURO et al., 2022). No entanto, por serem aplicações feitas em conjunto com dados óticos, os resultados têm mostrado pouca contribuição dos dados SAR em relação aos sensores óticos.

A maior parcela dos trabalhos envolvendo dados SAR focam na utilização do coeficiente de espalhamento (σ) (DOMENECH et al., 2020; MURO et al., 2022; ZHANG e ZEN, 2023), de métodos de decomposição (CLAUDE e POTTIER, 1997; WANG et al., 2019; CRABBE et al., 2021; HÄNSCH et al., 2021) ou de índices de radar (RAAB et al., 2020; BUSSINGUER et al., 2024) para inferir sobre a condição dos alvos de interesse. Apesar disso, seu maior potencial analítico emerge com a aplicação de técnicas de síntese polarimétrica, que

permitem analisar o comportamento dos alvos sob diferentes orientações (i.e., polarização) do ângulo de incidência (RICHARDS, 2009; JIN e XU, 2013; LEE e POTTIER, 2017). Nesse tipo de aplicação, a premissa fundamental que deve ser atendida é que o produto analisado seja coerente, ou seja, que preserve o ângulo fase relativo entre os componentes vertical e horizontal do sinal (i.e., onda eletromagnética) incidente (RANEY, 2006). Ainda que métodos de decomposição do sinal se enquadrem na definição de polarimetria, estes não seriam coerentes, e produtos como o vetor de Stokes (CHARBONNEAU et al., 2010) deveriam ser mais explorados por configurarem um produto polarimétrico completo (coerente), mesmo em sistemas de polarização *dual*, como o Sentinel-1 (RANEY, 2006; RANEY, 2024)

Com isso, dois desafios científicos podem ser identificados: (i) exploração de produtos polarimétricos SAR completos como o vetor de Stokes (JAFARZADEH et al., 2024), segundo a argumentação presente em Raney (2006 e 2024); e (ii) aplicações envolvendo a extração de indicadores de degradação em pastagens com melhor desempenho em função da adoção de dados SAR.

2.3.4 Aprendizado de Máquina aplicada no monitoramento de pastagens com dados remotos

O emprego de algoritmos de aprendizado de máquina para aplicações geoespaciais possibilitam sensível redução significativa dos custos operacional e financeiro em aplicações para mapeamento e extração de parâmetros de alvos e superfícies distribuídos no espaço e no tempo. O êxito desse tipo de abordagem, no entanto, vai variar: (i) em função do conjunto de dados utilizado; (ii) das etapas de pré-processamento; (iii) do planejamento da amostragem para treinamento e validação dos modelos; e (iv) das métricas de avaliação dos resultados (HAN et al., 2012; OLOFSSON et al., 2014; JAMES et al., 2023).

O efeito da realização de pré-processamento dos dados, que pode envolver eliminação de *outliers* (pixels, no caso de sensores óticos, ou células de resolução, no caso de dados SAR), transformação dos dados e/ou seleção de subconjunto dos atributos originais pode ser observada em Silva et al. (2020). Neste trabalho, os resultados foram sensivelmente aprimorados pela transformação de atributos sazonais e posterior seleção de atributos, quando comparados aos resultados obtidos sobre as séries temporais não transformadas.

Ainda que os algoritmos sejam mais dependentes da etapa de preparação dos dados do que o contrário, a heurística e as premissas de cada um terão impacto sobre o desempenho e o design dos experimentos. Um dos algoritmos mais populares disponíveis na literatura, o *Support Vector Machine* (SVM) (CORTES e VAPNIK, 1995; JAMES et al., 2023), é eficiente

em mapear os padrões em situações de limitação no tamanho do conjunto de dados. Este pode ser o caso em aplicações geoespaciais, podendo apresentar boa performance mesmo com cerca de 10% do tamanho do conjunto de dados necessário para outros algoritmos. Essa performance, no entanto, é sensivelmente dependente da qualidade desses dados, pois este algoritmo, por princípio, utiliza apenas alguns exemplos na formação da sua fronteira preditiva. Isto faz com que a presença de *outliers* seja um problema no desenvolvimento do modelo. Além disso, o SVM também é dependente da parametrização da sua função *Kernel* e da dimensionalidade do conjunto de dados originais (MOUNTRAKIS et al., 2011).

O algoritmo *Random Forest* (RF), por sua vez, se mostra mais robusto à presença de *outliers* e utiliza uma heurística preditiva baseada na criação de uma série de preditores (i.e., árvores de decisão). Desse modo, considerando subconjuntos aleatórios dos atributos originais, faz a predição para determinada classe ou valor com base na decisão tomada pela maioria dos preditores (no caso de classificação) ou no valor médio (no caso de regressão) (BELGIU e DRĂGUT, 2016). Essa robustez à qualidade reduzida dos dados faz com que o RF seja um dos, se não o mais frequente, e com melhor performance geral em aplicações geoespaciais.

Tanto o SVM quando o RF representam apenas uma parte da disponibilidade de algoritmos disponíveis na literatura (JAMES et al., 2023). Destaca-se que sua representatividade na área de sensoriamento remoto é importante pois são os algoritmos mais utilizados de acordo com Sheykhmousa et al. (2020). Estes autores ainda afirmaram que a performance do algoritmo RF é maior quando os dados são fontes com menor resolução espacial (e provavelmente em aplicações mais espacialmente abrangentes). Já o SVM obtém melhores resultados quando a resolução espacial é maior (provavelmente por haver maior detalhamento na amostragem, mesmo que o conjunto seja menor).

No mapeamento das áreas de pastagens feito por Parente et al. (2017) utilizando o algoritmo RF, estes autores aferiram a distribuição das pastagens ao longo de todo o país. O conjunto de treinamento utilizado foi gerado automaticamente e de forma independente para cada cena que compôs o mosaico representativo do Brasil. Mesmo com a acurácia obtida de cerca de 87%, e validada por seleção aleatória e inspeção visual, os autores afirmaram ser preciso melhorar o levantamento de dados para treinamento do modelo e diminuir a omissão e alocação incorreta das classes de pastagem.

Em Kordi e Yousefi (2022), os autores treinaram um modelo SVM utilizando séries temporais de sensores óticos e sistemas SAR para preencher falhas nas séries temporais e

distinguir cultivos agrícolas. Eles alcançaram cerca de 89% de acurácia geral combinando informações sazonais das séries de dados óticos com dados SAR para preenchimento de lacunas em virtude da ocorrência de nuvens.


Em Vaghela et al., (2021), os autores utilizaram dados polarimétricos para treinar um modelo baseado no algoritmo RF e conseguiram captar (r^2) cerca de 50% da variância na estimativa de biomassa em áreas de mangue. Para pastagens, espera-se resultados melhores na modelagem do seu desenvolvimento, e consequentemente na estimativa de biomassa, se considerada, além da situação observada, a condição potencial de desenvolvimento, como ponderado por White et al. (2021).

Os desafios em torno da aplicação de algoritmos de aprendizado de máquina no monitoramento de pastagens variam em função da característica que se pretende extrair, dos dados utilizados e das condições ambientais. Como afirmado acima, a variabilidade de ambientes com a presença de pastagens no Brasil impõe um desafio para a padronização em modelos preditivos genéricos. Nesse caso, é promissora a abordagem adotada em Parente et al. (2017) de desenvolver modelos com fronteira de decisão baseada em padrões locais. Isto está de acordo com os levantamentos que mostram a dependência das espécies vegetais às condições meteorológicas e climáticas, que limitam ou favorecem o processo de degradação, seja agrícola ou biológico, como conceituado em Dias-Filho (2015).

3 MATERIAL E MÉTODOS

As etapas desenvolvidas neste trabalho se dividiram em dois grupos atuando no dimensionamento de dois parâmetros relacionados à degradação de pastagens: A fertilidade enquanto indutor e a penalização da produtividade potencial como consequência desse processo (Figura 1).

Figura 1 — Fluxograma geral do desenvolvimento do trabalho.



3.1 CARACTERIZAÇÃO DA FERTILIDADE DAS PASTAGENS BRASILEIRAS

3.1.1 Área de estudo e design da amostragem do solo

O conjunto de dados de análise de solo foi obtido de uma campanha de amostragem de solo em escala nacional realizada previamente ao desenvolvimento deste trabalho e descrita

em maiores detalhes nos trabalhos de Assad et al. (2013) e Groppo et al. (2015). Nela, foram coletadas, entre 2010 e 2011, 894 amostras de diferentes profundidades (0-5cm, 5-10cm, 10-20cm e 20-30cm) representativas de três das principais classes de uso da terra distribuída pelos biomas Cerrado, Mata Atlântica, Pampa, Caatinga e Amazônia: (i) pastagem (todas em uso e cultivadas principalmente com *Brachiaria* spp.); (ii) sistema integrado (principalmente em arranjos do tipo lavoura-pecuária); e (iii) vegetação nativa (Figura 2). Enquanto as áreas de pastagem e de sistemas integrados têm função estratégica para cumprimento dos objetivos presentes no Plano ABC para promover a redução e mitigação de emissões de GEE (BRASIL, 2021), a vegetação nativa serviu como uma base de referência para comparação destas classes com a cobertura original do solo.


A amostragem de pastagens com representatividade regional foi realizada em mais de 100 locais escolhidos com base na observação de imagens de satélite e na viabilidade de acesso por estradas. Áreas de sistema integrado e de vegetação nativa, juntamente com áreas de pastagens adicionais e pareadas a estas classes de uso, foram amostradas em campos experimentais pertencentes aos escritórios regionais da Empresa Brasileira de Pesquisa Agropecuária (Embrapa). Assim, neste trabalho, a abordagem de amostragem foi conduzida utilizando uma abordagem não probabilística, e embora haja ciência de que esta estratégia pode ter introduzido algum viés nos resultados obtidos, a amostragem de áreas com acesso mais limitado não seria possível devido a restrições operacionais e financeiras.

Nesta fase do trabalho, todas as etapas de preparação e análise de dados foram conduzidas utilizando, principalmente, as bibliotecas computacionais Pandas⁴ e Scikit-Learn⁵.

⁴ Disponível em: <https://pandas.pydata.org/>. Acesso em: 22/07/2024.

⁵ Disponível em: <https://scikit-learn.org/stable/index.html/>. Acesso em: 22/07/2024.

Figura 2 — Distribuição espacial amostral das áreas de pastagem (P), sistema integrado (SI) e vegetação nativa (VN). As classes de solos mostradas são apenas aquelas com intersecção com os solos dos locais de amostragem. Alguns símbolos podem estar sobrepostos devido à proximidade entre os pontos amostrais.



As amostras de solo foram então submetidas a análises físico-químicas de onde foram extraídos os resultados primários para densidade do solo (DS ; g.dm^{-3}), estoque de nitrogênio (N ; Mg.ha^{-1}), pH baseado em CaCl_2 (cloreto de cálcio) (pH), conteúdo de carbono (C ; g.kg^{-1}) e matéria orgânica (MO ; dag.kg^{-1}) e concentrações de fósforo (P ; mg.dm^{-3}), potássio (K ; mg.dm^{-3}), cálcio (Ca ; cmolc.dm^{-3}), magnésio (Mg ; cmolc.dm^{-3}), alumínio (Al ; cmolc.dm^{-3}) e acidez potencial (AP ; cmolc.dm^{-3}). Em seguida, as amostras foram agrupadas com base nas categorias referidas anteriormente. O Apêndice 1 traz as estatísticas descritivas do conjunto de dados.

Os teores de carbono e nitrogênio foram determinados utilizando um analisador elementar e espectrometria de massa. A concentração de fósforo foi quantificada pelo método Mehlich-3 (MEHLICH, 1984; MATTILA e RAJALA, 2021), no qual é determinada uma mistura de frações das formas inorgânica e orgânica. Embora esta combinação seja considerada mais disponível para plantas (GATIBONI et al., 2005), apenas concentrações puramente orgânicas ou totais são normalmente adotadas em trabalhos de pesquisa (Groppo et al., 2015).

Os demais elementos foram determinados pelo método do KCl (cloreto de potássio). Informações mais detalhadas sobre determinação de elementos podem ser encontradas em Assad et al. (2013) para carbono e em Groppo et al. (2015) para nitrogênio e fósforo. Estes trabalhos incluem uma descrição mais detalhada da estimativa do estoque de nitrogênio usando uma correção de massa fixa para diferenças causadas na densidade do solo pela mudança no uso da terra.

A textura das amostras de solo foi classificada seguindo os *clusters* de textura do Sistema Brasileiro de Classificação de Solos (Santos et al., 2018), que a definiu como arenosa ($\beta - \alpha > 700 \text{ g kg}^{-1}$), média ($\alpha < 350 \text{ g kg}^{-1}$, $\beta > 150 \text{ g kg}^{-1}$), argilosa ($350 \text{ g kg}^{-1} \leq \alpha \leq 600 \text{ g kg}^{-1}$) e muito argilosa ($\alpha > 600 \text{ g kg}^{-1}$) com base em seu conteúdo de argila (α) e areia (β). Além da classificação da textura, o valor numérico relativo à densidade do solo também foi empregado na modelagem numérica devido à sua influência na avaliação da fertilidade em escalas espaciais mais amplas (ZHU et al., 2021). Zhu et al. (2021) e Baumann et al. (2022) afirmam ser importante considerar a densidade na extração de informações do solo ainda que esta seja uma tarefa operacional e financeiramente dispendiosa. Porém, a ciência e a inovação tecnológica têm avançado no desenvolvimento de dispositivos e técnicas de detecção proximal para estimar a textura do solo (PAVÃO et al., 2024). No caso do sensoriamento remoto, contudo, desafios para atingir resultados satisfatórios ainda precisam ser superados (MIRZAEI et al., 2024).

Inconsistências podem influenciar negativamente a qualidade dos modelos. Assim, fontes de inconsistências nos dados foram tratadas (i) descartando parâmetros calculados com alta correlação com insumos primários e que não agregariam ao processo de modelagem (HAN et al., 2012), como Capacidade de Troca Catiônica (CTC) ou Saturação por Bases (V%); e (ii) removendo objetos *outliers* (resultados de análise de solo para diferentes usos do solo, profundidade e textura) com potencial de influenciar negativamente nas análises de amostras de solo (FU et al., 2016).

A detecção de *outliers* foi realizada pelo algoritmo *Local Outlier Factor (LOF)* (BREUNIG et al., 2000), no qual a distância entre objetos individuais até os k vizinhos mais próximos (com $k = 20$) determina seu grau de isolamento, classificando-o então como *outlier* ou não. Formalmente, este método funciona numa perspectiva de densidade local, o que é adequado à natureza do conjunto de dados analisado, onde os objetos podem ser agrupados em

clusters com diferentes usos do solo, densidade do solo e profundidade. Assim, a aplicação do algoritmo *LOF* resultou na remoção de 59 objetos classificados como *outliers*.

3.1.2 Caracterização do Perfil de Fertilidade do Solo (PFS)

Um modelo baseado em Análise de Componentes Principais (PCA, em inglês), utilizando o conjunto de dados *inliers* foi ajustado para identificar relações intrínsecas entre os atributos químicos e físicos em proporção direta, inversa ou inexistente. Um efeito adicional da PCA é a redução de dimensionalidade (HAN et al., 2012) pela condensação dos atributos originais em dimensões comuns (WOLD et al., 1987; HAIR et al., 2009). Na ciência do solo, vários trabalhos vêm empregando esta técnica na avaliação da absorção de nitrogênio pelas plantas (REYES et al., 2015), na melhoria do manejo (SALTON et al., 2014; ZERAATPISHEH et al., 2020; OCCELLI et al., 2021), na avaliação da aptidão do sistema agrícola ao meio ambiente (NOWAK et al., 2022), entre outros. Antes da construção do modelo PCA, o conjunto de dados foi submetido a um pré-processamento e os registros (x_i) de cada atributo (X) foram normalizados pelo *z-score*

$$z_i = \frac{x_i - \bar{X}}{\sigma_X} \quad (1)$$

que, com base na sua média ($\bar{X}$) e desvio padrão (σ_X), transformou-os em variáveis contínuas (z_i) com média e desvio padrão iguais a 0 e 1, respectivamente, para equalizar o peso de cada atributo na construção do modelo exploratório. Em seguida, o modelo PCA construído sobre o conjunto de dados padronizado seguiu um critério de retenção das CPs com autovalores (λ) > 1 que permitiu reter as duas primeiras CPs englobando a maior parte da variação do conjunto de dados original (MANLY e ALBERTO, 2016; JAMES et al., 2023).

Os PFS foram relacionados a partir da sua distribuição no domínio das CPs retidas e da comparação estratificada por categoria individual (uso da terra, grupo textural e profundidade do solo), segmentada e agrupada pelos níveis restantes (e.g., comparação das classes de uso da terra para uma mesma profundidade do solo e grupo textural). Na avaliação do método de comparação estratificada, foi identificado previamente haver distribuição não-Normal para a maioria das amostras categorizadas e transformadas pelo modelo PCA, condição que foi contornada pela aplicação da função $\log(PC + k)$ em cada amostra, fixando a constante $k=20$ para garantir que todos os valores sejam positivos. Esta etapa equivale a aplicar a

transformação de BoxCox com seu parâmetro $\lambda=0$. Em seguida, a comparação das amostras em cada estrato foi feita por meio do teste Honesto de Tukey ($\alpha=0,05$).

3.1.3 Heterogeneidade dos perfis de fertilidade

Amostras categorizadas de PFS de pastagens foram comparadas estatisticamente e de forma individualizada com os outros PFS de pastagens, de sistemas integrados e de vegetação nativa, todos transformados pelo modelo PCA. Nesta etapa, em vez de aplicar uma transformação das amostras para adequá-las à distribuição Normal, como descrito anteriormente, foi adotado o teste de Levene (MANLY e ALBERTO, 2016), mais robusto à fuga da normalidade e adequado em razão das comparações a serem feitas em pares e não em grupos. O teste de Levene foi aplicado pela equação

$$W_m = \frac{(N_m - k_m) \sum_{i=1}^{k_m} N_{m,i} (\bar{Z}_{m,i} - \bar{Z}_{m,..})^2}{(k_m - 1) \sum_{i=1}^{k_m} \sum_{j=1}^{N_{m,i}} (Z_{m,ij} - \bar{Z}_{m,i})^2} \quad (2.1)$$

com

$$Z_{m,ij} = |Y_{m,ij} - \tilde{Y}_{m,i}| \quad (2.2)$$


que transforma os dados das amostras (Y_{ij}) em desvios absolutos (Z_{ij}) da mediana ($\tilde{Y}_i$) (BROWN e FORSYTHE, 1974) para verificar se a média da diferença observada na categoria ($\bar{Z}_i$) e no conjunto geral ($\bar{Z}_{..}$) seguem uma distribuição F em cada m CP retida, cujas amostras têm tamanho $N = N_i + N_j$, seguindo uma estratégia de comparação um-para-um ($k=2$) com descarte de auto comparações ($k_{i=j}$). Além do desvio de normalidade, o teste de Levene também é recomendado no caso de diferenças de tamanhos amostrais, o que justifica sua adequação ao escopo deste trabalho.

Assim, a proporção de diferenças significativas ($p<0,05$) para cada PFS de pastagem (16 no total) foi determinada em relação à quantidade de PFS válidas na comparação com as de pastagem propriamente dita (15 comparações), com as de sistemas integrados (15) e com as de vegetação nativa (14), totalizando 704 comparações por CP retida. Além de descartar as auto comparações na avaliação de pastagem, também foram descartadas algumas categorias de PFS de áreas de sistema integrado e de vegetação nativa devido ao tamanho amostral mínimo insuficiente para aplicação do teste de Levene (Apêndice 2).

3.2 AVALIAÇÃO DO IMPACTO DA DEGRADAÇÃO NO POTENCIAL PRODUTIVO NAS PASTAGENS

Esta etapa do trabalho descreve a segmentação de municípios compreendidos pela área de estudo com base em características relacionadas à pecuária de corte e o emprego desta segmentação na avaliação do acesso a apoio técnico, ambiental (i.e., climatológica) e de produção em áreas de pastagem a partir de modelos de produtividade. Estes foram, por sua vez, utilizados na criação de modelos preditivos do processo de degradação a partir de dados remotos coletados por tecnologia SAR, conforme fluxograma apresentado na Figura 3.

Figura 3 — Delineamento do experimento sobre o impacto do nível de degradação da pastagem. Os itens em azul são etapas intermediárias tratadas com maior detalhamento no decorrer do texto.



3.2.1 Área e período de estudo

O estudo da penalização da produtividade foi conduzido em áreas de pecuária extensiva compreendendo os estados de Goiás (GO), Mato Grosso (MT) e Mato Grosso do Sul (MS), líderes nacionais em extensão da área cultivada sob pastagens e em participação no rebanho bovino nacional. Também foi realizado para São Paulo (SP) (Figura 4), que, além da sua liderança na economia nacional, foi selecionado igualmente em função do contraste observado tanto no uso da terra, cujo direcionamento se deu pela maior intensificação da produção pecuária e diversificação da exploração territorial agrícola com outras culturas como cana-de-açúcar, soja e milho (LAPOLA et al., 2014), quanto em contingente do rebanho, menor em relação aos outros estados contemplados no estudo. Assim, este trabalho abrange cerca de 46% e 39% dos totais nacionais de área de pastagem antropizada e do rebanho bovino para o período considerado (Tabela 1), respectivamente.

O período principal para condução desse estudo foi o ciclo 2015-2016, estendendo-se para o período 2013-2019 para aquisição das séries temporais para modelagem da produtividade e de rebanho e 1986-2015 para modelagem dos parâmetros climatológicos.

Figura 4 — Distribuição dos polígonos das áreas de pastagem (LAPIG, 2023) ao longo da área de estudo.




Tabela 1 — Resumo descritivo da área de pastagem e do rebanho bovino por estado e para todo o Brasil. Os valores por estado são um recorte, em escala de município, da área de abrangência desse trabalho que excluiu os municípios dos biomas Amazônia (MT) e Pantanal (MS).

Estado	Pastagem⁶ (milhões de hectares)	Rebanho bovino (milhões de cabeças)				
	2015	2015	2016	2017	2018	Média
GO	11,67	21,86	22,89	22,81	22,62	22,55
MS	12,53	19,59	19,97	19,58	19,04	19,55
MT	10,19	14,89	15,35	14,75	15,05	15,01
SP	04,90	10,42	10,98	11,06	10,72	10,8
Total	39,29	66,76	69,19	68,2	67,43	67,91
Brasil	85,80	215,22	218,19	215,00	213,81	215,38

Fonte: Parente et al. (2017) e IBGE (2024).

3.2.2 Segmentação dos Sistemas Produtivos Pecuários (SPP)

A variabilidade de condições sociais, econômicas e ambientais exerce influência na dinâmica de uso da terra e na configuração dos diferentes agroecossistemas em todas as regiões do Brasil (CABALLERO et al., 2023). Sob diferentes perspectivas, essas influências podem ajudar: (i) a caracterizar o nível de manejo destinado às áreas de pastagem em escala local (PEREIRA et al., 2018); (ii) a entender o direcionamento das terras agricultáveis para modelos mais intensivos e voltados a exploração de commodities (LAPOLA et al., 2014) ou, ainda; (iii) a adequar modelos de projeção do uso da terra sob influência de políticas de regulação da exploração agrícola (THE REDD-PAC PROJECT, 2015). Mais recentemente, Dou et al. (2023) elencaram que tais fatores, juntamente àqueles relacionados ao clima, também estão presentes na percepção dos produtores rurais quanto ao uso da terra e, consequentemente, nas suas tomadas de decisão.

O perfil do nicho pecuário dos municípios foi determinado utilizando informações do seu rebanho médio (IBGE, 2024), território (IBGE, 2024) e área sob pastagem (PARENTE et al., 2017). Inicialmente, estes dados foram submetidos a pré-processamento com o objetivo de eliminar inconsistências e transformá-los visando melhorar a qualidade do modelo de segmentação gerado posteriormente (HAN et al., 2012). Num primeiro momento, foram

⁶ Representa área antropizada (pastagem plantada) e previamente filtrada utilizando técnicas de geoprocessamento para exclusão de regiões/polígonos que representem inconsistências nos dados.

calculados índices de intensidade pecuária para cada município (m), mais especificamente a sua taxa de lotação ($Tx_{lot,m}$; cabeças/hectare) e a taxa de ocupação por pastagem ($Tx_{op,m}$; %)

$$Tx_{lot,m} = \frac{N_{gb,m}}{A_{p,m}} \quad (3)$$

$$Tx_{op,m} = \frac{A_{p,m}}{A_{t,m}} \quad (4)$$

sendo N_{gb} o rebanho bovino, A_p a área de pastagem (hectare) e A_t é a área territorial (hectare). Por derivarem de atributos já existentes, estes índices podem apresentar correlação significativa com seus predecessores, condição que se apresenta como ruído em modelos exploratórios e demanda tratamento adequado. Nesse caso, o rebanho bovino médio foi removido por apresentar alta correlação ($r \geq 90\%$) com o tamanho da área de pastagem. Em seguida, os atributos restantes (A_t , A_p , Tx_{op} e Tx_{lot}) foram empregados na identificação e remoção de municípios *outliers* ($m_{outlier}$)

$$m_{outlier} = \begin{cases} Q_{75\%} + F_{outlier} * IIQ \\ Q_{25\%} - F_{outlier} * IIQ \end{cases} \quad (5)$$

pelo intervalo (IIQ) entre os quartis 1 ($Q_{25\%}$) e 3 ($Q_{75\%}$) (HAN et al., 2012), tomando o fator de ponderação $F_{outlier}=1,5$. Após a remoção dos municípios identificados como *outliers*, os registros restantes (x_i) de cada atributo (X) foram normalizados pelo *z-score*, descrito previamente em (1).

Os perfis pecuários, aqui denominados Sistemas Produtivos Pecuários (SPP), relacionam a ocupação do território por áreas de pastagem e pelo rebanho bovino e ajudam a entender a presença mais ou menos intensa da pecuária nos municípios envolvidos, tendo sido gerados pelo método *K-Means* (JAMES et al., 2023). Fundamentalmente, este algoritmo busca a otimização do problema pela minimização da equação


$$\min_{C, \{m_k\}_1^K} \sum_{k=1}^K N_k \sum_{C(i)=k} \|x_i - m_k\|^2 \quad (6)$$

atribuindo, para cada registro (i) de N observações o *cluster* (C) com a menor distância euclidiana (i.e., inércia)

$$C(i) = \underset{1 \leq k \leq K}{\operatorname{argmin}} \|x_i - m_k\|^2 \quad (7)$$

entre o registro e o valor médio (m_k) do *cluster* C . Este processo é repetido iterativamente até que o resultado da minimização se estabilize ou um critério de parada seja atingido (e.g., número de repetições sobre toda a coleção de registros). Uma etapa fundamental da aplicação do *K-Means* está na definição previa de K , cuja otimização (i.e., escolha do número ideal) é local e dependente da aplicação (AHMED et al., 2020; JAMES et al., 2023). Esta característica impede a mera importação deste parâmetro em aplicações de natureza distinta ou mesmo semelhante, mas com configuração conjunto de dados diferentes. Neste trabalho, a abordagem adotada foi reter o menor número de K que promovesse a maior redução da inércia em relação ao agrupamento único ($K=1$), antes da estabilização desse parâmetro, técnica comumente difundida como “regra do cotovelo”. Apesar de trivial, ela tem respaldo científico, pois o aumento K leva à criação de *clusters* desbalanceados que prejudicam a performance do algoritmo (FRÄNTI e SIERANOJA, 2018). Com isso, foram gerados 5 K_{SPP} (i.e., SPP) para definir os perfis da pecuária praticada na área de estudo em escala municipal (Figura 5).

Figura 5 — Redução relativa da inércia em função do número de *clusters* (SPP) gerados. A coluna destacada representa a redução da inércia para o número de K_{SPP} assumido para as etapas subsequentes.



Para verificar a qualidade e adequação da segmentação, as características descritivas dos SPP foram cruzadas com dados de acesso das propriedades à assistência técnica extraídos do último Censo Agropecuário (IBGE, 2017). Referentes ao número de produtores de cada município que declararam ter na sua propriedade alguma forma de exploração de

pastagens, esses dados quantificam aqueles que declararam ter tido acesso à assistência técnica proveniente de: (i) cooperativas; (ii) entidades governamentais (universidades, agências de extensão rural, instituições de pesquisa, entre outros); (iii) fontes internas ou próprias (quando o produtor é a fonte de informação ou dispõem de mão de obra contratada para esta finalidade); ou (iv) prestadoras de serviço do setor privado. O intuito de relacionar estas informações foi entender se municípios mais intensificados na sua prática pecuária dispõe de mais acesso à assistência técnica, e se alguma das categorias listadas tem predominância sobre as outras. Além disso, também foi analisado se entre os estados há alguma diferença na distribuição desse tipo de auxílio que o produtor tem à sua disposição.

3.2.3 Estimativa de produtividade das pastagens e modelagem do clima regional

A modelagem da produtividade foi feita para dois cenários: (i) um considerando a produtividade observada a partir de índices de vegetação coletados por sensores remotos; e (ii) outro pela produtividade potencial estimada a partir de dados agrometeorológicos. A produtividade observada (P_{obs} ; kg/hectare.dia) foi obtida pela Equação (8) desenvolvida por Rosa e Sano (2013):

$$P_{obs} = \varepsilon_f \sum_{j=1}^n NDVI * RAD_{par} \quad (8)$$

que usa dados do índice $NDVI$ (ROUSE et al., 1974) e de radiação fotossinteticamente ativa (RAD_{PAR}) associadas a um fator de eficiência fotossintética da radiação (ε_f) para estimar a produção primária líquida (matéria seca). Por não ser trivial determinar ε_f em função da sua alta variabilidade (PRINCE, 1991), este parâmetro foi valorado em 0,46, o mesmo adotado no trabalho que originou o modelo, por este ter sido definido com base em experimentos de campo conduzido pelos autores. A produtividade potencial (P_{pot} ; kg/hectare.dia), ou atingível, foi calculada utilizando equações extraídas de Tonato et al. (2010):

$$P_{pot,U1} = -94,92 + 8,19 * TEMP_{min} \quad (9)$$

$$P_{pot,C1} = -84,69 + 9,06 * TEMP_{min} \quad (10)$$

ambas baseadas apenas na temperatura mínima ($TEMP_{min}$) e representativas de dois dos principais genótipos (g) de gramíneas cultivados no Brasil, *Urochloa* (capim *Brachiaria*, cvs. Marandu, Basilisk e Arapoty) e *Cynodon* (cvs. Tifton-85 e Estrela), referentes ao primeiro

agrupamento realizado pelos autores, a partir daqui denominados U1 e C1, respectivamente. Tanto o modelo de produtividade observada quanto potencial foram gerados para as condições do bioma Cerrado, sendo, portanto, representativo da maior parte da área experimental deste trabalho (com exceção do estado de São Paulo, predominantemente pertencente à Mata Atlântica). Além disso, os genótipos utilizados na estimativa da produtividade atingível também foram utilizados em Strassburg et al. (2014) para calcular o potencial de intensificação de pastagens no território brasileiro, o que justifica a adoção desses modelos em áreas mais abrangentes.

O Brasil apresenta diferentes regimes hídrico, térmico e energético ao longo da sua extensão territorial, com reflexos sobre o comportamento fisiológico da vegetação (ALVES et al., 2020). No caso das pastagens, essa variação impacta o rendimento natural em biomassa aproveitável para alimentação do rebanho, o que, por sua vez, limita ou favorece a rentabilidade da atividade pecuária nas diferentes regiões em que é praticada.

Neste trabalho, as condições climáticas ao longo da área de estudo foram calculadas pelo balanço hídrico climatológico de Thornthwaite e Mather (1955), ferramenta ainda hoje empregada em diversos estudos climatológicos (APARECIDO et al., 2020; LIMA et al., 2021; VALE et al., 2024). Ele parametriza a entrada de água no sistema pela precipitação ($PREC$) e a saída por evapotranspiração potencial (ET_p), aqui calculada pelo método de Thornthwaite (1948). Das variáveis resultantes, a deficiência hídrica (DEF) e o armazenamento de água (ARM) foram geradas considerando duas situações com objetivos distintos: (i) análise do clima (i.e., média mensal) local e sua variação espacial na região de estudo no período 1986-2015 (30 anos), parametrizado em torno de uma Capacidade de Água Disponível de 100mm (CAD_{100mm}) e do qual foi extraída apenas a deficiência hídrica (DEF_{cad100}); e (ii) avaliação da variação sequencial no período 2013-2019 (i.e., escala meteorológica) — período escolhido para coincidir com a modelagem da sazonalidade, descrita posteriormente —, que também compreende a safra 2015-2016, período central para a avaliação dos impactos da degradação no desenvolvimento das pastagens a partir de dados de sensores ativos. Nessa segunda situação, o modelo foi gerado para duas $CADs$, com 125mm (CAD_{125mm}) e 50mm (CAD_{50mm}) e representativas de dois cenários, um com maior desenvolvimento radicular, característica de pastagens intensificadas e em boas condições (DEF_{cad125} e ARM_{cad125}), e outro com sistema radicular mais curto, como observado em pastagens sob degradação mais intensa (DEF_{cad50} e ARM_{cad50}), respectivamente (WHITE et al., 2021; ZHANG et al., 2021).

Os modelos de balanço hídrico (climatológico e sequencial) e de produtividade (observada e potencial) foram ambos construídos com base em dados agrometeorológicos. O Brasil dispõe de uma rede considerada robusta quanto ao número de estações, cuja distribuição de seus dados se dá por diversos sistemas e agências, como o Agritempo⁷, da Embrapa (Empresa Brasileira de Pesquisa Agropecuária) em parceria com o Cepagri/Unicamp, o Hidroweb⁸, mantido pela ANA (Agência Nacional de Águas) ou o portal de disseminação de dados do INMET⁹ (Instituto Nacional de Meteorologia), dentre outros. Não se pode ignorar, contudo, a maior concentração da distribuição dessas estações sobre a região Sudeste, especialmente no Estado de São Paulo, mas que representa apenas uma parte da área total estudada. Outra característica dessa malha, mais restritiva que a cobertura espacial reduzida, está no fato de que a maioria destas estações não dispõe de uma série temporal completa o suficiente para aplicações temporais mais abrangentes (AGUIAR e LOBO Jr., 2020), como é o caso deste trabalho.

Ainda que os dados de estações físicas sejam mais desejáveis para aplicações de modelagem, seus resultados podem ser prejudicados se sua qualidade for insatisfatória. Essa limitação motivou diversos trabalhos que buscaram substituir dados irreais ou preencher lacunas em séries temporais de estações de campo (AGUIAR e LOBO Jr., 2020; DIAS e SENTELHAS, 2020; DUARTE e SENTELHAS, 2020) ou interpolar dados de várias estações para gerar grades regulares (ALTHOFF et al., 2020; XAVIER et al., 2022).

Alguns desses trabalhos (AGUIAR e LOBO Jr., 2020; DIAS e SENTELHAS, 2020; DUARTE e SENTELHAS, 2020) utilizaram como fonte alternativa a base Power¹⁰ (*Prediction Of Worldwide Energy Resources*), desenvolvida pela Nasa (*National Aeronautics and Space Administration*), que disponibiliza inúmeros parâmetros obtidos pelo processamento de diferentes fontes e modelos de dados originados principalmente de observações de satélites, e que tem como característica principal a cobertura espaço-temporal mais consistente e regular para todo o planeta. Por esta razão, os dados fornecidos pela base Nasa-Power foram adotados como fonte de dados meteorológicos para os modelos de balanço hídrico e produtividade.

No caso da produtividade observada, esta também demanda dados do índice *NDVI* para compor sua estimativa, por sua vez obtido pelo sensor MODIS (*Moderate Resolution*

⁷ Disponível em: <https://www.agritempo.gov.br/>. Acesso em: 18/04/2024.

⁸ Disponível em: <https://www.snirh.gov.br/hidroweb/apresentacao>. Acesso em: 18/04/2024.

⁹ Disponível em: <https://portal.inmet.gov.br/>. Acesso em: 18/04/2024.

¹⁰ Disponível em: <https://power.larc.nasa.gov/>. Acesso em: 18/04/2024.


Imaging Spectroradiometer) em função da sua alta disponibilidade e cobertura espaço-temporal, o que o torna adequado para esta aplicação (SONG et al., 2021). As séries temporais de acúmulo de biomassa foram geradas e reescaladas para a resolução temporal do *NDVI*, menos frequente que os dados meteorológicos, enquanto as séries temporais do balanço hídrico sequencial foram geradas em escala decendial. A Tabela 2 traz os detalhes da configuração original destes conjuntos.

Tabela 2 — Configurações originais dos conjuntos de dados utilizados nos modelos de balanço hídrico e de produtividade.

Parâmetro	Nasa-Power	MODIS
Resolução espacial	0,5° x 0,5°	250m
Resolução temporal	1 dia	16 dias
Período da série temporal	jan/1986 a dez/2019	jan/2013 a dez/2019
Falhas na série temporal	0%	0%
Variáveis fornecidas	$TEMP_{mín}$, $TEMP_{máx}$, $PREC$ e RAD_{par}	<i>NDVI</i>

Para as análises subsequentes, uma grade regular foi estabelecida e suas células foram classificadas pelos SPP por critério de maior sobreposição com os municípios. A resolução espacial dessa grade foi definida em 0,5° x 0,5° para coincidir com a resolução original da base meteorológica importada do sistema Nasa-Power (Tabela 2). A partir dessa grade, foi conduzida uma seleção aleatória de 20 regiões (células), identificadas pelo município de maior sobreposição e com repetição de 4 amostras por SPP. As células selecionadas foram empregadas para delimitar as comparações do comportamento dos modelos de produtividade e a construção dos modelos preditivos do nível de degradação utilizando dados SAR (Figura 6). Definições para diferenciação dos SPP estão apresentadas na seção 4.2.1 referente aos resultados obtidos pelo agrupamento dos municípios.

Figura 6 — Seleção aleatória de áreas representativas dos SPP. O nome atribuído a cada célula corresponde ao nome do município com maior sobreposição.



As séries temporais de produtividade observada e potencial das amostras dos SPP foram empregadas no ajuste de um modelo comum, baseado no método dos mínimos quadrados, com o objetivo de filtrá-las (suavizá-las) para: (i) eliminação de discrepâncias (*outliers*); (ii) e extração da sazonalidade com maior precisão. Nesse *framework*, a detecção e remoção dos dados *outliers* é feita com base nos resíduos identificados na decomposição da tendência sazonal (CLEVELAND et al., 1990), que tem como vantagem não demandar dados qualitativos acerca das observações das séries de dados, como é o caso neste trabalho. O ajuste do modelo, por sua vez, é feito por uma outra função, chamada de logística dupla, cuja Equação (11) é ajustada pelas inflexões da série à esquerda (x_1) e à direita (x_3) entre os pontos de máximo e mínimo ao longo do período (t) e ponderada pelas respectivas taxas de aumento (x_2) e declínio (x_4).

$$g(t; x_1, \dots, x_4) = \frac{1}{1 + \exp\left(\frac{x_1 - t}{x_2}\right)} - \frac{1}{1 + \exp\left(\frac{x_3 - t}{x_4}\right)} \quad (11)$$

Esta rotina está implementada e disponível na ferramenta Timesat¹¹ (JÖNSSON e EKLUNDH, 2002; EKLUNDH e JÖNSSON, 2016) e tem seu uso bastante estabelecido em aplicações de modelagem de séries temporais de dados remotos (JIANG et al., 2023; WANG et al., 2023; SILVA et al., 2020; SUN et al., 2024). No Apêndice 3 estão as configurações da ferramenta Timesat para modelagem das séries temporais.

Considerando um ponto aleatório de cada região amostral dentro da delimitação de áreas de pastagem de referência (PARENTE et al., 2017), o comportamento da série temporal de produtividade observada foi comparado por correlação de Pearson (r) com o comportamento da série de produtividade potencial da mesma região com o objetivo de avaliar se, ao longo do tempo, a variação da temperatura mínima ($TEMP_{min}$), que parametriza o modelo potencial (TONATO et al., 2010), acompanha a variação fenológica da produção de matéria seca em áreas de pastagem. Também foi traçada a correlação (r) entre a produtividade observada com a própria temperatura mínima ($TEMP_{min}$), com a precipitação ($PREC$), com a deficiência hídrica (DEF_{cad50} e DEF_{cad125}) e com o armazenamento de água (ARM_{cad50} e ARM_{cad125}) do balanço hídrico sequencial para avaliar se outras variáveis extraídas de modelos meteorológicos podem captar melhor a variação da produtividade observada, e se essa performance varia espacialmente. Adicionalmente, uma análise descritiva do comportamento dessas variáveis entre os percentis 20% e 80% foi empregada para entender se essa relação é mais fortemente captada em função da distribuição das chuvas ao longo do ano. Com relação ao clima local, as médias espaciais das amostras foram confrontadas com as médias mensais das variáveis meteorológicas e do balanço hídrico climatológico para avaliar se os SPP estão sob maior ou menor risco de degradação das suas áreas de pastagem em função dessas condicionantes ambientais. Essa avaliação foi feita analisando contrastes entre a média e a variância espaciais dessa produtividade com as condicionantes ambientais por meio de mapeamento dessas áreas e por meio da PCA (HAN et al., 2012; MANLY e ALBERTO, 2019; JAMES et al., 2023) extraídas a partir da matriz de correlação, que equaciona o peso de todas as variáveis no modelo. Por fim, uma análise expandida das áreas de todos os SPP e contingente de rebanho em cada SPP ajudou a identificar aqueles com maior ou menor performance em relação aos fatores de degradação e em relação ao risco associado à atividade pecuária nessas regiões.

¹¹ Disponível em: <https://web.nateko.lu.se/timesat/>. Acesso em: 20/04/2024.


3.2.4 Modelagem sazonal e elaboração do conjunto de dados de referência

Além do comportamento dos modelos de produtividade ao longo das séries temporais completas (2013-2019), também foram extraídos parâmetros sazonais referentes ao período 2015-2016 para a construção dos modelos preditivos de penalização da produtividade utilizando dados SAR a partir das séries filtradas pelo modelo descrito na Equação (10) (EKLUNDH e JÖNSSON, 2016) (Figura 7). Do conjunto de parâmetros disponíveis, o valor de base (d) e a produção acumulada total (i) (Figura 7) não foram empregados na construção dos modelos preditivos, sendo substituídos pelas taxas de incremento (x_2) e declínio (x_4) da função logística dupla (10). Adicionalmente, também foi calculada a penalização relativa da produção (PRP_g ; %)

$$PRP_g = \frac{(P_{pot,g} - P_{obs})}{P_{pot,g}} * 100 \quad (12)$$

para cada genótipo (g) entre o acumulado dos modelos potencial ($P_{pot,g}$) e observado (P_{obs}) referentes à temporada sazonal 2015-2016. Dessa forma, define-se neste trabalho a penalização da produtividade como o intervalo entre o potencial produtivo máximo estimado pelo modelo proposto por Tonato et al. (2010) e a produtividade observada a partir do modelo de Rosa e Sano (2013). A penalização da produtividade também foi analisada em função da variação das condições climáticas nas áreas amostrais de cada SPP com o objetivo de entender onde e sob quais condições estão as regiões com maior ou menor diferença de produção sazonal. Com isso, as análises conduzidas a partir desta etapa serão feitas de forma independente para cada amostra de cada SPP para posterior avaliação posterior das diferenças de desempenho dos modelos em função da variação das condições disponíveis em cada amostra.

Figura 7 — Parâmetros sazonais extraídos da ferramenta Timesat referentes ao (a) início (data e valor), (b) fim (data e valor), (c) duração (meses), (d) valor base, (e) data do ponto de produtividade máxima, (f) valor máximo, (g) amplitude (entre os pontos de base [d] e máximo [f]), (h) produção acumulada a partir da base e (i) produção acumulada total.



Fonte: Eklundh e Jönsson (2016)

O conjunto de dados para o mapeamento de referência e avaliação de performance (OLOFSSON et al., 2014) do modelo preditivo foi gerado a partir de classificação não-supervisionada conduzida sobre os parâmetros sazonais extraídos das séries temporais de produtividade (observada e potencial) para cada genótipo (U1 e C1). Essa classificação adotou abordagem semelhante àquela que deu origem aos SPP, ou seja, aplicação do algoritmo *K-Means* sobre o conjunto de dados normalizado pelo *z-score* após a remoção de discrepâncias. A classificação dos dados discrepantes ou *outliers*, contudo, foi feita pelo algoritmo *LOF* (HAN et al., 2012; BREUNIG et al., 2000), mais robusto que aquele descrito anteriormente pelo Intervalo InterQuartil (*IIQ*). Isto considera a complexidade da estrutura do conjunto de objetos composta por suas dimensões (i.e., parâmetros sazonais) e densidade (i.e., unidade equivalente ao pixel da imagem gerada com dados do sensor MODIS) ao comparar cada objeto com seus k_{LOF} vizinhos mais próximos. Sua aplicabilidade está justificada pela adoção em análises de dados com alta dimensionalidade e/ou complexidade, como aqueles fornecidos por sensores hiperspectrais (TU et al., 2018; YU et al., 2021) ou baseados em LiDAR (CHEN et al., 2019).


A parametrização do algoritmo se deu seguindo os experimentos em BREUNIG et al. (2000), onde os autores relataram a obtenção de resultados plausíveis a partir de $k_{LOF}=20$, valor adotado no processo de detecção e remoção dos *outliers* neste trabalho. O critério de retenção dos K_{PDP} Perfis de Degradação das áreas de Pastagem (PDP) foi o mesmo adotado para a retenção de K_{SPP} . Nessa etapa, a maior redução da inércia em relação ao agrupamento unitário variou entre 2 e 5 K_{PDP} , o que resultou na fixação de $K_{PDP}=4$ para todas as amostras.

3.2.5 Preparação do conjunto de dados de Radar de Abertura Sintética (SAR)

Antes da criação dos modelos de classificação, todo o conjunto de dados SAR foi submetido a um processamento prévio que deu origem aos parâmetros polarimétricos (Figura 8) empregados nesta tarefa. Esses procedimentos foram repetidos com as mesmas configurações em todas as amostras dos SPP utilizando a ferramenta SNAP¹² (*Sentinel Application Platform*). Embora todas as etapas do pré-processamento sejam fundamentais para a utilização adequada dos dados SAR e objeto de estudo em inúmeros trabalhos de otimização do uso dessa tecnologia (ZHANG et al., 2020; SHEN et al., 2021; KANG e BAEK, 2022; YANG et al., 2022;), no escopo deste trabalho elas são intermediárias e a esquematização completa teve como objetivo apenas formalizar sua realização. Outros trabalhos (VAGHELA et al., 2020; BRAUN e OFFERMANN, 2022; JIAO et al., 2022) apresentam este *framework* com formato semelhante ou com variações em função da aplicação específica que se pretende realizar (e.g., diferenciação de vários tipos de alvo ou relação entre suas propriedades estruturais e dielétricas).

¹² Disponível em: <https://step.esa.int/main/toolboxes/snap/>. Acesso em: 25/04/2024.

Figura 8 — Fluxograma de processamento das imagens SAR para gerar as variáveis empregadas na construção do modelo preditivo. Os nomes das etapas de processamento estão em inglês para facilitar a localização destas no menu de opções da ferramenta SNAP. As etapas destacadas em azul estão descritas com maior detalhamento a seguir.



As configurações do sistema SAR para envio e recebimento do sinal são importantes para entender as possibilidades e restrições das aplicações de monitoramento utilizando os dados Sentinel-1. As informações da Tabela 3 descrevem as características centrais do sistema SAR ou aquelas cuja transformação tiveram implicações diretas nos resultados. Informações mais detalhadas podem ser encontradas em Torres et al. (2012) e nas páginas oficiais da missão¹³.

¹³ Disponível em: <https://sentiwiki.copernicus.eu/web/sentinel-1>. Acesso em: 24/04/2024.

Tabela 3 — Descrição geral da plataforma e do instrumento (antena) SAR de envio e recebimento de sinal.

Parâmetro	Valor
Plataforma	Sentinel-1A
Trajetória	Descendente
Altitude	693km
Tempo de revisita	12 dias
Frequência central	5,405GHz
Comprimento de onda (λ)	$\approx 5,55\text{cm}$
Direcionamento da antena	À direita
Polarização	Dual-polarimétrica (VV e VH)
Produto	<i>Single Look Complex</i> (SLC)
Modo de aquisição	<i>Interferometric Wide Swath</i> (IW)
Resolução espacial (IW)	5m (<i>range</i>) x 20m (<i>azimuth</i>) (visada única)
Ângulo de incidência (θ) (IW)	Entre $18,3^\circ$ e $46,8^\circ$
Largura de varredura total (IW)	250km
Número de subfaixas de varredura (IW)	3

Em todas as amostras dos SPP, as imagens SAR foram selecionadas o mais próximo possível da data de máxima produtividade observada (P_{obs}) (Figura 7), para maximizar tanto a resposta do sinal do radar relativo às condições estruturais e dielétricas da vegetação (RICHARDS, 2009), quanto o contraste com áreas de solo exposto, característico de pastagem sob degradação biológica (DIAS-FILHO, 2015). Objetivamente, esta seleção compreendeu o período entre 16/12/2015 e 28/01/2016 e a data exata variou para cada amostra em função da sua disponibilidade dado o período de revisita do satélite (Tabela 3). Por restrição operacional, não foi realizada a amostragem para outras datas que possibilitassem uma avaliação temporal da resposta da vegetação no sinal do radar (RAAB et al., 2020; SILVA-PEREZ et al., 2021; MURO et al., 2022), mas os resultados obtidos a partir de uma única data também foram instrumento de reflexão e comparação com trabalhos correlatos. O produto SLC empregado nas análises foi escolhido por preservar a fase relativa entre as componentes vertical (V) e horizontal (H) da onda eletromagnética retroespalhada pelo alvo, característica que denota o maior potencial analítico da tecnologia SAR (RANEY, 2006; RICHARDS et al., 2009).

O objetivo da polarimetria é modelar a relação entre o sinal incidente (E_i) e o retroespalhado (E_b), sob todas as configurações de polarização possíveis para descrever a

interferência causada pela superfície imageada. Uma forma de extrair as informações sobre o alvo é através da sua matriz de espalhamento, também conhecida como matriz de Sinclair (S) (RICHARDS, 2009), descrita pela Equação (13)

$$\begin{bmatrix} E_H^b \\ E_V^b \end{bmatrix} = \begin{bmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{bmatrix} \begin{bmatrix} E_H^i \\ E_V^i \end{bmatrix} \quad (13)$$


sendo $S_{VH} \equiv S_{HV}$ por uma condição assumida de reciprocidade. Dessa relação fundamental, um dos produtos possíveis de serem gerados para representar as propriedades espalhativas do alvo é a sua matriz de covariância (C). Sendo o Sentinel-1 um sistema dual-polarimétrico, ele é capaz de transmitir sinal com polarização apenas vertical e de receber o sinal retroespalhado (eco) com polarização vertical (V) e horizontal (H). Dessa forma, sua matriz C possível tem dimensões 2 x 2 cujo formato é

$$C = \begin{bmatrix} \langle S_{VV} S_{VV}^* \rangle & \langle S_{VV} S_{VH}^* \rangle \\ \langle S_{VH} S_{VV}^* \rangle & \langle S_{VH} S_{VH}^* \rangle \end{bmatrix} \quad (14)$$

podendo ser usada para descrever as propriedades desse alvo (os colchetes angulares denotam a média de várias leituras de um mesmo alvo e os asteriscos representam o conjugado transposto do número imaginário).

Em seguida, foi realizada a filtragem de C para redução do fenômeno de “mosqueamento” (*speckle filter*), característico de imagens SAR. Ainda que seja uma condição que demande o tratamento devido para viabilizar análises da cena imageada, especialmente de natureza quantitativa, esse fenômeno não se classifica formalmente como um ruído tal qual a presença de nuvens em relação a sensores óticos, quando o objetivo é analisar alvos na superfície, mas sim uma consequência da coerência do sinal incidente sobre os alvos. O princípio desse fenômeno está na composição da célula de resolução (i.e., unidade de imageamento análoga ao pixel no sensoriamento remoto ótico) (Tabela 3) por diversos alvos que reagem individualmente e de forma cumulativa com o sinal incidente (Figura 9). Além disso, como o comprimento da onda eletromagnética incidente é sensivelmente menor que a célula de resolução (Tabela 3), fazendo com que a fase da onda retroespalhada e definida pela agregação dos alvos dentro da célula seja randômica a partir da interferência destrutiva ou construtiva dos alvos sobre a fase inicial.

Figura 9 — Geração do mosqueamento (*speckle*) pela interferência de vários alvos dentro da célula de resolução retroespalhando o sinal incidente.



Fonte: Richards (2009)

A correção do “mosqueamento” é feita por modelos teóricos locais que buscam a otimização da qualidade da imagem pela redução desse efeito, visto que sua remoção completa é impraticável. Os filtros mais simples o fazem sumalizando a imagem pela média, mas causam distorções em regiões heterogêneas, onde a presença de alvos discretos e bordas espaciais é mascarada (RICHARDS, 2009). Uma alternativa mais eficiente está na adoção de filtros adaptativos que considerem a variação das células adjacentes na escolha daqueles que vão compor o modelo. Assim, o Filtro Refinado de Lee (LEE et al., 2009; MA et al., 2018) (*Refined Lee Filter*) foi adotado por ter essa característica de reduzir o “mosqueamento” enquanto preserva as bordas de transição em áreas de alta frequência espacial. Considerando que a relação entre o valor real (x) sem a presença de “mosqueamento” (s), e o valor sob este efeito (z) se dá por

$$z = xs \quad (15)$$

esse filtro opera estimando o valor filtrado ($\hat{x}$) pelo modelo

$$\hat{x} = \langle z \rangle + b(z - \langle z \rangle) \quad (16)$$

onde o valor original da célula de resolução (z) é comparada com a média dos seus vizinhos mais próximos ($\langle z \rangle$) e balizada por um coeficiente de adaptação (b)

$$b = \frac{var(x)}{var(z)} \quad (17)$$

que se estimado em uma região com pouca variação (i.e., $var(x)$ reduzida), $b \rightarrow 0$ e $\hat{x}$ assumirá o valor da média local ($\langle z \rangle$). Caso contrário, $var(x) \approx var(z)$ e z não será alterado. O valor de $var(x)$, inicialmente desconhecido, pode ser estimado por

$$var(x) = \frac{var(z) - \langle z \rangle^2 \eta^2}{1 + \eta^2} \quad (18)$$

sendo η^2 o desvio padrão de uma variável contínua de distribuição exponencial.

Nesse trabalho, o filtro foi configurado com uma janela de 17 x 17 células de resolução vizinhas para estimar $\langle z \rangle$ e 4 visadas *looks* para estimar η com o objetivo de suavizar ao máximo a textura da imagem e remover a heterogeneidade de alvos discretos (MEDASANI e REDDY, 2018; GIERSEWSKA e BEREZOWSKI, 2022).

As matrizes de espalhamento (S) ou de covariância (C), sua derivada imediata, descrevem as propriedades espalhativas do alvo com relação à copolarização e à polarização cruzada. Essa informação, no entanto, não explica completamente a relação polarimétrica que retorna à antena após a interação com o alvo. Dessa forma, é possível empregar a matriz de covariância (C) na determinação do vetor de Stokes (VS), cujos parâmetros são definidos pela Equação (19)

$$g_0 = a_H^2 + a_V^2 \quad (19.a)$$

$$g_1 = a_H^2 - a_V^2 \quad (19.b)$$

$$g_2 = 2a_H a_V \cos \delta \quad (19.c)$$

$$g_3 = 2a_H a_V \sin \delta \quad (19.d)$$

Este vetor avança na discriminação dos alvos por adicionar uma camada correspondente ao produto cruzado entre as partes complexas das amplitudes nos canais horizontal (a_H) e vertical (a_V) a partir de combinações lineares entre esse produto cruzado com a densidade de potência das parcelas co-polarizada e de polarização cruzada do sinal retroespalhado. Isso permite análises quantitativas de forma coerente, ou seja, com preservação

da fase relativa (δ) (RANEY, 2006; VERMA et al., 2023). Na definição dos parâmetros, g_0 (W.m^{-2}) representa a potência total do sinal retroespalhado, g_1 indica se este estará mais polarizado horizontal ou verticalmente e g_2 e g_3 indicam, em conjunto, a elipticidade da polarização: (i) se $\delta=0^\circ$, $g_3=0$ e a polarização será linear; (ii) se $\delta=90^\circ$, $g_2=0$ e a elipse estará alinhada vertical ou horizontalmente, sendo circular se a magnitude das componentes ortogonais (H e V) forem iguais (RICHARDS, 2009).

Da forma que foi apresentado, o vetor de Stokes mede a densidade de potência do sinal polarizado (g^{pol}), o que teoricamente seria a única forma de medir o sinal retroespalhado. No entanto, alguns meios como o vegetado podem apresentar estruturas altamente aleatórias e, nesse caso, sua interação com o sinal incidente originam uma resposta não-polarizada, que na realidade tem sua polarização altamente aleatória de forma que não é possível defini-la. Entretanto, ela também dispõe de densidade de potência e, portanto, pode ser medida e usada na discriminação de alvos (WANG et al., 2019; WANG et al., 2022). Esse eco depolarizado (g^{dpol}) tem o formato

$$g^{dpol} = \begin{bmatrix} g_0^{dpol} \\ g_1^{dpol} \\ g_2^{dpol} \\ g_3^{dpol} \end{bmatrix} = \begin{bmatrix} 2\langle a_H^2 \rangle \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (20)$$

e define o elemento g_0^{dpol} como o dobro da potência da componente ortogonal horizontal. Ele, somado à parcela polarizada (g_0^{pol}), compõe a densidade de potência total do sinal retroespalhado (g_0). Na realidade, esse elemento também poderia ser definido pela densidade da componente vertical, pois sendo ambas grandezas aleatórias, elas se equivalem na média calculada na dimensão do tempo. Os demais elementos do vetor serão zerados, pois a média de uma função trigonométrica com variação aleatória é zero. Assim, utilizando as grandezas medidas pela parcela polarizada e não-polarizada do sinal retroespalhado, calcula-se o grau de polarização (GP) por

$$GP = \frac{g_0^{pol}}{g_0^{pol} + g_0^{dpol}} = \frac{g_0^{pol}}{g_0} = \frac{\sqrt{g_1^2 + g_2^2 + g_3^2}}{g_0^2} \quad (21)$$

que por sua vez dá origem ao grau de depolarização (GD), calculado por

$$GD = 1 - GP \quad (22)$$

Entre a polarização puramente circular ou puramente linear, a situação mais comum é que o sinal retroespalhado seja composto por duas componentes ortogonais (a_H e a_V) com intensidade variável. A diferença de intensidade desses componentes pode ser medida pelo ângulo de elipticidade (ε) da polarização

$$\varepsilon = \frac{g_3}{g_0} \quad (23)$$

e que em meios vegetados pode indicar características singulares acerca do estágio fenológico das culturas (JIAO et al., 2022; ROBERTSON et al., 2022).

A razão de polarização circular (RCP) foi calculada a partir do vetor de Stokes (19) por

$$RCP = \frac{g_0 - g_3}{g_0 + g_3} \quad (23)$$

e sua influência foi analisada de acordo com o potencial de prejudicar a classificação, dado que o Sentinel-1 não se configura como um sistema de polarização compacta ou completa (*fully polarimetric*). Portanto, em tese, ele não dispõe de recursos informacionais para capturar a informação contida neste parâmetro caso este fosse gerado sob condições ideais (RANEY, 2006; RICHARDS, 2009; CHARBONNEAU et al., 2010).

Por fim, na etapa de correção geométrica das imagens SAR, os parâmetros relacionados ao ângulo de incidência local (θ) e elevação do terreno (*Elev*) foram obtidos a partir do modelo digital de elevação (DEM, em inglês) construído com dados da missão SRTM¹⁴ (*Shuttle Radar Topography Mission*). Em aplicações de monitoramento utilizando dados SAR, a performance dos algoritmos de classificação de áreas de pastagem e milho aumentaram sensivelmente pela utilização da informação disponibilizada pelo ângulo de incidência local (θ) (BUCKLEY e SMITH, 2010; TAMM et al., 2016; BAGHDADI et al., 2017; MA et al., 2024). A elevação (*Elev*) foi capaz de adicionar uma camada de contexto para discriminação da intensidade da prática pecuária em áreas montanhosas na Suíça (BUHVALD et al., 2022), justificando seu uso.

¹⁴ Disponível em: <https://www.earthdata.nasa.gov/sensors/srtm>. Acesso em: 20/10/2023.

3.2.6 Modelagem preditiva de penalização da produtividade

Para analisar a viabilidade de empregar dados SAR na identificação dos perfis de penalização da produtividade potencial das pastagens a partir de suas características estruturais e dielétricas, modelos preditivos foram gerados utilizando diferentes algoritmos para comparação da performance em relação à abordagem adotada por cada um. Previamente, também foram executadas etapas de preparação dos dados para otimizar a performance dos modelos gerados (Figura 10). Nestas etapas, as principais bibliotecas empregadas foram o Pandas¹⁵, xarray¹⁶, Scikit-Learn¹⁷ e Weka¹⁸.


¹⁵ Disponível em: <https://pandas.pydata.org/>. Acesso em: 22/07/2024.

¹⁶ Disponível em: <https://xarray.dev/>. Acesso em: 22/07/2024.

¹⁷ Disponível em: <https://scikit-learn.org/stable/index.html/>. Acesso em: 22/07/2024.

¹⁸ Disponível em: <https://ml.cms.waikato.ac.nz/weka/>. Acesso em: 22/07/2024.

Figura 10 — Fluxograma do modelo de classificação dos dados SAR para a penalização da produtividade potencial das pastagens.



A amostragem dos dados foi realizada seguindo o protocolo de boas práticas proposto por Oloffson et al. (2014), não tendo sido realizadas coletas de dados de campo com cobertura sobre todas as amostras de todos os SPP. Devido a isso, a seleção das amostras de referência seguiu a estratégia aleatória estratificada, cujos estratos foram os produtos da classificação não-supervisionada dos parâmetros sazonais das séries temporais de produtividade potencial e observada, tomados como mapeamento de referência.

A unidade básica de avaliação espacial do mapeamento de referência seria o pixel do sensor MODIS (250m). Como a sua resolução é menor que aquela da imagem SAR (14m após as etapas de pré-processamento), essa unidade foi assumida como um polígono de referência. Assim, dentro de cada unidade, foram amostrados 5 pontos escolhidos aleatoriamente e o tamanho total do conjunto variou em função da área sob pastagem em cada amostra de cada SPP (Tabelas 4 e 5). Com relação à qualidade do mapa de referência, foi assumido que esta característica é superior àquela apresentada pelas imagens SAR, por estar modelada de acordo com as características temporais e sazonais das áreas avaliadas.

Tabela 4 — Número de pontos das amostras empregadas na construção dos modelos preditivos dos grupos de pastagem referentes ao genótipo U1.

Local	Grupo			
	#1	#2	#3	#4
SPP 1				
Ponta Porã-MS	3.755	6.140	950	1.065
Tesouro-MT	12.395	15.095	8.845	3.580
Avaré-SP	410	3.365	3.855	2.550
Água Fria de Goiás-GO	3.485	3.735	1.695	1.735
SPP 2				
Itaporã-MS	6.090	8.450	3.865	360
Rio Verde-GO	900	2.835	2.095	4.605
Birigui-SP	8.210	740	5.115	5.740
Campo Novo do Parecis-MT	2.000	1.785	595	1.345
SPP 3				
Rondonópolis-MT	11.395	17.855	3.995	10.780
Naviraí-MS	21.890	18.795	9.040	1.615
Crixás-GO	9.935	17.740	9.630	6.875
Piracanjuba-GO	5.810	11.605	22.465	11.845
SPP 4				
Canarana-MT	21.015	24.540	4.320	18.880
Porto Murtinho-MS	22.960	2.645	17.485	8.750
Campo Grande-MS	17.340	33.840	24.675	45.515
Serranópolis-GO	1.105	820	245	815
SPP 5				
Alcinópolis-MS	32.885	24.095	31.200	29.415
Montes Claros de Goiás-GO	27.335	38.310	14.410	24.250
Aparecida do Taboado-MS	17.150	18.585	23.370	17.840
Porangatu-GO	8.605	18.195	17.670	10.000

Tabela 5 — Número de pontos das amostras empregadas na construção dos modelos preditivos dos grupos de pastagem referentes ao genótipo C1.

Local	Grupo			
	#1	#2	#3	#4
SPP 1				
Ponta Porã-MS	325	9.065	265	2.275
Tesouro-MT	12.435	14.575	4.015	8.890
Avaré-SP	190	4.875	2.870	2.200
Água Fria de Goiás-GO	2.860	4.130	1.980	1.685
SPP 2				
Itaporã-MS	6.095	8.520	3.635	515
Rio Verde-GO	2.145	2.795	5.265	230
Birigui-SP	7.275	6.570	5.370	600
Campo Novo do Parecis-MT	2.000	1.795	595	1.335
SPP 3				
Rondonópolis-MT	12.665	16.355	10.575	4.455
Naviraí-MS	19.265	22.685	7.770	1.500
Crixás-GO	9.945	17.895	6.885	9.470
Piracanjuba-GO	5.815	11.615	11.825	22.485
SPP 4				
Canarana-MT	23.025	22.085	20.250	3.420
Porto Murtinho-MS	19.720	20.095	9.900	2.160
Campo Grande-MS	41.160	31.005	41.620	7.545
Serranópolis-GO	1.105	815	250	815
SPP 5				
Alcinópolis-MS	32.960	24.100	29.355	31.185
Montes Claros de Goiás-GO	10.435	24.345	37.910	31.690
Aparecida do Taboado-MS	14.490	19.300	18.520	24.655
Porangatu-GO	8.610	10.265	17.630	17.950

No início da etapa de preparação, a detecção de *outliers* e normalização dos dados foi realizada empregando o intervalo interquartil (*IIQ*) (3) (HAN et al., 2012) e *z-score* (1), respectivamente, seguindo a mesma estratégia na definição dos SPP. Em seguida, os dados foram segmentados em dois conjuntos para treino (66%) e teste (33%) dos modelos.

Algoritmos preditivos tradicionais buscam minimizar os erros gerados na classificação assumindo equilíbrio da distribuição das classes e no custo entre os erros falso-positivos e falso-negativos (HAN et al., 2012). Esta premissa frequentemente não existe em conjuntos de dados reais e, portanto, demanda adoção de medidas de contorno. Nesse trabalho, a estratégia adotada para eliminar o desbalanceamento entre as classes de pastagem ($N_{cPastagem}$) foi o ajuste inversamente proporcional dos pesos de cada classe ($[W_{cPastagem}]$) baseado na sua frequência de ocorrência ($[Freq_{cPastagem}]$) no conjunto de treinamento dos modelos a partir de

$$[W_{cPastagem}] = \frac{1}{(N_{cPastagem} - [Freq_{cPastagem}])} \quad (25)$$

Os modelos de classificação foram construídos a partir de algoritmos amplamente empregados em aplicações de sensoriamento remoto. Embora na literatura haja trabalhos onde seu desempenho é comparável, estes algoritmos diferem quanto à sua taxonomia (HAN et al., 2012; JAMES et al., 2023) e podem ter sua performance influenciada pelas características da aplicação e do conjunto de dados (CRACKNELL e READING, 2014; CAMPOS-TABERNER et al., 2019). O desempenho de todos esses algoritmos será avaliado pela sua capacidade preditiva da penalização de produtividade potencial.

O algoritmo *k-Nearest Neighbor* (kNN), primeiro e mais simples da série aplicada, é expresso por

$$Pr(Y = j|X = x_0) = \frac{1}{k} \sum_{i \in \mathcal{N}_0} I(y_i = j) \quad (26)$$

e confere uma classe (j) a um registro (i) pela maximização da probabilidade condicional definida pela semelhança das suas propriedades (x_0) com aquelas do grupo de registros mais próximos ($\mathcal{N}_0$) que também pertençam à classe j .

Sua parametrização é definida pelo número (k) de registros vizinhos mais próximos na composição do grupo ($\mathcal{N}_0$) que vai conferir maior ou menor flexibilização da fronteira de decisão da classificação. Nesse trabalho, em razão da semelhança entre as classes do conjunto de dados, o melhor desempenho foi obtido aumentando a flexibilização da fronteira de decisão (i.e., restringindo a generalização) com $k=2$ vizinhos mais próximos, o que gera um classificador com menor viés, porém com alta variabilidade (JAMES et al., 2023). Xiao et al.

(2021) obtiveram acurácia geral acima de 98% na diferenciação de culturas agrícolas classificando séries temporais de dados SAR adotando $k=5$ para aumentar a flexibilização da fronteira de decisão.

O algoritmo *Naive Bayes* (NB) também foi empregado para avaliação do seu desempenho. Assumindo independência entre os atributos preditores (p), esse algoritmo calcula a probabilidade *a posteriori* de um objeto (X) pertencer à determinada classe (k) pela expressão


$$Pr(Y = k|X = x) = \frac{\pi_k \prod_{m=1}^p f_{k,m}(x_m)}{\sum_{l=1}^K (\prod_{m=1}^p \pi_l f_{l,m}(x_m))} \quad (27)$$

modulada em função da probabilidade *a priori* (π_k) de cada uma das classes (K) e da função densidade de cada atributo ($f_{k,p}(x_p)$) (JAMES et al., 2023). Embora simples, esse algoritmo é capaz de produzir resultados satisfatórios em aplicações envolvendo análise de dados SAR (MA et al., 2019).

Saindo da dinâmica probabilística, o algoritmo SVM (CORTES e VAPNIK, 1995) é um dos algoritmos de aprendizado de máquina mais avançados disponíveis na literatura e foi empregado neste trabalho para avaliação do seu desempenho. Fundamentado na identificação dos exemplos essenciais (i.e., os vetores de suporte) que permitem definir o hiperplano marginal máximo de separabilidade entre duas classes (Figura 11), esse algoritmo tem sua complexidade determinada pela quantidade de vetores de suporte e não pelo número de atributos preditores presentes (HAN et al., 2012; JAMES et al., 2023). Embora isto culmine em custo computacional mais alto para otimização do hiperplano durante o treinamento, também reduz a susceptibilidade do modelo gerado ao *overfitting*, também possibilita a obtenção de resultados robustos com poucos exemplos para treinamento, características desejáveis em aplicações de sensoriamento remoto (MOUNTRAKIS et al, 2011), onde o levantamento de amostras em campo pode ser um obstáculo operacional (OLOFFSSON, 2014).

Em aplicações com dados SAR, modelos de classificação baseados em SVM costumam apresentar acurácia geral superior a 80% (WANG et al. 2019; CAMPOS-TABERNER et al., 2019; SHEYKHMUSA et al., 2020; ASADI e SHASODDINI, 2024), embora seu uso ainda seja incipiente. Segundo o levantamento conduzido por Sheykhmousa et al. (2020), apenas 4% dos trabalhos avaliados eram dedicados a este tipo de fonte de dados.

Figura 11 — Hiperplano de separabilidade entre as classes.



Fonte: Adaptado de Han et al. (2012).

Pela definição matemática, o hiperplano no modelo SVM

$$\mathbf{W} \cdot \mathbf{X} + b = 0 \quad (28)$$

resulta de um produto cruzado entre os exemplos de treinamento, definidos como vetores de suporte ($\mathbf{X}$), e um vetor de ponderação ($\mathbf{W}$) de mesma dimensão (p), agregado por um valor numérico (b) que representa o viés do modelo. Com isso, a classificação (j) se dá pelo posicionamento dos registros em relação ao hiperplano

$$H_1: b + \sum_{i=1}^p w_i x_i \geq 1 \text{ para } y_j = +1 \quad (29.1)$$

$$H_1: b + \sum_{i=1}^p w_i x_i \leq 1 \text{ para } y_j = -1 \quad (29.2)$$

cujas margens são calculadas pela distância deste com o objeto mais próximo de H_1 , calculado por $\frac{1}{\|\mathbf{W}\|}$, ou de H_2 , por $\frac{2}{\|\mathbf{W}\|}$, sendo $\|\mathbf{W}\|$ a norma Euclidiana ($\sqrt{\mathbf{W} \cdot \mathbf{W}} = \sqrt{\sum_{i=1}^p w_i^2}$). A partir disso, a maximização da margem ($\mathbf{W}$) é encontrada por métodos Lagrangianos de otimização quadrática cuja descrição excede o escopo deste trabalho e pode ser encontrada com maior detalhamento em James et al. (2023), Hastie et al. (2009) e Cortes e Vapnik (1995).

Após a identificação dos vetores de suporte e definição do hiperplano (i.e., treinamento do modelo), novos objetos para teste ou aplicação do modelo são classificados utilizando a expressão

$$d(\mathbf{X}^T) = \sum_{i=1}^l y_i a_i \mathbf{X}_i \mathbf{X}^T + b_0 \quad (30)$$

onde y_i é a classe do vetor de suporte ($\mathbf{X}_i$), $\mathbf{X}^T$ é o objeto a ser classificado, a_i e b_0 são os multiplicadores Lagrangianos gerados na otimização das margens e l é o número de vetores de suporte identificados. Do resultado da expressão (30), é o seu sinal que dá a classificação do novo objeto.

Em aplicações práticas, um hiperplano de separação linear entre as classes não poderá ser prontamente definido, sendo necessária a adoção de *kernels*

$$K(\mathbf{X}_i, \mathbf{X}_j) = \phi(\mathbf{X}_i) \cdot \phi(\mathbf{X}_j) \quad (31)$$

que são funções de transformação sobre os conjuntos de treino ($\mathbf{X}_i$) e teste ($\mathbf{X}_j$) para conversão a uma dimensão superior que permita a definição do hiperplano linear. A escolha do tipo de *kernel*, a princípio, não influencia significativamente os resultados, mas o ajuste dos seus parâmetros deve ser feito empiricamente (HAN et al., 2012). Neste trabalho foi adotado o *kernel Radial Basis Function* (RBF)

$$K(\mathbf{X}_i, \mathbf{X}_j) = e^{-\frac{\|\mathbf{X}_i - \mathbf{X}_j\|^2}{2\sigma^2}} = e^{-\gamma(\mathbf{X}_i - \mathbf{X}_j)^2} \quad (32)$$

proposto por Cortes e Vapnik (1995) com ajuste empírico da função custo ($C=10$), que limita os multiplicadores Lagrangianos, e do parâmetro *gamma* ($\gamma=0,2$) do *kernel* escolhido.

O último modelo foi gerado utilizando *Random Forest* (RF). Com uma abordagem que difere dos demais, este algoritmo avança sobre a metodologia tradicional de árvores de decisão seguindo uma lógica de consenso por séries de árvores de decisão (B) com configurações distintas que, quando combinadas, aumentam expressivamente sua acurácia (JAMES et al., 2023; HAN et al., 2012). Sua parametrização simplificada e robustez ao *overfitting* e a presença de ruídos nos dados (CRACKNELL e READING, 2014) respaldam sua dominância em aplicações de sensoriamento remoto mais recentes (SHEYKHMUSA et al., 2020). No caso da análise de dados SAR, o emprego do algoritmo RF tem sido mais frequente

que o SVM, observando-se vantagem em relação à performance obtida (SHEYKHOUSA et al., 2020).

Na construção do modelo RF, séries de árvores de decisão não correlacionadas entre si são geradas seguindo um método de seleção aleatória, binária e recursiva (i.e., avaliando o erro associado em cada seleção, sem considerar o impacto nas divisões subsequentes) de subconjuntos (m) dos atributos preditores originais (p), elegendo como região preditora (i.e., fronteira de decisão dos atributos) aquela que promove a maior redução do erro de classificação. Nesta etapa, o critério adotado para avaliação do erro preditivo a cada segmentação dos internódios das árvores foi o Ganho de Informação (D), ou Entropia, definido por

$$D = - \sum_{k=1}^K \hat{p}_{i,k} \log \hat{p}_{i,k} \quad (33)$$

que será tão menor quanto mais pura ($\hat{p}_{i,k}$) for a distribuição das classes (K) em determinada região de classificação (i) (JAMES et al., 2023).

Para definição do tamanho do subconjunto de atributos preditores (m), utilizados na construção das árvores, não há uma regra universal que deva ser seguida, embora a relação $m = \sqrt{p}$ seja comumente recomendada para avaliações preliminares (BELGIU e DRĂGUT, 2016; JAMES et al., 2023).

Neste trabalho, o critério $m = \text{int}(\log_2 p + 1)$ foi adotado para a seleção aleatória dos subconjuntos em razão de ser o padrão do pacote computacional empregado na construção e avaliação do modelo. O número de árvores aleatórias geradas foi fixado em $B=200$ para todas as amostras em todos os SPP, por ter sido o ponto de máxima redução do erro de classificação.

A avaliação de desempenho dos modelos gerados foi feita utilizando protocolos de melhores práticas para avaliação de tarefas preditivas em sensoriamento remoto (OLOFSSON et al., 2014). A acurácia geral (AG) mede a taxa de acerto geral do modelo considerando a correta classificação das classes minoritária (VP) e majoritárias (VN) sobre sua distribuição total (P e N). Complementarmente, cada classe (k) foi analisada de forma individualizada pela acurácia do produtor (AP) e acurácia do usuário (AU), que medem, respectivamente, a concordância do mapeamento do ponto de vista (i) do mapeamento de referência previamente descrito e (ii) do modelo de classificação.

$$AG = \frac{VP + VN}{P + N} \quad (34)$$

$$AP_k = \frac{VP_k}{P_k} \quad (35)$$

$$AU_k = \frac{VP_k}{VP_k + FP_k} \quad (36)$$

sendo FP a taxa de classificação incorreta de classes majoritárias como a classe minoritária.

Em outras obras de referência para métodos de mineração de dados e aprendizado de máquina, como Han et al. (2012) e James et al. (2023), a acurácia do produtor (AP) está referida como *true positive rate*, *sensitivity* ou *recall*. A acurácia do usuário (AU) está definida pelo sinônimo *precision*. O índice Kappa, frequentemente presente na validação de mapeamento gerado por técnicas de sensoriamento remoto (McNAIRN e BRISCO, 2004; KORDI e YOUSEFI, 2022; ASADI e SHAMSODDINI, 2024) não foi empregado por ser uma métrica baseada na aleatoriedade na distribuição das classes, o que não ocorre em aplicações de natureza geográfica e, portanto, tem seu uso desencorajado (PONTIUS Jr. e MILONES, 2010; PONTIUS Jr., 2022).

A camada vetorial empregada na delimitação da área de pastagem é um produto de classificação previa com acurácia geral entre 80% (PARENTE e FERREIRA, 2018) e 87% (PARENTE et al., 2017). Como consequência, há a consideração de outros tipos de cobertura como área de pastagem, o que implica na transferência da incerteza associada para aplicações de monitoramento de pastagem como descrito anteriormente neste trabalho. Para mitigar ou dirimir o impacto dessa incerteza, e considerando apenas o modelo de melhor desempenho inicial, foi conduzida uma repetição das etapas de amostragem, construção do modelo e avaliação do desempenho desconsiderando a classe com menor acurácia em cada amostra de cada SPP. Abordagem semelhante foi adotada por SANTOS et al. (2021), na avaliação de padrões espaço-temporais de amostragem de diferentes classes de uso e cobertura do solo.

4 RESULTADOS E DISCUSSÃO

4.1 CARACTERIZAÇÃO DA FERTILIDADE DAS PASTAGENS BRASILEIRAS

4.1.1 Caracterização dimensional do perfil de fertilidade em áreas de pastagens

As Componentes Principais (CPs) retidas englobaram 59,12% da variância total do conjunto de dados, e seus coeficientes sugerem duas dimensões que contrastam as características físicas e químicas do solo, em arranjos e intensidades distintas na constituição de cada CP (Tabela 6).

Por um lado, a 1ª CP foi ponderada positivamente pela maior concentração de cátions, teor de carbono e matéria orgânica, estoque de nitrogênio e acidez ativa e potencial. A densidade do solo atuou no sentido contrário, comportamento que corrobora Zhu et. al. (2021) e Baumann et al. (2022) sobre a importância de considerar este fator na análise da fertilidade em escalas mais amplas e motiva iniciativas como a de Panagos et al. (2024) de mapear e estimar esse parâmetro em escala continental para toda a Europa.

Por outro lado, a 2ª CP foi ponderada positivamente principalmente por níveis mais acentuados de alumínio e acidez potencial, seguida pelo estoque de nitrogênio – provavelmente relacionado às formas amoniacal e ao processo de nitrificação, no qual o hidrogênio é liberado para a solução do solo e promove aumento da acidez (SINGH, 2018; ALVES et al., 2019) – e teor de carbono e matéria orgânica, contrapondo o *pH* (i.e., ponderando negativamente) e concentrações de cálcio, magnésio, fósforo, potássio e densidade aparente do solo.


Assim, a 1ª CP poderia ser tratada como a relação entre concentração de nutrientes e densidade do solo, o que se traduz em uma dimensão relacionada à fertilidade do solo, enquanto a 2ª CP mede a dinâmica em torno da acidez do solo.

Tabela 6. Constituição das CPs retidas por cada atributo de análise do solo. Os valores entre parênteses representam a quantidade de variância contabilizada por cada um.

Atributo	1ª CP (35,09%)	2ª CP (24,30%)
	(variância contida)	
<i>DS</i>	-0,30 (09,00%)	-0,16 (02,56%)
<i>C</i>	0,43 (18,49%)	0,16 (02,56%)
<i>N</i>	0,33 (10,89%)	0,18 (03,24%)
<i>pH</i>	0,14 (01,96%)	-0,49 (24,01%)
<i>MO</i>	0,40 (16,00%)	0,12 (01,44%)
<i>P</i>	0,13 (01,69%)	-0,18 (03,24%)
<i>K</i>	0,28 (07,84%)	-0,16 (02,56%)
<i>Ca</i>	0,38 (14,44%)	-0,28 (07,84%)
<i>Mg</i>	0,37 (13,69%)	-0,25 (06,25%)
<i>Al</i>	0,00 (00,00%)	0,48 (23,04%)
<i>AP</i>	0,24 (05,76%)	0,48 (23,04%)

A disposição dos valores médios no plano das CPs elucidou a dinâmica dos PFS, com um gradiente textural ao longo da 1ª CP e permitiu observar os PFS de textura argilosa e muito argilosa mais dispersos que os de textura média e arenosa, o que mostra diferença na variação nos atributos que definem a fertilidade do solo (Figura 12).


Figura 12 — Distribuição dos PFS no plano das CPs retidas. As setas e eixos em vermelho representam os atributos da análise de solo e sua importância na constituição de cada CP.



A comparação de sistemas de uso da terra pelos PFS segmentados por profundidade e agrupados pela textura (Figura 13) não apresentou diferenças significativas quanto à fertilidade. Visualmente, a pastagem apresentou menor mediana em quase todos os grupos texturais com exceção de solos muito argilosos. Nestes, os PFS de pastagem superaram os demais em quase todas as profundidades amostrais (Figuras 13.A, 13.C, 13.E) com exceção da camada 20-30cm (Figura 13.G), onde a presença de solos de sistemas integrados com maior concentração de nutrientes foi mais frequente.

Na dimensão acidez, os solos de vegetação nativa se mostraram mais ácidos que os de pastagem e de sistemas integrados nas camadas mais superficiais, mas as diferenças tornaram-se não significativas com o aumento da profundidade do solo (Figuras 13.B, 13.D, 13.F e 13.H).

Figura 13 — Comparação do sistema de uso da terra (Pastagem – P, Sistema Integrado – SI e Vegetação Nativa – VN) segmentado por profundidade amostral e agrupado pela textura. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo textural.




Comparando grupos texturais segmentados por sistema de uso da terra e agrupados por profundidade (Figura 14), a dimensão de fertilidade reforçou o gradiente observado para a densidade do solo. Além disso, permitiu identificar que os solos de pastagem foram mais diversos em suas condições de fertilidade (1ª CP) nas camadas 0-5cm, 5-10cm e 10-20cm de (Figura 14.A). De outro modo, os solos de sistemas integrados e, principalmente, de vegetação nativa, foram menos flexíveis (14.C e 14.E), ou seja, com menor diversidade na comparação pelo teste de Tukey. Como a densidade do solo apresentou baixa participação na constituição da 2ª CP (Tabela 6), é possível argumentar, com base apenas nos atributos químicos, que os PFS de solos de pastagens argilosos e muito argilosos são mais ácidos do que os de textura arenosa e média, e tais diferenças se tornaram significativas a partir da camada 5-10cm (Figura 14.B).

No caso dos sistemas integrados, a acidez do solo foi sensivelmente maior em solos muito argilosos considerando todas as profundidades amostradas (Figura 14.D).


Para PFS de áreas de vegetação nativa, diferenças significativas estiveram presentes apenas na profundidade 10-20cm, sendo este sistema, portanto, mais estável para todos os grupos texturais e profundidades avaliadas.

Figura 14 — Comparação do grupo textural segmentado por sistema de uso da terra e agrupado pela profundidade amostral. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo de profundidade amostral.



Os PFS segmentados por sistema de uso da terra e agrupados por grupo textural mostraram redução da fertilidade em direção às camadas mais profundas (Figuras 15A, 15.C e 15.E) para quase todos os casos exceto para solos muito argilosos coletados de sistemas integrados e vegetação nativa, onde as diferenças observadas não foram significativas (15.C e 15.E). A acidez do solo, por sua vez, apresentou diferença significativa em profundidade apenas para os PFS de solos com textura média e argilosa de áreas de sistemas integrados (Figuras 15.D).

Figura 15 — Comparação da profundidade amostral segmentada por sistema de uso da terra e agrupada por grupo textural. As letras representando o resultado do teste de Tukey estão limitadas para cada grupo textural.



Os resultados da comparação dos sistemas de uso da terra (Figura 13) não permitiram extrair diferenças significativas como em Assad et al. (2013) e Groppo et al. (2015) para a dimensão da fertilidade. Esta limitação está provavelmente relacionada ao caráter regional da avaliação e à transformação dos atributos originais combinados nas CPs que levaram à perda de variância. Isto pode servir de elemento motivador para a coleta de variáveis adicionais para permitir o diagnóstico das propriedades do solo com maior precisão. O nitrogênio, por exemplo, é um elemento de contabilização complexa (GUERRERO et al., 2021), enquanto os fertilizantes à base desse elemento são uma importante fonte de custo financeiro e ambiental no manejo agrícola (SILVA et al., 2022), o que justifica a necessidade de aprimoramento dos métodos de mensuração e recomendação.

Reflexões semelhantes sobre a variação dos atributos de fertilidade do solo podem ser feitas também para o potássio e o fósforo. Estes resultados, no entanto, avançam mostrando distinções encontradas na comparação estratificada de grupos texturais e profundidades de camadas entre cada uso do solo.

Agropecuáristas normalmente enfrentam restrições técnicas (OLIVEIRA et al., 2016) e financeiras (CHAMEN et al., 2016) para adubação e correção de acidez em profundidade em solos com maior teor de argila. Nessas áreas, esse manejo geralmente é

realizado apenas superficialmente. Os resultados obtidos neste trabalho mostram o reflexo disso em solos de pastagem, onde houve: (i) maior heterogeneidade (i.e., número de diferenças significativas) das condições de fertilidade dos PFS na profundidade 0-5cm (Figura 14.A) e (ii) homogeneidade da acidez dos PFS na profundidade 0-5cm (que mostra correção em todos os grupos texturais) (Figura 14.B), enquanto em camadas mais profundas (20-30cm) há, tanto para fertilidade quanto para acidez, uma distinção apenas entre solos de textura arenosa e média daqueles de textura argilosa e muito argilosa.

Em sistemas integrados, diferenças significativas entre PFS de solos de textura arenosa e média são menos frequentes em ambas as dimensões, mas aqueles de solos muito argilosos ainda assim diferiram dos demais (Figura 14.C e 14.D). A comparação em profundidade segmentada por sistema de uso da terra e agrupada pela textura elucidou a diminuição da fertilidade em profundidade (LIMA et al., 2022) (Figuras 15.A, 15.C e 15.D), embora sua acidez não tenha mostrado diferença significativa na maioria dos casos, com exceção de PFS de solos de textura média e argilosa de sistemas integrados (Figura 15.B, 15.D e 15.F), o que significa um tratamento homogêneo ao longo do perfil do solo.


O fornecimento de nutrientes e a correção da acidez realizada apenas nas camadas superficiais levam à degradação em profundidade (LUZ et al., 2019). A maior concentração de alumínio, especialmente para PFS de solos argilosos e muito argilosos, representam um fator limitante para desenvolvimento do sistema radicular e leva a problemas relacionados ao aproveitamento hídrico, especialmente num contexto de alterações climáticas cujos efeitos incluem o aumento do stress hídrico (TIECHER et al., 2017; ZULLO JUNIOR. et al., 2018). Assim, o aumento da diferença entre a produtividade potencial e a observada, em pastagens, aumenta a severidade da degradação, seja ela agrícola ou biológica (DIAS-FILHO, 2015; LUZ et al., 2019).

Por fim, além de apenas aumentar o rendimento das culturas por meio do fornecimento de nutrientes no solo e da correção da acidez, pastagens cultivadas em solos de textura argilosa e muito argilosa também poderiam se beneficiar de técnicas de manejo mais aprimoradas que explorem o potencial naturalmente mais elevado de estocar carbono no solo, permitindo a esses pecuaristas ingressarem em mercados de carbono com maior rentabilidade (BAUMANN et al., 2022; PHELAN et al., 2024; SANTOS et al., 2024). As Figuras 15.A e 15.C ilustram esse potencial devido à discrepância entre a camada de 0-5cm de profundidade em comparação com as mais profundas.

4.1.2 Heterogeneidade dos perfis de fertilidade

As amostras categorizadas, transformadas em índices de fertilidade e acidez (Apêndice 2), foram submetidas ao teste de Levene para igualdade de variâncias para comparar PFS de pastagem com: (i) pastagem; (ii) sistemas integrados; e (iii) vegetação nativa. Cada sistema de uso da terra foi composto inicialmente por 16 categorias únicas. Assim, de um total de 704 comparações possíveis por CP retida, excluindo as auto comparações (16 para o caso pasto contra pasto), e comparações que não puderam ser testadas devido ao tamanho insuficiente da amostra (1 PFS para sistema integrado e 2 para vegetação nativa, conforme detalhado no Apêndice 2), houve diferenças significativas ($p < 0,05$) em 46 e 24 comparações para as dimensões da fertilidade (1ª CP) e da acidez (2ª CP), respectivamente. O desdobramento dessas diferenças por sistema de uso da terra, grupo textural e profundidade, para cada dimensão, mostrou que as diferenças na dimensão de fertilidade, na maioria dos casos, estão concentradas entre PFS de pastagens (i.e., na comparação de pastagem com pastagem), seguida por sistema integrado e por último por vegetação nativa. Para a dimensão acidez (2ª CP), entretanto, as comparações de pastagem com sistema integrado e vegetação nativa compartilharam a mesma proporção, enquanto diferenças significativas entre pastagens foram menos frequentes (Figura 16.A). Pela classificação do grupo textural (SANTOS et al., 2018) os solos arenosos foram mais suscetíveis à variação da fertilidade (1ª CP), que por sua vez diminuiu com a densidade do solo em direção a solos muito argilosos. Na dimensão da acidez (2ª CP), os solos muito argilosos também apresentaram o menor número de diferenças significativas, e os de textura argilosa e média superaram os arenosos (Figura 16.B). Em profundidade, as diferenças de fertilidade concentraram-se na camada 20-30cm e seguiram um gradiente decrescente em direção à camada superficial (0-5cm). Para a dimensão da acidez, essas diferenças foram distribuídas de forma mais homogênea em quase todas as profundidades do solo, exceto na camada de 5-10cm, onde as diferenças foram menos frequentes (Figura 16.C).

Figura 16 — Distribuição das diferenças significativas para cada sistema de uso da terra (Pastagem, Sistema Integrado e Vegetação Nativa), grupo textural e profundidade amostral das dimensões de fertilidade e acidez do solo.



A maior heterogeneidade (ou singularidade) observada para PFS de pastagens na 1ª PC (Figura 16), em parte, pode ser explicada por variações nos sistemas de manejo de pastagens e pelo grau de tecnologia adotado pelos agricultores que impactam uma série de propriedades do solo (CONANT et al., 2017; JAKIMOW et al., 2018). Em camadas mais profundas, especialmente na profundidade 20-30cm (Figura 16.C), a maior concentração de diferenças está em conformidade com Tian et al. (2010) e Tischer et al. (2014). Nestes trabalhos, os autores descobriram que as proporções de conteúdo de nitrogênio e carbono são menos restritas (i.e., mais flexíveis) nas camadas mais profundas do que em superfície, provavelmente devido a menor regulação biótica e influência edáfica. Bertrand et al. (2019) sugeriram que camadas mais profundas do solo deveriam ser consideradas (juntamente com a matéria orgânica) em abordagens mais agroecológicas visando o aumento do estoque de carbono (ALCÁNTARA et al., 2016). Isto devido à essa maior flexibilidade, ou seja, sua capacidade de sustentar mudanças nas proporções de carbono, nitrogênio e fósforo sem impactar negativamente o agroecossistema.

Para o potássio, Rosolem e Steiner (2017) também apontaram que amostragem limitada a 20cm de profundidade poderia ser insuficiente para recomendações de fertilização

satisfatórias. No presente trabalho, portanto, está demonstrado que informações relevantes a um manejo mais eficiente seriam negligenciadas ao amostrar apenas camadas superficiais do solo.

O aumento da matéria orgânica do solo, que é mais concentrada e menos flexível nas camadas superficiais, exigiria um aumento (RICHARDSON et al, 2014; GROENIGEN et al., 2017) dos níveis atuais de aplicação de nitrogênio (+46%) e fósforo (+24%) (CHEN e GRAEDEL, 2016; LASSALETTA et al., 2016). Isto levaria a, no caso do nitrogênio, aumento das emissões de GEE (GUERRERO et al., 2021; SANTOS et al., 2024).

Para os PFS de pastagem, à medida que a correção da acidez é feita de forma homogênea (i.e., com menos diferenças significativas) (Figura 16.A), e tomando os sistemas integrados como mais intensificados e técnicos que o sistema de pastagem (REIS et al., 2021), o que implica terem maior adoção de práticas de correção de acidez (Figuras 13.B, 13.D, 13.F e 13.H), os resultados desse trabalho mostram que esta tarefa é, de forma generalizada, mal adotada nas áreas de pastagens.

Portanto, a correção da acidez do solo se mostra como uma estratégia mais viável a ser executada antes da adubação devido à esta apresentar menor emissão de GEE e menores custos em comparação a aplicação de fertilizantes sintéticos, além de promover o aumento da disponibilidade dos nutrientes do solo para as plantas (ABDALLA et al., 2022; WARNER et al., 2023). Isto culmina, em última instância, em impactos positivos sobre a rentabilidade da atividade se conduzido considerando também as camadas mais profundas do solo (KALKHORAN et al., 2020).

Na avaliação do grupo textural, a heterogeneidade na dimensão da fertilidade (1ª CP) é mais frequente em solos de textura arenosa do que naqueles de textura muito argilosa (Figura 16.B). Estas diferenças estão mais concentradas nas camadas mais profundas (Figura 16.C), mostrando que a fertilidade deve ser manejada considerando tais particularidades ao longo do perfil do solo.

Na dinâmica da matéria orgânica, por exemplo, Baumann et al. (2022) apontaram que considerar tais particularidades é ainda mais importante em regiões com maior variação na mineralogia do solo e nas condições climáticas. A conscientização sobre as condições específicas do local nas estratégias de adubação e correção da acidez do solo está frequentemente presente em trabalhos relacionados (ABDALLA et al., 2022; BAUMANN et

al., 2022; ENESI et al., 2023) e nossos resultados ajudam a elucidar a distribuição dessas singularidades.


4.2 IMPACTO DA DEGRADAÇÃO NA PRODUTIVIDADE POTENCIAL

4.2.1 Segmentação de Sistemas Produtivos Pecuários (SPP) baseados em pecuária extensiva

A análise de municípios com características discrepantes em relação ao conjunto original de dados (*outliers*) identificou 92 destes (9,1%) com pouca adoção de pecuária extensiva, com destaque para municípios localizados nas regiões de Ribeirão Preto-SP (tradicional produtora de cana-de-açúcar), de Assis-SP (uma das principais produtoras de grãos do estado) e nos arredores de Goiatuba-GO (Figura 17). Na agregação por estado, foi possível observar que estes municípios se concentram quase exclusivamente nos estados de São Paulo (80%) e Goiás (18,4%), com apenas 1 no Mato Grosso do Sul e nenhum em Mato Grosso. Cabe destacar que, para além de alguns municípios (8,7%) classificados como *outliers* em razão da sua baixa aptidão para a pecuária em geral (i.e., rebanho reduzido), a maior parcela destes (91,3%) apresentou rebanho bovino entre 1.000 e 108.000 cabeças e ocupação territorial por pastagem de apenas 6,5%, em média. Isto reforça a relevância econômica da atividade pecuária do nicho praticado (pecuária intensiva), nas regiões em que se concentram (GREENWOOD, 2021). Ainda que especificidades destes municípios não sejam objeto de aprofundamento neste trabalho, o Apêndice 4 traz um resumo descritivo dos municípios classificados como *outliers* e removidos da segmentação de sistemas produtivos.

A distribuição espacial dos 5 SPP determinados pela análise de agrupamento evidenciou um padrão regional com núcleos de concentração de municípios com características semelhantes (Figura 17). Ainda que a comparação dos resultados obtidos nesta etapa com outros trabalhos seja limitada, dado que o *K-Means* é um algoritmo de ajuste ótimo local e, portanto, dependente do conjunto de dados e do domínio da aplicação (AHMED et al., 2020, JAMES et al., 2023), o respaldo está na sua utilização em trabalhos dessa mesma natureza. Como exemplo, tem-se a segmentação regional utilizando dados censitários (MAIA et al., 2018), a análise regional do desempenho de sistemas de produção agropecuária (MAIONE et al., 2018; CANOZZI et al., 2019), e a avaliação da pegada hídrica em regiões de expansão agrícola (SANTOS e NAVAL, 2020), dentre outros. O Apêndice 5 traz uma relação espacializada de municípios com vocação agropecuária exemplificando a distribuição dos SPP nos estados.

Figura 17 — Espacialização (i) dos Sistemas Produtivos Pecuários (SPP) obtidos por análise de agrupamento e (ii) dos municípios considerados *outliers*. Municípios vizinhos pertencentes a um mesmo SPP tiveram sua área dissolvida.




A composição dos estados por cada SPP, em termos proporcionais, ajudou a entender a dinâmica da distribuição dos totais de área de pastagem e rebanho bovino de forma mais detalhada (Figura 18 e Apêndice 6). Sob esta perspectiva, Goiás e Mato Grosso do Sul apresentaram a menor parcela de suas áreas de pastagem (4% e 1%, respectivamente) e rebanho bovino (3% e 1%) sob o SPP 1 e a maior sob o SPP 5 (54% das áreas de pastagem e 52% do rebanho bovino, em média).

No caso do Mato Grosso, ainda que a parcela referente ao SPP 1 tenha sido pequena (13% das áreas de pastagem e 12% do rebanho bovino), a menor participação na sua composição se deu pelos SPP 2 (com 1% da área de pastagem e 2% do rebanho bovino) e 5 (com 6% e 7%, respectivamente), e a maior pelo SPP 4, tanto para área de pastagem (60%) quanto para o rebanho bovino (57%). Em São Paulo, onde o SPP 4 foi ausente, essa dinâmica mudou e houve maior participação dos SPP 2, cobrindo 15% das áreas de pastagem e 22% do rebanho bovino (os outros estados apresentaram, na média, participação desse SPP de apenas 3% e 5%, respectivamente), e 3, que respondeu por 46% da área de pastagem e 44% do rebanho

bovino, enquanto os demais estados tiveram, em média, apenas 19% das pastagens e 22% do rebanho bovino pertencentes a este SPP.

Figura 18 — Distribuição proporcional dos atributos dos Sistemas Produtivos Pecuários (SPP) na composição dos estados.



Os SPP apresentaram correlação geral forte ($r=77\%$) entre a área do município (Figura 19.A) e sua área de pastagem (Figura 19.B). Individualmente, quase todos acentuaram essa correlação, com valores (r) acima de 80% para os SPP 1 e 2 e acima de 96% para os SPP 3 e 5. A exceção ficou para o SPP 4, com apenas 33%. Mesmo assim, as áreas de pastagem dos municípios do SPP 4 são maiores em relação aos demais. De certa forma, essa relação já era esperada dada a dinâmica da expansão da atividade pecuária no Brasil, promovida primordialmente para ocupação do território.

Os atributos relativos, entretanto, destacam a variação do desempenho desses sistemas quanto à ocupação do território. A parcela sob cobertura de pastagens ultrapassou a barreira dos 50% apenas no SPP 5 (Figura 19.C), cuja presença foi mais acentuada nos estados de Goiás e Mato Grosso do Sul (Figura 18.A), ambos com as maiores taxas de desmatamento acumulado desde 2000 (21% e 17%, respectivamente) para o Cerrado, segundo dados dos sistemas PRODES e DETER (VALERIANO et al., 2016a; VALERIANO et al., 2016b) disponibilizados pela plataforma TerraBrasilis¹⁹ (ASSIS et al., 2019).

¹⁹ Disponível em: <http://terrabrasilis.dpi.inpe.br/app/dashboard/deforestation/biomes/cerrado/increments>. Acesso em: 30/10/2023.

Entre os estados sob o bioma Mata Atlântica, São Paulo ocupa o segundo lugar com 20% da vegetação nativa suprimida no mesmo período (ASSIS et al., 2019), e, apesar da participação do SPP 5 neste estado ter sido menor, teve a maior parte dos seus municípios pertencentes ao SPP 3 (Figura 18.A), que por sua vez apresentou a segunda maior taxa de ocupação territorial por pastagens (Figura 19.C).

Um contraste interessante pôde ser observado na comparação entre os SPP 1 e 5, cujos municípios apresentaram área territorial semelhante enquanto as respectivas parcelas sob pastagem tiveram o menor e maior valor entre todos os SPP. Este fato pode indicar: (i) maior diversificação de sistemas de uso da terra pelo SPP 1, por dispor de mais área disponível para este fim ou já sob outros tipos de cobertura; e/ou (ii) menor preservação da vegetação nativa no SPP 5, dada a maior parcela desses municípios já sob pastagem, observação reforçada pela maior presença do SPP 5 nos estados com maior índice de desmatamento (ASSIS et al., 2019) e que, por sua vez, pode estar relacionado a déficit no cumprimento do Código Florestal (SOARES-FILHO et al., 2014).

Essa constatação corrobora o trabalho de Parente e Ferreira (2018), que identificaram a Mata Atlântica como único bioma com contração da área de pastagem no período entre 2000 e 2016. Entretanto, não está no escopo deste trabalho discutir se as áreas destes e dos demais SPP teriam índices de perda da vegetação nativa ainda maiores envolvendo, nesse caso, a substituição desta ou mesmo de pastagens naturais por outros tipos de cobertura.


Mais território ou maior ocupação por pastagem não se traduz, necessariamente, em aumento da eficiência produtiva (DIAS-FILHO, 2015; LAHSEN et al., 2016; FELTRAN-BARBIERI e FÉRES, 2021). Os SPP 1, 3, 4 e 5 apresentaram as menores taxas de lotação (Figura 19.D), mas, apesar de serem semelhantes nesse aspecto, se distinguiram quanto à ocupação territorial, seja na área absoluta de pastagem (Figura 19.B), seja na sua ocupação relativa (Figura 19.C). A semelhança observada no padrão de lotação desses pastos também pode indicar similaridade quanto ao manejo empregado, o que culminaria, em última análise, em oportunidade de aumento da eficiência produtiva desses sistemas.

Por outro lado, os municípios com as maiores taxas de lotação (Figura 19.D) foram aqueles pertencentes ao SPP 2, com os menores valores absolutos de área de pastagem (Figura 19.B). Não é possível afirmar, no entanto, que o modelo de pecuária adotado no SPP 2 seja mais sustentável que os demais, dado que superpastejo também é um elemento promotor do processo de degradação de pastagens (DIAS-FILHO, 2015) e isso pode evidenciar um limite

para aumento do rebanho nessas áreas. Observando as características centrais dos agrupamentos relativos à cada SPP (Figura 19), estes foram rotulados de acordo com seu padrão de ocupação do território por áreas pastagens e de distribuição do rebanho da seguinte forma:

- SPP 1: Municípios pequenos, com a menor ocupação relativa por pastagem e taxa de lotação pequena.
- SPP 2: Menores municípios, com baixa ocupação relativa e a maior taxa de lotação.
- SPP 3: Municípios pequenos, com ocupação relativa moderada e taxa de lotação moderada.
- SPP 4: Maiores municípios, com as maiores áreas absolutas de pastagem, ocupação relativa moderada e menores taxa de lotação.
- SPP 5: Municípios pequenos, com a maior ocupação relativa e taxa de lotação moderada.

Figura 19 — Valores médios dos atributos de cada Sistema Produtivo Pecuário (SPP). As linhas verticais em vermelho representam o desvio padrão de cada atributo em torno do centroide.




Avaliando as informações disponibilizadas pelo Censo Agropecuário (IBGE, 2017), em um recorte envolvendo propriedades com alguma área de pastagem (i.e., sem distinção da qualidade), foi possível observar que municípios do SPP 2, com a maior taxa de lotação (Figura 19.D), também apresentaram o maior índice de produtores que declararam

receber algum tipo de orientação técnica (Figura 20.A). Esse fato contrasta com o SPP 4, com menor taxa de lotação dos seus pastos (Figura 19.D) e o segundo menor índice de produtores que declararam receber orientação técnica de alguma natureza (Figura 20.A).

Isso tudo é reforçado na avaliação por estado (Figura 20.B), que mostrou que São Paulo, cuja cobertura relativa do SPP 2 foi maior, liderou a declaração positiva de recebimento de orientação técnica por parte dos produtores, ao contrário da situação observada em Mato Grosso, composto por municípios majoritariamente pertencentes ao SPP 4.

Goiás e Mato Grosso do Sul apresentaram valores discrepantes apesar da semelhança observada na sua composição relacionada aos SPP (Figura 18). Ainda que Goiás tenha tido maior parcela dos municípios sob os SPP 2 e 3 (com taxa de lotação superiores), seus produtores alegaram dispor de menos orientação técnica.

Figura 20 — Parcela de produtores rurais que dispõe de alguma área de pastagem por município, que declararam receber algum tipo de orientação técnica.



Quanto à natureza da assessoria recebida (IBGE, 2017), tanto no recorte por SPP (Tabela 7) quanto por estado (Tabela 8), a maioria dos produtores declararam ter orientação própria ou serem eles os próprios responsáveis pela indicação das melhores práticas de manejo. Isto pode representar um gargalo técnico para o setor, caso a gestão dessas propriedades ainda esteja sob responsabilidade de tomadores de decisão de gerações anteriores, com perfil menos técnico e menor grau de escolaridade formal (TEY e BRINDAL, 2012). Um contraste interessante está no maior suporte proveniente de cooperativas no SPP 2, enquanto o SPP 4 teve a menor parcela de produtores que declararam receber esse tipo de orientação e o maior índice de produtores que declararam ter ou ser sua própria fonte de orientação técnica, ou seja, o

suporte técnico por terceiros foi menor (Tabela 7). Nos estados, São Paulo e Goiás lideraram a presença de cooperativas fornecendo suporte técnico enquanto Mato Grosso apresentou a menor cobertura dessa categoria. Neves et al. (2021) analisaram dados do mesmo Censo Agropecuário (IBGE, 2017) sob uma perspectiva econômica e também encontraram relação positiva entre a adoção do cooperativismo nos municípios e a receita líquida da produção.

As orientações recebidas por instituições de governo superaram aquelas recebidas por empresas nos recortes por estado e por SPP, o que demonstra espaço para iniciativas privadas suprirem essa demanda, dado que o aumento da cobertura por órgãos do Estado não é imediato e pode até ser inviável (NETTLE et al., 2021) (Tabela 8).

Tabela 7 — Parcela dos produtores rurais que declararam receber cada categoria de orientação técnica, por SPP.

SPP	Orientação técnica recebida			
	(%)			
	Cooperativa	Governamental	Interna	Prestadora de serviços
SPP 1	17,39	20,94	49,42	12,24
SPP 2	26,09	14,41	47,46	12,03
SPP 3	19,67	24,18	49,17	06,98
SPP 4	12,38	18,66	57,86	11,10
SPP 5	15,08	29,03	49,45	06,45

Tabela 8 — Parcela dos produtores rurais que declararam receber cada categoria de orientação técnica, por estado.

Estado	Orientação técnica recebida			
	(%)			
	Cooperativa	Governamental	Interna	Prestadora de serviços
GO	21,32	15,87	53,68	09,13
MS	14,93	27,18	49,61	08,29
MT	06,62	22,17	58,11	13,09
SP	21,50	23,71	46,20	08,59

Explicar discrepâncias presentes na análise de dados declaratórios requer parcimônia, como apontam Feltran-Barbirei e Féres (2021), pois os produtores podem ter algum receio ou interesse na formulação de suas respostas, gerando enviesamento. Mesmo assim, as relações observadas quanto ao acesso dos produtores à orientação técnica, e, portanto, às

tecnologias disponíveis (JANK et al., 2014; ZANTEN et al., 2016), podem servir de indicativo para explicar a diferença de desempenho na lotação dos pastos entre os SPP.

4.2.2 Estimativa de produtividade das pastagens e modelagem do clima regional

O perfil temporal (Figura 21) mostrou que a produtividade potencial (TONATO et al., 2010) do grupo C1 superou o grupo U1 e essa diferença foi mais acentuada no período úmido. O modelo para a produtividade observada (ROSA e SANO, 2013), por sua vez, foi inferior a ambos, pois reflete os efeitos negativos do ambiente, como a ocorrência de pragas e doenças, deficiência nutricional das plantas e/ou maior demanda evaporativa que culminam em aumento do déficit hídrico.

A análise sazonal (JÖNSSON e EKLUNDH, 2004; EKLUNDH e JÖNSSON, 2016) gerou séries temporais filtradas para ambos os modelos. Algumas regiões, no entanto, demonstraram baixa correlação entre os modelos de produtividade observada e potencial, notadamente nas regiões de Águas Frias de Goiás-GO, Campo Novo do Parecis-MT, Crixás-GO, Canarana-MT e Porangatu-GO, para os quais a correlação (r) máxima observada foi de 45% para o período estudado (Figura 21).

Nessas regiões, o modelo sazonal não detectou o comportamento esperado para o acúmulo potencial de matéria seca (TONATO et al., 2010) devido à pouca variação da temperatura mínima ($TEMP_{min}$) nos meses de inverno (Figura 22), o que prejudicou a extração dos parâmetros sazonais. Por outro lado, a correlação entre o modelo de produtividade observada e a precipitação ($PREC$) (Figura 23) nessas regiões capturou melhor a variação do desenvolvimento vegetativo, o que indica a necessidade de se considerar a variação sazonal deste parâmetro na modelagem do potencial produtivo das pastagens (ZHANG et al., 2021).

Outras regiões, por sua vez, apresentaram comportamento inverso, com maior correlação do modelo de produtividade observada com a temperatura mínima ($TEMP_{min}$) ($r \geq 75\%$) e menor com a precipitação ($PREC$) ($r \leq 60\%$). É o caso de Ponta Porã, Itaporã, Naviraí, Campo Grande e Porto Murtinho (todos no Mato Grosso do Sul). Isto mostra que modelos que utilizam variáveis individualizadas têm limitações para escalar sua aplicação sobre áreas com condições climáticas e meteorológicas distintas.

Por fim, analisando o déficit hídrico (Figuras 24 e 25) e o armazenamento de água no solo (Figuras 26 e 27), derivados do balanço hídrico (THORNTON e MATHER, 1955), sob duas $CADs$ (50mm e 125mm), ambos mostraram correlação maior que a precipitação

($PREC$) em regiões onde a temperatura mínima ($TEMP_{min}$) teve baixa performance. Nesse caso, a deficiência hídrica (DEF_{cad50} e DEF_{cad125}) teve melhor performance e se mostrou mais estável que o armazenamento de água (ARM_{cad50} e ARM_{cad125}).

Isto não significa que este fator seja menos importante do ponto de vista do monitoramento. A drenagem satisfatória em solos sob pastagem (BIRCH et al., 2021) ajuda na manutenção da produtividade com redução da dependência de chuvas recorrentes ou sistemas de irrigação (PEREIRA-FLORES et al., 2023) e reduz a ocorrência de problemas como a síndrome da morte do capim pelo excesso de água (BOURSCHEIDT et al., 2021; DIAS-FILHO, 2015). Esta síndrome, apesar de gerar atualmente mais preocupação no norte do Mato Grosso e em regiões Amazônicas (MANZATTO et al., 2017), poderá se tornar um problema em outras regiões com o agravamento dos efeitos das mudanças climáticas, no qual uma das consequências é o aumento da concentração das chuvas em períodos mais curtos (ALVES et al., 2020; AVILA-DIAZ et al., 2020).

Em estudo realizado em solos sob pastagens no Panamá, Birch et al. (2021) identificaram que mais de 50% da água da chuva é perdida por escoamento superficial devido à baixa capacidade de drenagem. Dessa forma, aumentar o potencial de drenagem do solo e promover o aprofundamento do sistema radicular pode favorecer a capacidade de resiliência da vegetação (WHITE et al., 2021) pelo aumento da faixa de solo disponível para absorção de água (Figuras 26 e 27), especialmente em locais mais secos (ZHANG et al., 2021), onde a irrigação também se torna uma opção (PEREIRA-FLORES et al., 2023). Além disso, a promoção da recuperação de pastos degradados contribui para a aumentar o estoque de carbono no solo (OLIVEIRA et al., 2022).

Figura 21 — Séries temporais dos modelos de produtividade observada (NDVI) e potencial (grupos U1 e C1) com escala temporal de 16 dias e seus coeficientes de correlação (r). As cores indicam o SPP dos pontos amostrados.




Figura 22 — Frequência da temperatura mínima mensal média (1986-2015) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.




Figura 23 — Frequência da soma da precipitação mensal média (1986-2015) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.




Figura 24 — Frequência da def. hídrica mensal (DEF_{cad50}) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.




Figura 25 — Frequência da def. hídrica mensal (DEF_{cad125}) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.




Figura 26 — Frequência do arm. de água mensal (ARM_{cad50}) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.





Figura 27 — Frequência do arm. de água mensal (ARM_{cad125}) (2013-2019) e correlação (r) com o modelo de produtividade observada no período de estudo (2013-2019). Os limites inferior e superior das barras representam os percentis 20% e 80%, respectivamente.




Conhecer o clima regional é importante no dimensionamento de redes de sensores (GREENWOOD, 2021), como estações meteorológicas, com relação ao número e variedade de sensores a serem acoplados e no desenvolvimento e calibração de modelos de avaliação de risco e/ou de produtividade de acordo com a relevância de cada variável (YU et al., 2019).

Com relação à degradação, os parâmetros climáticos podem ajudar a avaliar o risco de degradação agrícola dada a influência da precipitação sobre a composição florística, que promove a substituição da pastagem por espécies de menor valor econômico (PITTARELLO et al., 2020). Por outro lado, se a precipitação for alta o suficiente para causar a lixiviação de nutrientes e erosão do solo, a degradação biológica passa a exercer dominância. Segundo Sloat et al. (2018), entre 41% e 49% dos pastos no mundo têm experimentado aumento da precipitação inter e intra anual, respectivamente. Riquetti et al. (2020), apesar de corroborar a mesma hipótese, inclusive utilizando projeções para a região estudada, apontam também a existência de sub-regiões onde a precipitação tende a diminuir pela redução do abastecimento Amazônico. Tais limitações ambientais podem ser superadas, ao menos em parte, pela adoção de manejo adequado (PITTARELLO et al., 2020).

A relação entre o clima regional dos SPP (Figura 28) com a produtividade observada contrastou a média espacial da produção acumulada ($MS_{méd}$) em cada SPP (no período 2015-2016) com os parâmetros diretamente relacionados ao aumento da demanda hídrica, principalmente a média anual da temperatura mínima ($TEMP_{mín}$) e o acumulado anual da deficiência hídrica (DEF_{cad100}) (Figura 29). Apesar da alta correlação entre eles ($TEMP_{mín}$ e DEF_{cad100}) ($r=84\%$), seu comportamento é complementar na avaliação mensal. Em regiões onde a temperatura mínima ($TEMP_{mín}$) não foi capaz de determinar com precisão o desenvolvimento vegetal (Figura 22), a deficiência hídrica (DEF_{cad100}) apresentou performance superior (Figuras 24 e 25), sendo válida a situação recíproca. Essa relação reforça a importância de se considerar essas duas variáveis na modelagem da produtividade de pastagens com aplicação espacialmente mais abrangente. Para a precipitação anual ($PREC$), a correlação com a média da produção ($MS_{méd}$) foi negligenciável ($r=-14\%$) (ZHANG et al., 2021) enquanto, para a sua variância (MS_{var}), a correlação foi mais expressiva ($r=65\%$). Isto sugere: (i) que o efeito do aumento da precipitação anual na distribuição das chuvas durante o ano é que influencia o desempenho das pastagens (PEREIRA-FLORES et al., 2023); ou, ainda, (ii) que nestas regiões as pastagens são mais sensíveis às condições de ambiente e manejo empregado, coexistindo situações de manejo mais ou menos intensificado que resultaram na variância observada em termos de produtividade espacial média (ZHANG et al., 2021).

Figura 28 — Variáveis meteorológicas e parâmetros resultantes do balanço hídrico (THORNTHWAITE e MATHER, 1955), para a região estudada, entre 1986 e 2015. As cores das amostras representam os Sistemas Produtivos Pecuários (SPP) descritos previamente.



A distribuição dos SPP pelas CPs (Figura 29) caracterizou os SPP 1 e 2 como regiões com maior média de produção acumulada e menor demanda evaporativa. Isto se traduz em aproveitamento mais eficiente das condições ambientais mais favoráveis nesses SPP e antagoniza com a situação observada para o SPP 5, concentrado na direção oposta.

Os SPP 3 e 4, por sua vez, foram distribuídos em situações diferentes e interpretações generalistas nesse quesito devem ser feitas com cautela. Algumas regiões dos SPP 3 (Rondonópolis-MT), 4 (Canarana-MT e Porto Murtinho-MS) e 5 (Montes Claros de Goiás-GO) foram alocados em áreas cuja demanda evaporativa foi mais acentuada e contrastante com a produtividade. Mesmo assim, apresentaram valores médios da estimativa da produção acumulada anual (no período sazonal) superior a 7.000kg (Apêndice 7), o que pode ser resultado da aplicação de técnicas de manejo para promoção da produtividade.

Entretanto, esses SPP estão, no geral, mais expostos aos efeitos negativos das mudanças climáticas em função do agravamento da demanda hídrica anual (ALVES et al., 2019; AVILA-DIAZ et al., 2020). A relevância dessa constatação está no fato de que eles demonstraram ocupação territorial maior dos seus municípios por pastagens (Figura 19.C).

Além disso, o SPP 4, de forma mais específica, também apresentou as maiores áreas de pastagem em valores absolutos (Figura 19.B), o que denota a importância da atividade pecuária na economia local sob risco, seja pela inviabilização climática da atividade (JONES e THORNTON, 2009), seja pelo custo de implantação de ações de adaptação (FELTRAN-BARBIERI e FÉRES, 2021).

Considerando toda a sua extensão, os SPP 3, 4 e 5 contabilizaram, respectivamente, 25%, 23% e 37% (85%, no total) de todo o rebanho sob a área de abrangência dessa tese, ou 26% do contingente nacional (IBGE, 2024). Isto denota a importância da região do ponto de vista econômico e alimentar (SLOAT et al., 2018). O cruzamento da área de cobertura desses SPP com as condicionantes climáticas regionais mostra que essas áreas são justamente aquelas onde o clima antagonizou com a produtividade de forma mais severa, culminando em maior risco de degradação (Figura 30).

Esses resultados corroboram White et al. (2021) mostrando que a modelagem climatológica da produção deve ir além de apenas calcular a produtividade. Ela deve se estender para extrair conhecimentos acerca da estabilidade e manutenção dos níveis de produção atuais, identificando áreas sob maior ou menor risco em função dos efeitos das mudanças climáticas.

Figura 29 — Relação entre os parâmetros climáticos (1986-2015) e a produção acumulada observada de matéria seca. As linhas vermelhas são os autovetores das Componentes Principais e os valores no título dos eixos representam a variância explicada por cada CP.





Figura 30 — Distribuição das condições climatológicas nos SPP. As linhas brancas representam a posição mediana.



4.2.3 Penalização da produtividade potencial utilizando dados de Radar de Abertura Sintética (SAR)

Entre as amostras selecionadas, a mediana da penalização percentual observada entre os modelos de produtividade observada e potencial (*PRP*) concentrou-se na faixa entre 30% e 57%, para o grupo U1 (Tabela 9), e entre 36% e 61%, para o grupo C1 (Tabela 10). Isto agrega na estimativa de ocorrência do processo de degradação em 80% das pastagens brasileiras (DIAS-FILHO, 2015). Essa observação também está presente no estudo realizado em nível nacional por Santos et al. (2022), no qual os autores mostraram que, apesar da área sob degradação ter diminuído entre 2010 e 2018, áreas de pastagens sob degradação severa ou moderada ainda são majoritárias.

Em estudo sobre o potencial de intensificação das pastagens brasileiras entre 2014 e 2015, Arantes et al. (2018) encontraram potencial de aumento da Capacidade de Suporte dos pastos brasileiros de 0,97UA/hectare para 3,60UA/hectare (na média nacional), utilizando dados de produção primária bruta obtidos pelo sensor MODIS. Este potencial, apesar do alerta dos autores sobre ser superestimado, poderia ser ainda maior se considerada a penalização da produtividade potencial encontrada nesta tese.

Quanto à distribuição espacial das áreas de pastagens degradadas, sua dinâmica também está relacionada a fatores sociais, ambientais e econômicos. Regiões mais vulneráveis nesses aspectos também estão sujeitas a menor eficiência e retorno econômico da atividade pecuária, com impactos negativos para os produtores, para o meio ambiente e para toda sua cadeia de valor. Nessas regiões, ações de recuperação de pastagens e aumento da produtividade precisam de mais suporte de entidades públicas e privadas para auxiliar os produtores (PEREIRA et al., 2018).

Nas amostras dos SPP com baixa correlação ($r \leq 45\%$) entre as séries de produtividade observada e potencial (Figura 21), representadas pelos municípios de Água Fria de Goiás-GO (SPP 1), Campo Novo do Parecis-MT (SPP 2), Crixás-GO (SPP 3), Canarana-MT (SPP 4) e Porangatu-GO (SPP 5), o modelo de produtividade potencial não teve comportamento adequado e, em função disso, foram excluídos da discussão sobre a penalização da produtividade.

As amostras remanescentes mantiveram o contraste entre a penalização da produtividade com a média anual da radiação fotossinteticamente ativa (RAD_{par}) e com a deficiência hídrica total anual (DEF_{cad100}), com correlação (r) de -71% e -60% para o grupo

U1, e -76% e -66% para o grupo C1, respectivamente. No caso da radiação (RAD_{par}), os resultados mostraram que em regiões com regime de radiação solar reduzido, o manejo dessas pastagens deve ser otimizado para a obtenção de retornos econômicos em produtividade (PITTARELLO et al., 2020), observando as condições limitantes naturais que não podem ser contornadas.

A deficiência hídrica total anual (DEF_{cad100}), por sua vez, mostrou que a penalização da produtividade foi mais expressiva em áreas onde o déficit hídrico foi menor. Isto indica subutilização das suas áreas de pastagem (possivelmente por degradação biológica, pois o acúmulo de matéria seca medido pelo $NDVI$ foi reduzido) em regiões onde seu desenvolvimento seria favorecido pela maior disponibilidade de água. Esse fenômeno, a princípio, seria um efeito esperado em áreas com deficiência hídrica acentuada (DIAS-FILHO, 2015).

Na média entre os grupos U1 e C1, as demais variáveis climatológicas apresentaram correlação menor com a penalização da produtividade, com $r=-25\%$ e $r=-19\%$ para precipitação anual ($PREC$) e temperatura mínima ($TEMP_{min}$), respectivamente, $r=-7\%$ para evapotranspiração potencial (ET_p) e $r=-0,5\%$ para temperatura máxima ($TEMP_{máx}$).

A análise do desenvolvimento das pastagens sob o prisma da penalização da produtividade potencial pode abrir novos paradigmas sobre a relação com os parâmetros meteorológicos e climáticos (ALVES et al., 2021) que limitam ou favorecem a produção de matéria seca (ZHANG et al., 2021) e as opções de manejo que contribuem de forma mais efetiva com a produtividade (PITTARELLO et al., 2020, YU et al., 2020).

Tabela 9 — Distribuição da diferença relativa entre os modelos de produtividade observada e potencial (*PRP*) para o grupo U1. As colunas representam os percentuais encontrados nas posições de mínimo (Mín.), de 25% (Q1), da mediana (Q2), de 75% (Q3), máximo (Máx.) e o desvio padrão (D.P.).

Local	Resumo descritivo					
	(%)					D.P.
	Mín.	Q1	Q2	Q3	Máx.	
SPP 1						
Ponta Porã-MS	31	49	53	58	83	08
Tesouro-MT	13	41	46	52	82	07
Avaré-SP	23	40	44	48	74	06
SPP 2						
Itaporã-MS	37	53	57	61	85	06
Rio Verde-GO	04	33	39	44	85	09
Birigui-SP	23	48	53	57	83	07
SPP 3						
Rondonópolis-MT	05	29	35	41	92	09
Naviraí-MS	26	49	53	57	97	07
Piracanjuba-GO	00	24	30	35	71	08
SPP 4						
Campo Grande-MS	33	52	56	60	93	06
Serranópolis-GO	18	37	43	48	74	09
Porto Murtinho-MS	36	52	55	59	75	05
SPP 5						
Alcinópolis-MS	14	40	45	50	84	08
Montes Claros de Goiás-GO	21	43	47	51	81	06
Aparecida do Taboado-MS	20	50	54	57	91	05

Tabela 10 — Distribuição percentual da diferença relativa entre os modelos de produtividade observada e potencial (*PRP*) para o grupo C1. As colunas representam os percentuais encontrados nas posições de mínimo (Mín.), de 25% (Q1), da mediana (Q2), de 75% (Q3), máximo (Máx.) e o desvio padrão (D.P.).

Local	Resumo descritivo					
	($\%$)					
	Mín.	Q1	Q2	Q3	Máx.	D.P.
SPP 1						
Ponta Porã-MS	35	53	57	62	87	07
Tesouro-MT	21	47	52	56	84	07
Avaré-SP	30	46	49	53	77	06
SPP 2						
Itaporã-MS	43	58	61	65	86	05
Rio Verde-GO	13	40	45	50	87	08
Birigui-SP	30	53	57	61	84	06
SPP 3						
Rondonópolis-MT	14	35	41	46	93	08
Naviraí-MS	33	54	57	61	98	06
Piracanjuba-GO	08	31	36	42	74	07
SPP 4						
Campo Grande-MS	38	56	60	64	94	05
Serranópolis-GO	26	43	48	53	77	08
Porto Murtinho-MS	42	56	59	63	77	04
SPP 5						
Alcinópolis-MS	22	46	50	55	85	07
Montes Claros de Goiás-GO	16	39	44	48	81	06
Aparecida do Taboado-MS	27	55	58	62	92	05

O agrupamento dos parâmetros sazonais extraídos das séries temporais geradas pelos modelos de produtividade observada e potencial (para ambos os grupos, U1 e C1) definiu os perfis de produtividade regional para todas as amostras.

Inicialmente, a análise singular da penalização relativa da produtividade não permitiu distinguir claramente os *clusters* gerados, devido à similaridade da sua distribuição. A agregação com os outros parâmetros sazonais aumentou o grau de diferenciação das classes com base também no tempo e na intensidade das variações observadas (Apêndice 8). A análise

de agrupamento (*clustering*) como metodologia para rotulagem não-supervisionada (RICHARDS, 2005) ainda hoje se mostra uma técnica comumente adotada em aplicações de sensoriamento remoto.

Com o objetivo de melhorar a eficiência do processo de aquisição de amostras de treinamento em aplicação de larga escala espacial, Santos et al. (2021) utilizaram agrupamento hierárquico para subclassificação de séries temporais em áreas sob cultivos anuais e pastagem. Concluíram que o método demonstrou melhor performance na diferenciação de cultivos anuais do que em áreas de pastagem, evidenciando o desafio da subclassificação de áreas de pasto.

Em aplicação de larga escala temporal, Viana et al. (2019) aplicaram o algoritmo *K-Means* no refinamento da assinatura espectral de amostras de classes de uso e mudança de uso da terra isso refletiu positivamente na performance da classificação posterior.

A performance dos modelos gerados apresentou comportamento variado ao longo das amostras dos SPP. Na comparação entre os algoritmos utilizados, o RF teve melhor performance em praticamente todas as amostras (Figura 31), variando sua acurácia geral entre 43% e 79% para o grupo U1 e entre 43% e 80% para o grupo C1, inicialmente levando em consideração todas as classes determinadas pela análise de agrupamento. O melhor desempenho do algoritmo RF, em comparação a outros comumente adotados em aplicações de mineração de dados e aprendizado de máquina voltadas a geociências, também pode ser observado em Campos-Taberner et al. (2019). No caso, o RF foi superior aos algoritmos SVM, kNN e atingiu 89% de acurácia geral na discriminação de vários tipos de cobertura do solo, mas inferior ao algoritmo *Boosting*, também baseado em árvores de decisão, que atingiu cerca de 94% de acurácia geral. Parente et al. (2017) e Parente e Ferreira (2018) utilizaram o algoritmo RF no mapeamento de pastagens no território brasileiro utilizando imagens dos satélites Landsat e MODIS e reportaram 87% e 80% de acurácia geral, respectivamente. Em revisão sobre o uso do algoritmo RF em aplicações de sensoriamento remoto, Belgiu e Drăguț (2016) e Sheykhmousa et al. (2020), reforçando os resultados obtidos nesta tese, também mostraram que este algoritmo tem performance ligeiramente superior ao SVM, sendo também mais eficiente na classificação utilizando dados multidimensionais, menos sensível à parametrização e menos custoso computacionalmente para treinamento do modelo.

Na avaliação por classe (*cluster*), algumas amostras apresentaram acurácia do produtor e do usuário sensivelmente inferiores em (ao menos) uma das classes em relação às demais. Como exemplo, menciona-se Tesouro-MT (SPP 1), Itaporã-MS (SPP 2), Naviraí-MS

(SPP 3), Serranópolis-GO (SPP 4) e Aparecida do Taboado-MS (SPP 5) (Figuras 32 e 33). Uma das explicações possíveis pode estar associada ao número pré-definido de *clusters* para a modelagem com o algoritmo *K-Means*. Isto, nesse caso, abriria espaço para personalização do número de classes do mapa de referência com possibilidade de melhora na performance do modelo.

Fränti e Sieranoja (2018) sugerem que a performance dos resultados é melhor quanto menor o número de *clusters*. Ressalta-se que a definição do número de *clusters* para aplicação do algoritmo *K-Means* não é uma tarefa trivial, mas sim repetitiva e dependente da aplicação, do contexto e do modo de inicialização. Por isso, pode ser que a heurística adotada na obtenção desse número — redução da inércia relativa pelo aumento do número de *clusters* e definição de um número fixo para todas as amostras — tenha prejudicado o desempenho final em alguns locais, o que pode significar limitação na generalização da aplicação devido à baixa separabilidades das classes vegetativas.

Ainda que não haja consenso sobre a melhor forma de inicialização (JAMES et al., 2023), uma das linhas de pesquisa acerca do algoritmo *K-Means* busca avançar na otimização da inicialização e automatização do processo de obtenção do número de *clusters* ideal (VILORIA e LEZAMA, 2019; SINAGA e YANG, 2020; CHOWDHURY et al., 2021).

Outra explicação, mais simples que a primeira, porém não negligenciável, pode estar ligada à modelagem (PARENTE et al., 2017) que deu origem aos polígonos que delimitam as áreas de pastagem e que podem ter classificado erroneamente outros tipos de cobertura.

Figura 31 — Acurácia geral dos diferentes modelos de classificação sobre as amostras dos SPP.




Figura 32 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando todas as classes geradas a partir dos modelos de produtividade observada (NDVI) e potencial (grupo U1).





Figura 33 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando todas as classes geradas a partir dos modelos de produtividade observada (NDVI) e potencial (grupo C1).



Outras explicações para a diminuição da performance da classificação em alguns casos podem estar relacionadas: (i) à resolução espacial das séries de *NDVI* (250m), que pode ter promovido a mistura espectral dos alvos nas áreas vegetadas e contribuído com a redução do seu grau de discriminação; (ii) à resolução espaço-temporal e representatividade das séries meteorológicas; e (iii) à incerteza dos próprios modelos de produtividade, tanto observada quanto potencial.

A penalização da acurácia em razão da fonte de dados remotos pode ser observada comparando os dados de Parente et al. (2017) e Parente e Ferreira (2018), onde a acurácia geral dos modelos diferiu para uma aplicação análoga utilizando dados Landsat (87%) e MODIS (80%), respectivamente.

Em outra abordagem, agora comparando o uso de dados de satélites mais modernos e disponibilizados gratuitamente com resolução espacial superior ao sensor MODIS no mapeamento de áreas de soja e milho, Song et al. (2021) também obtiveram performance superior (94,8% a 96,8% de acurácia geral) utilizando dados das constelações Landsat (30m) e Sentinel-2 (10m) em razão da melhor resolução espacial, embora ainda atestem a boa qualidade no mapeamento utilizando imagens do sensor MODIS (250m) (92% de acurácia geral).

No caso dos dados meteorológicos, salienta-se que os dados de temperatura e precipitação disponibilizados pela base Nasa-Power, e empregados no cálculo do balanço hídrico e na modelagem do acúmulo potencial de matéria seca, foram gerados com base no modelo de assimilação MERRA-2²⁰. Apesar de apresentar²¹ boa assertividade para temperatura ($r^2=87\%$), demonstrou baixa precisão para precipitação diária ($r^2=39\%$). Alguns estudos (DIAS e SENTELHAS, 2019; DUARTE e SENTELHAS, 2020; VALERIANO et al., 2019) avançaram na validação do uso dos dados de precipitação da base Nasa-Power em substituição aos dados medidos em campo que, muitas vezes, são difíceis de serem obtidos, principalmente quando há demanda por dados em larga escala espacial e temporal, como é o caso desta tese.

Ainda que estes estudos atestem que a precipitação diária não apresenta precisão suficiente, também mostram que o aumento da escala temporal ameniza essa incerteza e aumenta a concordância do modelo com dados de superfície (DIAS e SENTELHAS, 2019; DUARTE e SENTELHAS, 2020). Este foi exatamente o caso desta tese, onde a escala temporal

²⁰ Disponível em: <https://gmao.gsfc.nasa.gov/reanalysis/MERRA-2/>. Acesso em: 21/02/2024.

²¹ Disponível em: <https://power.larc.nasa.gov/docs/methodology/meteorology/assessment/>. Acesso em: 21/02/2024.

empregada variou entre decendial e mensal para cálculo do balanço hídrico sequencial e climatológico respectivamente, enquanto as correlações entre os modelos de produtividade potencial e observado e entre o modelo de produtividade observada com as variáveis meteorológicas de entrada e resultantes do balanço hídrico foram feitos com a mesma escala das séries temporais de *NDVI* do sensor MODIS (16 dias) (Tabela 2).

Além disso, novos modelos (XAVIER et al., 2022; BALLARIN et al., 2023) vêm sendo desenvolvidos especificamente para as condições brasileiras e têm demonstrado potencial para contribuir de forma mais assertiva na modelagem do desenvolvimento das culturas agrícolas, em substituição aos dados medidos em superfície, mais difíceis de serem levantados. Dias e Sentelhas (2019) e Duarte e Sentelhas (2020) também contribuem comparando dados das bases Nasa-Power com aquela proposta por Xavier et al. (2022).

A reclassificação conduzida após a remoção da classe menos informativa (i.e., com menor acurácia do produtor e/ou usuário) teve como objetivo remover classes que poderiam representar outros tipos de cobertura, geralmente distribuídas marginalmente nos polígonos de pastagem (Figuras 34 e 35) e mapeadas em função de erros de classificação das áreas de pastagem a partir do mapeamento original (PARENTE et al., 2017). Esta estratégia também foi adotada também em Prasad et al. (2022) e Santos et al. (2021). Com isso, a remoção da classe (*cluster*) com menor precisão de classificação pelo modelo permitiu o aumento da acurácia geral para o algoritmo RF entre 4% e 10% para o grupo U1 e entre 2% e 9% para o grupo C1, com média de 7% para ambos (Figuras 36 a 38).

Figura 34 — Distribuição das áreas de pastagem classificadas pela análise de agrupamento para o município de Tesouro-MT, representando o grupo genotípico U1.




Figura 35 — Distribuição das áreas de pastagem classificadas pela análise de agrupamento para o município de Porto Murtinho-MS, representando o grupo genotípico C1.




Figura 36 — Acurácia geral da classificação excluindo as classes de distribuição local marginal nas áreas de pastagem utilizando o algoritmo *Random Forest* sobre as amostras dos SPP.




Figura 37 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando apenas as classes com melhor desempenho prévio geradas a partir dos modelos de produtividade observada (*NDVI*) e potencial (grupo genotípico U1).





Figura 38 — Desempenho do modelo de classificação das imagens SAR para as amostras dos SPP considerando apenas as classes com melhor desempenho prévio geradas a partir dos modelos de produtividade observada (*NDVI*) e potencial (grupo genotípico C1).



Esta tese procura contribuir na modelagem de um mesmo tipo de cobertura (pastagem) utilizando dados SAR, onde o desafio na distinção dos alvos é maior e a performance dos algoritmos é penalizada. Isto é diferente dos estudos agroambientais com objetivo de avaliar o desempenho de algoritmos de aprendizado de máquina na identificação de diferentes classes de uso da terra e cobertura do solo utilizando dados SAR, em combinação com sensores óticos (CAMPOS-TABERNER, 2019; SONG et al., 2021; KORDI e YOUSEFI, 2022; PRUDENTE et al., 2022; ASADI e SHAMSODDINI, 2024) ou não (SILVA-PEREZ et al., 2021; XIAO et al., 2021; CHEN et al., 2022; NAJEM et al., 2023). Neste caso, geralmente, atinge-se maior desempenho (todos os estudos citados têm acurácia geral acima de 85%, com maioria acima de 90%) em função da significativa e já esperada distinção espectral dos alvos.

Em Raab et al. (2020), os autores avaliaram a eficiência do uso de dados óticos (Sentinel-2) na extração de parâmetros de pastagem seminaturais. Obteve-se melhor desempenho para as concentrações de fibra detergente de ácido orgânico ($r^2=78\%$) e proteína bruta ($r^2=70\%$), e pior para altura do pasto comprimido ($r^2=59\%$) e produção de matéria seca ($r^2=45\%$). A integração com dados SAR, por sua vez, resultou em valores máximos do coeficiente de determinação (r^2) iguais a 79%, 73%, 60% e 45%, respectivamente, o que mostra pouca contribuição dessa fonte de dados na abordagem empregada.

Muro et al. (2022) conseguiram determinar em torno de 40% da variância (r^2) para estimar a biomassa e riqueza de espécies utilizando apenas dados de sensores óticos (Sentinel-2). A integração com dados SAR aumentou em apenas ~3% a assertividade (r^2) do algoritmo RF e reduziu a qualidade dos resultados do modelo treinado utilizando Redes Neurais Profundas (*Deep Neural Networks*).

Buhvald et al. (2020) reportaram entre 70% e 85% de acurácia na diferenciação de áreas de pastagem de uso intensivo e extensivo. Atribuíram, porém, às informações de terreno (declividade e elevação), a maior relevância na distinção entre as classes. Utilizando apenas dados topográficos, os autores atingiram 79% de acurácia geral, o que mostra que a alta assertividade do modelo se deu principalmente em razão da localização das áreas estudadas, e não pela resposta espectral da vegetação.

Zhang e Ren (2022) utilizaram dados óticos (Landsat) e SAR para estimar a altura do dossel de pastagens através de modelos de aprendizado de máquina e atingiram, no melhor modelo, $r^2=58\%$ utilizando a combinação desses dados e $r^2=50\%$ utilizando apenas dados óticos. Em nenhum desses estudos os resultados foram beneficiados de forma significativa pela

inclusão de dados SAR, expressando situações de pouco aumento, a mera manutenção ou até redução da sua assertividade, o que mostra que a maior contribuição nesses resultados provém do uso de dados de sensores óticos (GRIFFITHS et al. 2020).

Comparativamente, os resultados obtidos nesta tese avançam ao conseguir atingir acurácia geral entre 60% e 78% para a maioria das regiões analisadas, podendo também atingir resultados iguais ou maiores que 80%, chegando à 94%, o que contribui na aplicação de dados SAR na extração de parâmetros biofísicos para monitoramento de pastagens.

Por fim, cabe destacar que embora alguns dos trabalhos citados utilizam mais de uma leitura de um mesmo alvo (RAAB et al., 2020; MURO et al., 2022), o que constitui ganho de informação temporal, nesta tese foi realizada apenas uma coleta da resposta espectral da vegetação, abrindo espaço para aprimoramentos pela inclusão da variabilidade temporal dos alvos (WANG et al., 2019; SILVA-PEREZ et al., 2021; MASCOLO et al., 2022; JAFARZADEH et al., 2024; MA et al., 2024;).

O desempenho dos parâmetros polarimétricos no algoritmo RF (Figuras 39 e 40) mostra que os elementos do vetor de Stokes (g_0 , g_1 , g_2 e g_3) tiveram maior importância na redução da impureza pela métrica do Ganho de Informação (BREIMAN, 2001) na distinção das classes, seguidos pelos graus de polarização (GP) e de depolarização (GD), elipticidade (ε), elevação ($Elev$), razão de polarização circular (RPC) e ângulo de incidência local (θ). A extração da relevância relativa dos atributos preditores em aplicações utilizando o algoritmo RF traz reflexões importantes sobre a interação dos alvos com relação aos dados e características do método ou ferramenta de sensoriamento adotado (BELGIU e DRĂGUȚ, 2016). A Figura 41 ilustra a resposta da vegetação ao sinal incidente a partir dos elementos mais importantes do vetor de Stokes na classificação pelo algoritmo RF (g_0 , g_1 , g_2).

Figura 39 — Importância dos parâmetros polarimétricos no desempenho do modelo pelo Decréscimo Médio da Impureza (*DMI*) para o grupo genotípico U1. Os parâmetros representam o sinal retornado à antena e representam o vetor de Stokes (g_0 - g_3), os graus de polarização (GP), de depolarização (GD), de elipticidade (ϵ), a elevação ($Elev$), a razão de polarização circular (RPC) e o ângulo de incidência local (θ).




Figura 40 — Importância dos parâmetros polarimétricos no desempenho do modelo pelo Decréscimo Médio da Impureza (*DMI*) para o grupo genotípico C1. Os parâmetros representam o sinal retornado à antena e representam o vetor de Stokes (g_0 - g_3), os graus de polarização (*GP*), de depolarização (*GD*), de elipticidade (ϵ), a elevação (*Elev*), a razão de polarização circular (*RPC*) e o ângulo de incidência local (θ).





Figura 41 — Composição RGB do sinal retroespalhado pelos parâmetros do vetor de Stokes (g_0 , g_1 , g_2) com maior relevância no desempenho da classificação pelo algoritmo RF.



As propriedades geométricas e dielétricas (i.e., umidade) dos alvos influenciam a potência (g_0 ; $W.m^{-2}$) e estado de polarização (g_1 , g_2 e g_3) dos sinais incidente e retroespalhado e a quantificação desses parâmetros contém toda a informação disponível sobre eles (RANEY, 2006; RICHARDS, 2009; CHARBONNEAU et al., 2010; RANEY, 2024). Dessa forma, a informação contida no vetor de Stokes, cuja exploração raramente é realizada (VAGHELA et al., 2021), mostrou-se mais efetiva que os demais parâmetros na distinção entre as classes considerando a escala de aplicação desta tese, onde não houve disponibilidade de informações mais detalhadas sobre os alvos imageados. Trabalhos correlatos que utilizaram os demais parâmetros, e que conseguiram gerar modelos com boa assertividade, o fizeram considerando áreas menos abrangentes e, portanto, com acesso facilitado a informações mais detalhadas e específicas sobre os alvos estudados (McNAIRN e BRISCO, 2014; WANG et al., 2019; MA et al., 2024).

O processo de degradação pode levar tanto à redução quanto ao aumento do acúmulo de biomassa, variando em função do tipo de degradação presente (biológica ou agrícola) (DIAS-FILHO, 2015). No caso da degradação biológica, se o relevo não for muito acidentado, a maior interação da superfície do solo com o sinal incidente aumenta a

contribuição do componente especular que reduz a potência (g_0) do sinal retroespalhado e a rotação (ou inversão) da polarização incidente (g_1 , mas com reflexos sobre g_2 e g_3 que armazenam informações sobre a fase relativa entre os componentes vertical e horizontal) (DOMENECH et al., 2020; MA et al., 2024). A degradação agrícola, por sua vez, reduz a influência do solo e aumenta a predominância da vegetação, pois os alvos (i.e., biomassa de espécies contaminantes e da espécie forrageira) se caracterizam como espalhadores isotrópicos (CRABBE et al., 2021). Pastagens em boas condições, portanto, se assemelhariam a áreas sob degradação agrícola, onde a biomassa é mais volumosa e as características do sinal retroespalhado distinguem daquelas medidas pelo solo.

O segundo fator de influência sobre a potência do sinal retroespalhado (g_0) diz respeito às condições dielétricas (i.e., umidade) da vegetação e do solo, pois este está diretamente relacionado ao teor de água no meio. Pastagens sob maior grau de degradação apresentam menor cobertura e desenvolvimento radicular e, portanto, diferem daquelas em boas condições no que diz respeito à retenção hídrica (ZHANG et al., 2021). Nesta tese, como a amostragem dos dados SAR foi feita apenas entre dezembro e janeiro, período mais úmido do ano e onde o acúmulo de biomassa é maior, o solo estava próximo ou no nível de armazenamento pleno (CAD) (THORHTNWAITE e MATHER, 1955) em todas as áreas amostradas (Figuras 26 e 27). Por isso, não foi possível avaliar o desempenho dos modelos considerando períodos mais secos, tanto para vegetação quanto para o solo. Além disso, como houve limitação para aquisição de informações de campo sobre a condição hídrica do solo, esta tese não avançou na quantificação da sua dinâmica utilizando dados SAR (BAGHDADI et al., 2017; HÄNSCH et al., 2021).

Por fim, a fase relativa do sinal retroespalhado (g_2 e g_3) contribuiu como terceiro e quarto parâmetro mais importante para a distinção entre as classes de pastagem, o que justifica a importância de produtos polarimétricos como o vetor de Stokes em aplicações de dados SAR (RANEY, 2006; RANEY, 2024).

A interação do sinal incidente com meios vegetados resulta em uma fração não polarizada do sinal retroespalhado. Apesar de não contribuir com a avaliação polarimétrica do alvo, compõe a potência total retornada à antena (g_0) em maior ou menor grau e, portanto, pode ser um elemento de distinção entre os alvos (RICHARDS, 2009; McNAIRN e BRISCO, 2014). O grau de polarização (GP) e de depolarização (GD), complementares ($r=100\%$), apresentaram contribuição intermediária na discriminação das classes de pastagem devido às características

das áreas estudadas. Ainda que diferissem quanto à severidade do processo de degradação, estão sob regime climático comparável e, por terem sua cobertura modelada como gramíneas (*Urochloa* spp. e *Cynodon* spp.), presume-se que estejam nos mesmos estádios de desenvolvimento fenológico (desenvolvimento vegetativo) em toda a extensão da área de estudo. Como a amostragem dos dados SAR foi feita para apenas uma data, não foi possível capturar a variação temporal das interações do sinal incidente com as demais etapas do desenvolvimento estrutural da vegetação que permitisse maior distinção entre as classes (McNAIRN e BRISCO, 2014; WANG et al., 2019). Pedreira et al. (2009) pontuam que, diferentemente das culturas anuais, a distinção das fases do ciclo fenológico em pastagens perenes é um desafio científico com lacunas ainda a serem preenchidas, não sendo recomendadas intervenções com base em definições além das fases vegetativas e reprodutivas, inclusive em escala de campo. Dessa forma, nas condições desta tese, principalmente em função da escala espacial empregada, a influência do grau de polarização (GP) e do grau de depolarização (GD) seria maior para contrastar pastagens com degradação mais acentuada – principalmente com degradação do tipo biológico, onde há predominância de solo exposto (DIAS-FILHO, 2015) e menor depolarização do sinal incidente, principalmente para a polarização vertical (McNAIRN e BRISCO, 2014) – e pastagens com pouca ou nenhuma degradação – onde a depolarização em função da estrutura aleatória do meio vegetado (i.e., GD) é maior. As Tabelas 9 e 10 mostram, contudo, que esta situação foi menos frequente na área avaliada dado que as faixas entre os quartis Q1 (25%) e Q3 (75%) concentram níveis intermediários de penalização da produtividade. A contribuição desses atributos (GD e GP) poderia ter sido maior se houvesse à disposição informações sobre a altura (WANG et al., 2022) e estrutura do dossel vegetal (McNAIRN e BRISCO, 2014) e de heterogeneidade da pastagem (que pode significar degradação agrícola) (CRABBE et al., 2021), características mais facilmente disponíveis em aplicações de menor escala espacial.

Os demais parâmetros apresentaram menor relevância relativa para a distinção entre as classes devido à natureza da informação que contêm ou à redundância com os elementos discutidos até o momento. No caso da elipticidade (ϵ), esta apresentou relevância menor para a distinção entre as classes em função da alta correlação com o parâmetro g_3 do vetor de Stokes.

O menor desempenho da elevação ($Elev$) na performance do modelo contrasta com o trabalho de Buhvald et al. (2020), no qual parâmetros de configuração do terreno foram responsáveis pela maior parcela da assertividade do modelo proposto. Nesse trabalho, a superioridade das características do terreno em relação aos atributos espectrais pode ter refletido

simplesmente erros de amostragem ou modelagem, mas também pode revelar contextos no uso da terra que excedam a capacidade de sistemas de monitoramento remoto (i.e., tomada de decisão por práticas de pecuária extensiva ou intensiva a depender da configuração do terreno), que limitam a aplicação de modelos preditivos indistintamente.

Nesse caso, modelos com pouca participação dos atributos do terreno, como o apresentado nesta tese, teriam sua performance sensivelmente prejudicada. Por sua vez, a razão de polarização circular (*RPC*) simulada a partir da matriz de covariância extraída dos dados Sentinel-1 apresentou a segunda menor relevância na performance do modelo RF. Esse baixo desempenho se deve ao fato do Sentinel-1 não configurar estritamente um sistema SAR de polarimetria compacta (RANEY, 2006; CHARBONNEAU et al., 2010; TORRES et al., 2012), e, portanto, não dispor das características de transmissão do sinal necessárias para um melhorar a performance preditiva.

Utilizando dados de sistemas de polarização compacta híbrida da constelação RADARSAT (KROUPNIK et al., 2021), Charbonneau et al. (2010) atingiram acurácia geral comparável ao método de decomposição de Cloude e Pottier (1997), que utiliza polarimetria completa (quadrática), e, portanto, dispõe de todas as combinações possíveis de orientação entre a transmissão do sinal e a recepção do eco. Ressalta-se que o RADARSAT transmite polarização circular e recebe (retroespalhamento pelo alvo) polarização linear dupla e coerente (i.e., com preservação do ângulo fase relativo entre os componentes vertical e horizontal).

Por fim, a menor relevância do ângulo de incidência local (θ ; grau) é característica em alvos de espalhamento do tipo volumétrico devido à pequena extensão da interface de espalhamento do sinal com o alvo, que por sua vez é considerado um espalhador isotrópico em cada interação do sinal com o dossel da vegetação, o que reduz a capacidade de distinção dos alvos (RICHARDS, 2009).

5 CONCLUSÕES

- As características físico-químicas do solo se dividem em duas dimensões, representativas da fertilidade e acidez do solo. Entretanto, a precisão da determinação dessas características em escalas mais abrangentes utilizando resultados de análise físico-química de solo pode ser melhorada se novos parâmetros, mais relacionados com a variabilidade dos nutrientes, coletados em campo ou determinados em laboratório, forem agregados à essas bases de dados.
- Na comparação estratificada dos PFS, diferenças da acidez entre solos de pastagens e de sistemas integrados em relação aos de vegetação nativa ocorrem na camada superficial e são atenuadas nas camadas mais profundas e com o decréscimo da densidade do solo (em direção a solos mais argilosos). Comparando a fertilidade entre os grupos texturais de solos de pastagem, as diferenças são mais frequentes na camada superficial (0-5cm), com um padrão diferenciando as texturas arenosa e média de argilosa e muito argilosa nas camadas mais profundas, padrão também presente em solos de sistemas integrados. Na dimensão da acidez, as diferenças se acentuam com o aumento da profundidade, mostrando que nessas camadas a realização da correção da acidez é mais restrita aos solos arenosos e médios.
- Na comparação geral, a heterogeneidade dos PFS de pastagem é maior para a fertilidade em solos de textura arenosa na camada 20-30cm, o que mostra que a amostragem deve ser mais detalhada nessas condições (aumentando a densidade amostral, por exemplo) e que importar estratégias de adubação de outras áreas pode diminuir a eficiência nutricional.
- Apesar da maior rentabilidade e melhoria dos benefícios sociais promovidos pela adoção de sistemas integrados, a pecuária extensiva ainda é o sistema mais adotado no Brasil, e barreiras financeiras políticas e técnicas ainda se impõe ao processo de transição. Portanto, especialmente para solos argilosos e muito argilosos, a intensificação e recuperação de pastagens através de adubação e correção das condições de acidez do solo ainda são opções viáveis para aumentar a produtividade e a eficiência do setor pecuário, que por sua vez reduz a pressão por desmatamento e promove o acúmulo de carbono no solo. Esta tese mostra que o manejo do solo considerando camadas mais profundas é fundamental para alcançar estes objetivos.
- Na busca pela digitalização da agricultura, aplicações em bases de dados de análises de solo podem ser um elo de integração e troca de conhecimento importante entre diferentes atores do setor, como pecuaristas, agricultores e fornecedores de insumos e serviços em diferentes escalas espaciais. Desta forma, os agricultores e pecuaristas poderiam se beneficiar de

análises de solo coletadas e analisadas por prestadores de serviços e compartilhadas com pesquisadores a fim de impulsionar o conhecimento científico sobre as condições e estratégias de manejo do solo.

- Os municípios de Goiás e Mato Grosso do Sul apresentam semelhança na ocupação territorial por pastagens e distribuição do rebanho, com ocupação de cerca de 50% do seu território (SPP 5). São Paulo, por sua vez, concentra a maior parte dos municípios com taxa de lotação superior (SPP 2 e 3, com 3,26 cabeças/hectare e 2,02 cabeças/hectare, respectivamente). A pecuária praticada no Mato Grosso o distingue dos demais, com maior área de pasto absoluta por município e taxa de ocupação inferior aos demais estados (1,40 cabeças/hectare).
- Na maioria dos SPP, as taxas de lotação observadas são baixas e apontam para uma semelhança no manejo empregado, o que pode ser uma oportunidade de avanços na eficiência do setor como um todo. O contraste entre (i) os municípios do SPP 2 – com maior taxa de lotação, menor área absoluta de pastagem e segunda menor ocupação relativa por pastagem – e (ii) os municípios dos SPP 4 e 5 – ambos com taxa de lotação reduzida e com maior área de pastagem absoluta e relativa, respectivamente – mostra que o crescimento vertical deve ser o objetivo de programas e políticas de impulsionamento da produção.
- Maior disponibilidade de orientação técnica impacta positivamente a eficiência da pecuária e promove aumento da lotação dos pastos. São Paulo é o estado onde os pecuaristas declararam ter maior acesso à orientação técnica enquanto Mato Grosso apresenta os menores índices. Coincidentemente, é em São Paulo que estão concentrados a maioria dos municípios com alta taxa de lotação dos seus pastos enquanto Mato Grosso, Goiás e Mato Grosso do Sul concentram os municípios com menores taxa de lotação e menor taxa de pecuaristas que declararam receber algum tipo de orientação técnica. A parcela superior de produtores que declararam serem eles próprios a fonte de informações na propriedade em relação às outras revela um gargalo existente quanto ao acesso dos produtores à assessoria técnica e um obstáculo para aumentar a eficiência da pecuária brasileira.
- O cooperativismo é um importante aliado do setor pecuário, pois os municípios com as maiores taxas de lotação também são aqueles onde há maior atuação das cooperativas. Nos estados, essa atuação se mostra mais frequente no estado de São Paulo, que concentra os municípios com a pecuária mais eficiente, e em Goiás, enquanto o estado do Mato Grosso apresenta a menor participação desse sistema no seu modelo produtivo.

- Ainda é grande a participação de órgãos governamentais no fornecimento de apoio técnico por meio de instituições de ensino, pesquisa e extensão rural, o que contrasta com a baixa presença da iniciativa privada na prestação desse tipo de serviço e mostra que há demanda para a iniciativa privada auxiliar a atividade pecuária, visto que o sistema público não é suficiente para supri-la de forma integral, especialmente considerando as crescentes exigências técnicas e ambientais por parte do mercado e de agências reguladoras.
- O desenvolvimento de modelos de produtividade potencial de pastagens em escalas espaciais mais abrangentes precisa considerar variáveis como aquelas extraídas do balanço hídrico para atender de forma mais precisa a variação das condições ambientais locais. Parâmetros relacionados à demanda evaporativa do sistema solo-planta como deficiência hídrica, temperatura, evapotranspiração e disponibilidade energética (radiação) estão mais relacionadas à produtividade observada do que o regime hídrico anual.
- As alterações climáticas que provocam o agravamento da estiagem nas regiões estudadas colocam em risco a atividade pecuária que abrange um contingente equivalente à 25% do rebanho bovino nacional, com impactos diretos na economia local em função da alta ocupação territorial dos municípios por pastagem.
- Na área de estudo, a quebra de produtividade estimada varia entre aproximadamente ~30% e ~60%, o que representa uma oportunidade de crescimento vertical da produção e a oportunidade do país se estabelecer ainda mais como um vetor de sustentabilidade e de mitigação das mudanças climáticas dado que pastagens bem manejadas promovem o acúmulo de carbono no solo e reduzem as emissões líquidas do sistema.
- Modelos de classificação utilizando dados SAR possibilitam identificar essa penalização da produtividade potencial com até 94% de acurácia geral, com o algoritmo *Random Forest* apresentando performance superior aos demais (*Support Vector Machine*, *k-Nearest Neighbor* e *Naive Bayes*) na construção dos modelos.
- O vetor de Stokes, produto polarimétrico coerente, apresentou a maior relevância na subclassificação de pastagens e conseguiu discriminar as propriedades dielétricas e estruturais da vegetação que implicaram na determinação do seu nível de degradação.
- Os resultados obtidos corroboram a hipótese de que parâmetros biofísicos de pastagens, obtidos por dados de sensores remotos ativos, e de fertilidade do solo podem ser empregados na caracterização do seu nível de degradação a partir de técnicas estatísticas e de aprendizado de máquina.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDALLA, M. et al. Does liming grasslands increase biomass productivity without causing detrimental impacts on net greenhouse gas emissions? **Environmental Pollution**, [s.l.], v.300, p.118999, mai., 2022. Disponível em: <<https://doi.org/10.1016/j.envpol.2022.118999>>. Acesso em: 01/06/2024.

AGUIAR, D.A.; ADAMI, M.; SILVA, W.F.; RUDORFF, B.F.T.; MELLO, M.P.; DA SILVA, J.D.S.V. MODIS time series to assess pasture land. In: Geoscience and Remote Sensing Symposium, 30, 2010, Honolulu. **Anais...** [s.l.]: IEEE, 2010. p.2123–2126. Disponível em: <<https://ieeexplore.ieee.org/document/5649388>>. Acesso em: 01/06/2024.

AGUIAR, D.A.; RUDORFF, B.F.T.; SILVA, W.F.; ADAMI, M.; MELLO, M.P. Remote sensing images in support of environmental protocol: Monitoring the sugarcane harvest in São Paulo State, Brazil. **Remote Sensing**, Basel, v.3, n.12, p.2682–2703, 2011. Disponível em: <<https://doi.org/10.3390/rs3122682>>. Acesso em: 01/06/2024.

AGUIAR, J.T.; LOBO Jr., M. Reliability and discrepancies of rainfall and temperatures from remote sensing and Brazilian ground weather stations. **Remote Sensing Applications: Society and Environment**, [s.l.], v.18, p.100301, abr., 2020. Disponível em: <<https://doi.org/10.1016/j.rsase.2020.100301>>. Acesso em: 01/06/2024.

AHMED, M.; SERAJ, R.; ISLAM, S.M.S. The k-means Algorithm: A Comprehensive Survey and Performance Evaluation. **Electronics**, [s.l.], v.9, n.8, p.1295, ago., 2020. Disponível em: <<https://doi.org/10.3390/electronics9081295>>. Acesso em: 01/06/2024.

ALCÁNTARA, v.et al. Deep ploughing increases agricultural soil organic matter stocks. **Global Change Biology**, [s.l.], v.22, n.8, p.2939–2956, 2016. Disponível em: <<https://doi.org/10.1111/gcb.13289>>. Acesso em: 01/06/2024.

ALENCAR, A. et al. Mapping Three Decades of Changes in the Brazilian Savanna Native Vegetation Using Landsat Data Processed in the Google Earth Engine Platform. **Remote Sensing**, [s.l.], v.12, n.6, p.924, jan., 2020. Disponível em: <<https://doi.org/10.3390/rs12060924>>. Acesso em: 01/06/2024.

ALI, I.; GREIFENEDER, F.; STAMENKOVIC, J.; NEUMANN, M.; NOTARNICOLA, C. Review of machine learning approaches for biomass and soil moisture retrievals from remote sensing data. **Remote Sensing**, Basel, v.7, n.12, p.16398–16421, 2015. Disponível em: <<https://doi.org/10.3390/rs71215841>>. Acesso em: 01/06/2024.

ALI, I.; CAWKWELL, F.; DWYER, E.; BARRETT, B.; GREEN, S. Satellite remote sensing of grasslands: from observation to management. **Journal of Plant Ecology**, Oxford, v.9, n.6, p.649–671, 2016. Disponível em: <<https://doi.org/10.1093/jpe/rtw005>>. Acesso em: 01/06/2024.

ALI, I.; BARRETT, B.; CAWKWELL, F.; GREEN, S.; DWYER, E.; NEUMANN, M. Application of Repeat-Pass TerraSAR-X Staring Spotlight Interferometric Coherence to Monitor Pasture Biophysical Parameters: Limitations and Sensitivity Analysis. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.10, n.7, p.3225–3231, 2017. Disponível em: <<https://doi.org/10.1109/JSTARS.2017.2679761>>. Acesso em: 01/06/2024.

ALLEN, V.G.; BATELLO, C.; BERRETTA, E.J.; HODGSON, J.; KOTHMANN, M.; LI, X.; McIVOR, J.; MILNE, J.; MORRIS, C.; PEETERS, A.; SANDERSON, M. An international terminology for grazing lands and grazing animals. **Grass and forage science**, [s.l.], v.66, n.1, p.2–28, 2011. Disponível em: <<https://doi.org/10.1111/j.1365-2494.2010.00780.x>>. Acesso em: 01/06/2024.

ALTHOFF, D. et al. ETo-Brazil: A Daily Gridded Reference Evapotranspiration Data Set for Brazil (2000–2018). **Water Resources Research**, [s.l.], v.56, n.7, p.e2020WR027562, 2020. Disponível em: <<https://doi.org/10.1029/2020WR027562>>. Acesso em: 01/06/2024.

ALVES, L.A. et al. Soil acidification and P, K, Ca and Mg budget as affected by sheep grazing and crop rotation in a long-term integrated crop-livestock system in southern Brazil. **Geoderma**, [s.l.], v.351, p.197–208, out., 2019. Disponível em: <<https://doi.org/10.1016/j.geoderma.2019.04.036>>. Acesso em: 01/06/2024.

ALVES, L.M. et al. Assessment of rainfall variability and future change in Brazil across multiple timescales. **International Journal of Climatology**, [s.l.], v.41, n.S1, p.E1875–E1888, 2020. Disponível em: <<https://doi.org/10.1002/joc.6818>>. Acesso em: 01/06/2024.

ANDRADE, C.M.S.; VALENTIM, J.F. Soluções tecnológicas para a síndrome da morte do capim-marandu. Em: BARBOSA, R. A. Morte de pastos de braquiárias. Campo Grande: Empresa Brasileira de Pesquisa Agropecuária, 2006, p.175-197. Disponível em: <<https://www.alice.cnptia.embrapa.br/alice/handle/doc/504600>>. Acesso em: 01/06/2024.

APARECIDO, L.E.O.; ROLIM, G.S.; MORAES, J.R.S.C. Validation of ECMWF climatic data, 1979–2017, and implications for modelling water balance for tropical climates. **International Journal of Climatology**, [s.l.], v.40, n.15, p.6646–6665, 2020. Disponível em: <<https://doi.org/10.1002/joc.6604>>. Acesso em: 01/06/2024.

ARANTES, A.E. et al. Livestock intensification potential in Brazil based on agricultural census and satellite data analysis. **Pesquisa Agropecuária Brasileira**, [s.l.], v.53, p.1053–1060, set. 2018. Disponível em: <<https://doi.org/10.1590/S0100-204X2018000900009>>. Acesso em: 01/06/2024.

ASADI, B.; SHAMSODDINI, A. Crop mapping through a hybrid machine learning and deep learning method. **Remote Sensing Applications: Society and Environment**, [s.l.], v.33, p.101090, jan., 2024. Disponível em: <<https://doi.org/10.1016/j.rsase.2023.101090>>. Acesso em: 01/06/2024.

ASSAD, E.D. et al. Changes in soil carbon stocks in Brazil due to land use: paired site comparisons and a regional pasture soil survey. **Biogeosciences**, [s.l.], v.10, n.10, p.6141–6160, out., 2013. Disponível em: <<https://doi.org/10.5194/bg-10-6141-2013>>. Acesso em: 01/06/2024.

ASSIS, L.F.F.G. et al. TerraBrasilis: A Spatial Data Analytics Infrastructure for Large-Scale Thematic Mapping. **ISPRS International Journal of Geo-Information**, [s.l.], v.8, n.11, p.513, nov., 2019. Disponível em: <<https://doi.org/10.3390/ijgi8110513>>. Acesso em: 01/06/2024.

AVILA-DIAZ, A. et al. Assessing current and future trends of climate extremes across Brazil based on reanalyses and earth system model projections. **Climate Dynamics**, [s.l.], v.55, n.5, p.1403–1426, set., 2020. Disponível em: <<https://doi.org/10.1007/s00382-020-05333-z>>. Acesso em: 01/06/2024.

BAGHDADI, n.et al. Calibration of the Water Cloud Model at C-Band for Winter Crop Fields and Grasslands. **Remote Sensing**, [s.l.], v.9, n.9, p.969, set., 2017. Disponível em: <<https://doi.org/10.3390/rs9090969>>. Acesso em: 01/06/2024.

BALESDENT, J. et al. Atmosphere–soil carbon transfer as a function of soil depth. **Nature**, [s.l.], v.559, n.7715, p.599–602, jul., 2018. Disponível em: <<https://doi.org/10.1038/s41586-018-0328-3>>. Acesso em: 01/06/2024.

BALLARIN, A.S. et al. CLIMBra - Climate Change Dataset for Brazil. **Scientific Data**, [s.l.], v.10, n.1, p.47, jan., 2023. Disponível em: <<https://doi.org/10.1038/s41597-023-01956-z>>. Acesso em: 01/06/2024.

BAUMANN, K. et al. Clay fraction properties and grassland management imprint on soil organic matter composition and stability at molecular level. **Soil Use and Management**, [s.l.], v.38, n.4, p.1578–1596, 2022. Disponível em: <<https://doi.org/>>. Acesso em: 01/06/2024.

BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v.114, p.24–31, abr., 2016. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2016.01.011>>. Acesso em: 01/06/2024.

BERNARDI, A.C.C.; INAMASU, R.Y. **Adoção da agricultura de precisão no Brasil**. Em: BERNARDI et al. Agricultura de precisão: resultados de um novo olhar, Brasília: Empresa Brasileira de Pesquisa Agropecuária, 2014, p.559-577. Disponível em: <<http://www.alice.cnptia.embrapa.br/alice/handle/doc/1003682>>. Acesso em: 01/06/2024.

BERNARDI, A.C.C. et al. Spatial variability of soil properties and yield of a grazed alfalfa pasture in Brazil. **Precision Agriculture**, [s.l.], v.17, n.6, p.737–752, dez., 2016. Disponível em: <<https://doi.org/10.1111/sum.12815>>. Acesso em: 01/06/2024.

BERTRAND, I. et al. Stoichiometry constraints challenge the potential of agroecological practices for the soil C storage. A review. **Agronomy for Sustainable Development**, [s.l.], v.39, n.6, p.54, nov., 2019. Disponível em: <<https://doi.org/10.1007/s13593-019-0599-6>>. Acesso em: 01/06/2024.

BOURSCHEIDT, M.L.B. et al. BIODIVERSIDADE DE BACTÉRIAS ANTAGÔNICAS A FUNGOS ASSOCIADOS À SÍNDROME DA MORTE DO CAPIM-MARANDU (*Brachiaria brizantha*). **Nativa**, [s.l.], v.9, n.5, p.454–459, 2021. Disponível em: <<https://doi.org/10.31413/nativa.v9i5.12666>>. Acesso em: 01/06/2024.

BRASIL. MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO. **Plano Setorial de Mitigação e de Adaptação às Mudanças Climáticas para a Consolidação de uma Economia de Baixa Emissão de Carbono na Agricultura**. Brasília: [s.n.], 2012. Disponível em: <<https://ieeexplore.ieee.org/document/7083718>>. Acesso em: 01/06/2024.

BRASIL. MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E COMUNICAÇÃO. **3ª Comunicação nacional do Brasil à convenção-quadro das Nações Unidas sobre mudança do clima**. Brasília: [s.n.], 2016. Disponível em: <https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/comunicacoes-nacionais-do-brasil-a-unfccc/arquivos/mcti_tcn_3sumario_executivo_port.pdf>. Acesso em: 01/06/2024.

BRAUN, A.; OFFERMANN, E. Polarimetric information content of Sentinel-1 for land cover mapping: An experimental case study using quad-pol data synthesized from complementary repeat-pass acquisitions. **Frontiers in Remote Sensing**, [s.l.], v.3, 28 set., 2022. Disponível em: <<https://doi.org/10.3389/frsen.2022.905713>>. Acesso em: 01/06/2024.

BREIMAN, L. Random Forests. **Machine Learning**, [s.l.], v.45, n.1, p.5–32, out., 2001. Disponível em: <<https://doi.org/10.1023/A:1010933404324>>. Acesso em: 01/06/2024.

BREUNIG, M.M. et al. LOF: identifying density-based local outliers. In: Proceedings of the 2000 ACM SIGMOD international conference on Management of data, 2000, New York. **Anais...** [s.l.]: Association for Computing Machinery, 2000, p.93-104. Disponível em: <<https://dl.acm.org/doi/10.1145/342009.335388>>. Acesso em: 23/04/2024.

BROWN, M.B.; FORSYTHE, A.B. Robust Tests for the Equality of Variances. **Journal of the American Statistical Association**, [s.l.], v.69, n.346, p.364–367, 1974. Disponível em: <<https://doi.org/10.2307/2285659>>. Acesso em: 01/06/2024.

BUCKLEY, J.R.; SMITH, A.M. Monitoring grasslands with radarsat 2 quad-pol imagery. In: 2010 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 30, 2010, Honolulu. **Anais...** [s.l.]: IEEE, 2010, p.3090-3093. Disponível em: <<https://doi.org/10.1109/IGARSS.2010.5652367>>. Acesso em: 27 fev. 2024

BUHVALD, A. et al. Grassland Use Intensity Classification Using Intra-Annual Sentinel-1 and -2 Time Series and Environmental Variables. **Remote Sensing**, [s.l.], v.14, n.14, p.3387, jan., 2022. Disponível em: <<https://doi.org/10.3390/rs14143387>>. Acesso em: 01/06/2024.

BUSSINGUER, J. et al. Understanding the Spatio-Temporal Behavior of Sentinel-1 SAR Vegetation Indices Over the Brazilian Savanna. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.62, p.1–18, 2024. Disponível em: <<https://doi.org/10.1109/TGRS.2024.3381468>>. Acesso em: 01/06/2024.

BUSTAMANTE, M.M.C.; NOBRE, C.A.; SMERALDI, R.; AGUIAR, A.P.D; BARIONI, L.G.; FERREIRA, L.G.; LONGO, K; MAY, P.; PINTO, A.S; OMETTO, J.P.H.B. Estimating greenhouse gas emissions from cattle raising in Brazil. **Climatic change**, [s.l.], v.115, n.3-4, p.559–577, 2012. Disponível em: <<https://doi.org/10.1007/s10584-012-0443-3>>. Acesso em: 01/06/2024.

CABALLERO, C.B. et al. Transformation of Brazil's biomes: The dynamics and fate of agriculture and pasture expansion into native vegetation. **Science of The Total Environment**, [s.l.], v.896, p.166323, 20 out., 2023. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2023.166323>>. Acesso em: 01/06/2024.

CAMPOS-TABERNER, M. et al. A Copernicus Sentinel-1 and Sentinel-2 Classification Framework for the 2020+ European Common Agricultural Policy: A Case Study in València (Spain). **Agronomy**, [s.l.], v.9, n.9, p.556, set., 2019. Disponível em: <<https://doi.org/10.3390/agronomy9090556>>. Acesso em: 01/06/2024.

CANOZZI, M.E.A. et al. Typology of beef production systems according to bioeconomic efficiency in the south of Brazil. **Ciência Rural**, [s.l.], v.49, p.e20190030, set., 2019. Disponível em: <<https://doi.org/10.1590/0103-8478cr20190030>>. Acesso em: 01/06/2024.

CANTARELLA, H. et al. Ensaio de Proficiência IAC para laboratórios de solo para fins agrícolas. 82p. **Relatório Técnico** - Instituto Agrônomo de Campinas, Campinas, 15 fev. 2022. Disponível em: <https://lab.iac.sp.gov.br/Publicacao/ep_iac_relatorio_2021_2022.pdf>. Acesso em 01/06/2024.

CHAMEN, W.C.T. et al. Mitigating arable soil compaction: A review and analysis of available cost and benefit data. **Soil and Tillage Research**, Soil Structure and its Functions in Ecosystems: Phase matter & Scale matter, [s.l.], v.146, p.10–25, mar., 2015. Disponível em: <<https://doi.org/10.1016/j.still.2014.09.011>>. Acesso em: 01/06/2024.

CHARBONNEAU, F.J. et al. Compact polarimetry overview and applications assessment. **Canadian Journal of Remote Sensing**, [s.l.], v.36, n.sup2, p.S298–S315, jan., 2010. Disponível em: <<https://doi.org/10.5589/m10-062>>. Acesso em: 01/06/2024.

CHEN, B. et al. Ground and Top of Canopy Extraction From Photon-Counting LiDAR Data Using Local Outlier Factor With Ellipse Searching Area. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.16, n.9, p.1447–1451, set., 2019. Disponível em: <<https://doi.org/10.1109/LGRS.2019.2899011>>. Acesso em: 01/06/2024.

CHEN, M.; GRAEDEL, T.E. A half-century of global phosphorus flows, stocks, production, consumption, recycling, and environmental impacts. **Global Environmental Change**, [s.l.], v.36, p.139–152, jan., 2016. Disponível em: <<https://doi.org/10.1016/j.gloenvcha.2015.12.005>>. Acesso em: 01/06/2024.

CHEN, Q. et al. Superpixel-Based Cropland Classification of SAR Image With Statistical Texture and Polarization Features. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.19, p.1–5, 2022. Disponível em: <<https://doi.org/10.1109/LGRS.2021.3139103>>. Acesso em: 01/06/2024.

CHEN, Y. et al. Estimating Pasture Biomass Using Sentinel-2 Imagery and Machine Learning. **Remote Sensing**, [s.l.], v.13, n.4, p.603, jan., 2021. Disponível em: <<https://doi.org/10.3390/rs13040603>>. Acesso em: 01/06/2024.

CHOWDHURY, K.; CHAUDHURI, D.; PAL, A. K. An entropy-based initialization method of K-means clustering on the optimal number of clusters. **Neural Computing and Applications**, [s.l.], v.33, n.12, p.6965–6982, jun., 2021. Disponível em: <<https://doi.org/10.1007/s00521-020-05471-9>>. Acesso em: 01/06/2024.

CLEVELAND, R.B.; CLEVELAND, W.S.; McRAE, J.E.; TERPENNING, I., 1990. STL: A seasonal-trend decomposition. **Journal of Official Statistics**, Stockholm, v.6, n.1, p.3–73, mar., 1990. Disponível em: <<https://www.proquest.com/docview/1266805989/abstract/95A28F166D404053PQ/1>>. Acesso em: 01/06/2024.

CLOUDE, S.R.; POTTIER, E. An entropy based classification scheme for land applications of polarimetric SAR. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.35, n.1, p.68–78, jan., 1997. Disponível em: <<https://doi.org/10.1109/36.551935>>. Acesso em: 01/06/2024.

CONANT, R.T. et al. Grassland management impacts on soil carbon stocks: a new synthesis. **Ecological Applications**, [s.l.], v.27, n.2, p.662–668, 2017. Disponível em: <<https://doi.org/10.1002/eap.1473>>. Acesso em: 01/06/2024.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine Learning**, [s.l.], v.20, n.3, p.273–297, set., 1995. Disponível em: <<https://doi.org/10.1007/BF00994018>>. Acesso em: 01/06/2024.

CRABBE, R.A.; LAMB, D.W.; EDWARDS, C. Investigating the potential of Sentinel-1 to detect varying spatial heterogeneity in pasture cover in grasslands. **International Journal of Remote Sensing**, [s.l.], v.42, n.1, p.274–285, jan., 2021. Disponível em: <<https://doi.org/10.1080/01431161.2020.1812129>>. Acesso em: 01/06/2024.

CRACKNELL, M.J.; READING, A.M. Geological mapping using remote sensing data: A comparison of five machine learning algorithms, their response to variations in the spatial distribution of training data and the use of explicit spatial information. **Computers & Geosciences**, [s.l.], v.63, p.22–33, fev., 2014. Disponível em: <<https://doi.org/10.1016/j.cageo.2013.10.008>>. Acesso em: 01/06/2024.

DEBLITZ, C. Beef and sheep report 2012: understanding agriculture worldwide. 23p. **Relatório técnico** - Agri benchmark: Braunschweig, 2012. Disponível em: <<http://www.agribenchmark.org/fileadmin/Dateiablage/B-Beef-and-Sheep/Reports-Abstracts/Beef-and-Sheep-Report-extract-2012.pdf>>. Acesso em: 16/07/2024.

DAHMARDEH, M.; HODIANI, A. Assessment of soil elements in intercropping based on mathematical modelling. **Computers and Electronics in Agriculture**, [s.l.], v.122, p.218–224, mar., 2016. Disponível em: <<https://doi.org/10.1016/j.compag.2016.01.036>>. Acesso em: 01/06/2024.

DE ROSA, D. et al. Predicting pasture biomass using a statistical model and machine learning algorithm implemented with remotely sensed imagery. **Computers and Electronics in Agriculture**, [s.l.], v.180, p.105880, jan., 2021. Disponível em: <<https://doi.org/10.1016/j.compag.2020.105880>>. Acesso em: 01/06/2024.

DELABY, L. et al. Pasture-Based Dairy Systems in Temperate Lowlands: Challenges and Opportunities for the Future. **Frontiers in Sustainable Food Systems**, [s.l.], v.4, 2020. Disponível em: <<https://doi.org/10.3389/fsufs.2020.543587>>. Acesso em: 01/06/2024.

DIAS, H.B.; SENTELHAS, P.C. Assessing the performance of two gridded weather data for sugarcane crop simulations with a process-based model in Center-South Brazil. **International Journal of Biometeorology**, [s.l.], v.65, n.11, p.1881–1893, nov., 2021. Disponível em: <<https://doi.org/10.1007/s00484-021-02145-6>>. Acesso em: 01/06/2024.

DIAS-FILHO, M.B. Produção de Bovinos a Pasto na Fronteira Agrícola. 32p. **Relatório Técnico** – Embrapa Amazônia Oriental, Empresa Brasileira de Pesquisa Agropecuária, Belém, 2010. Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/883920>>. Acesso em: 01/06/2024.

DIAS-FILHO, M.B. Diagnóstico das pastagens no Brasil. 33p. **Relatório técnico** – Embrapa Amazônia Oriental, Empresa Brasileira de Pesquisa Agropecuária, Belém, 2014. Disponível em: <<https://www.embrapa.br/en/busca-de-publicacoes/-/publicacao/986147/diagnostico-das-pastagens-no-brasil>>. Acesso em: 01/06/2024.

DIAS-FILHO, M.B. **Degradação de pastagens**: processos, causas e estratégias de recuperação. 4ed. Belém: MBDF, 2015.

DOMENECH, M.B. et al. Prediction of topsoil properties at field-scale by using C-band SAR data. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v.93, p.102197, dez., 2020. Disponível em: <<https://doi.org/10.1016/j.jag.2020.102197>>. Acesso em: 01/06/2024.

DOU, Y. et al. Mapping crop producer perceptions: The role of global drivers on local agricultural land use in Brazil. **Land Use Policy**, [s.l.], v.133, p.106862, out., 2023. Disponível em: <<https://doi.org/10.1016/j.landusepol.2023.106862>>. Acesso em: 01/06/2024.

DUARTE, Y.C.N.; SENTELHAS, P.C. NASA/POWER and DailyGridded weather datasets—how good they are for estimating maize yields in Brazil? **International Journal of Biometeorology**, [s.l.], v.64, n.3, p.319–329, mar., 2020. Disponível em: <<https://doi.org/10.1007/s00484-019-01810-1>>. Acesso em: 01/06/2024.

EKLUNDH, L.; JÖNSSON, P. TIMESAT for Processing Time-Series Data from Satellite Sensors for Land Surface Monitoring. Em: BAN, Y. Multitemporal Remote Sensing: Methods and Applications. Remote Sensing and Digital Image Processing. Cham: Springer International Publishing, 2016. p.177–194. Disponível em: <https://doi.org/10.1007/978-3-319-47037-5_9>. Acesso em: 01/06/2024.

ENESI, R.O. et al. Liming remediates soil acidity and improves crop yield and profitability - a meta-analysis. **Frontiers in Agronomy**, [s.l.], v.5, jun., 2023. Disponível em: <<https://doi.org/10.3389/fagro.2023.1194896>>. Acesso em: 01/06/2024.

FAY, P.A. et al. Grassland productivity limited by multiple nutrients. **Nature Plants**, [s.l.], v.1, n.7, p.1–5, jul., 2015. Disponível em: <<https://doi.org/10.1038/nplants.2015.80>>. Acesso em: 01/06/2024.

FELTRAN-BARBIERI, R.; FÉRES, J.G. Degraded pastures in Brazil: improving livestock production and forest restoration. **Royal Society Open Science**, [s.l.], v.8, n.7, p.201854, jul., 2021. Disponível em: <<https://doi.org/10.1098/rsos.201854>>. Acesso em: 01/06/2024.

FERRAZ, J.B.S.; FELÍCIO, P.E. Production systems – An example from Brazil. **Meat Science**, Special Issue: 55th International Congress of Meat Science and Technology (55th ICoMST), 16-21 August 2009, Copenhagen, Denmark. [s.l.], v.84, n.2, p.238–243, 1 fev. 2010. Disponível em: <<https://doi.org/10.1016/j.meatsci.2009.06.006>>. Acesso em: 01/06/2024.

FOLEY, J.A. et al. Solutions for a cultivated planet. **Nature**, [s.l.], v.478, n.7369, p.337–342, out., 2011. Disponível em: <<https://doi.org/10.1038/nature10452>>. Acesso em: 01/06/2024.

FONSECA, L.M.G. et al. Pattern Recognition and Remote Sensing techniques applied to Land Use and Land Cover mapping in the Brazilian Savannah. **Pattern Recognition Letters**, [s.l.], v.148, p.54–60, ago., 2021. Disponível em: <<https://doi.org/10.1016/j.patrec.2021.04.028>>. Acesso em: 01/06/2024.

FRÄNTI, P.; SIERANOJA, S. K-means properties on six clustering benchmark datasets. **Applied Intelligence**, [s.l.], v.48, n.12, p.4743–4759, dez., 2018. Disponível em: <<https://doi.org/10.1007/s10489-018-1238-7>>. Acesso em: 01/06/2024.

FU, W. et al. Outlier identification of soil phosphorus and its implication for spatial structure modeling. **Precision Agriculture**, [s.l.], v.17, n.2, p.121–135, abr., 2016. Disponível em: <<https://doi.org/10.1007/s11119-015-9411-z>>. Acesso em: 01/06/2024.

GARCIA, E. et al. Costs, Benefits and Challenges of Sustainable Livestock Intensification in a Major Deforestation Frontier in the Brazilian Amazon. **Sustainability**, [s.l.], v.9, n.1, p.158, jan., 2017. Disponível em: <<https://doi.org/10.3390/su9010158>>. Acesso em: 01/06/2024.

GATIBONI, L.C.; KAMINSKI, J.; SANTOS, D.R. Modificações nas formas de fósforo do solo após extrações sucessivas com Mehlich-1, Mehlich-3 e resina trocadora de ânions. **Revista Brasileira de Ciência do Solo**, [s.l.], v.29, p.363–371, jun., 2005. Disponível em: <<https://doi.org/10.1590/S0100-06832005000300006>>. Acesso em: 01/06/2024.

GIANETTI, G.W.; FERREIRA FILHO, J.B.S. Pasture recovery, emissions, and the Brazilian Paris agreement commitments. **Land Use Policy**, [s.l.], v.141, p.107118, jun., 2024. Disponível em: <<https://doi.org/10.1016/j.landusepol.2024.107118>>. Acesso em: 01/06/2024.

GIERSZEWSKA, M.; BEREZOWSKI, T. On the Role of Polarimetric Decomposition and Speckle Filtering Methods for C-Band SAR Wetland Classification Purposes. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.15, p.2845–2860, 2022. Disponível em: <<https://doi.org/10.1109/JSTARS.2022.3162641>>. Acesso em: 01/06/2024.

GOLICZ, K. et al. Adapting smartphone app used in water testing, for soil nutrient analysis. **Computers and Electronics in Agriculture**, [s.l.], v.175, p.105532, ago., 2020. Disponível em: <<https://doi.org/10.1016/j.compag.2020.105532>>. Acesso em: 01/06/2024.

GREENWOOD, P.L. Review: An overview of beef production from pasture and feedlot globally, as demand for beef and the need for sustainable practices increase. **Animal**, Sustainable livestock systems for high-producing animals, [s.l.], v. 15, p. 100295, dec., 2021. Disponível em: <<https://doi.org/10.1016/j.animal.2021.100295>>. Acesso em: 01/06/2024.

GRIFFITHS, P. et al. Towards national-scale characterization of grassland use intensity from integrated Sentinel-2 and Landsat time series. **Remote Sensing of Environment**, Time Series Analysis with High Spatial Resolution Imagery. [s.l.], v.238, p.111124, mar., 2020. Disponível em: <<https://doi.org/10.1016/j.rse.2019.03.017>>. Acesso em: 01/06/2024.

GROENIGEN, J. W. et al. Sequestering Soil Organic Carbon: A Nitrogen Dilemma. **Environmental Science & Technology**, [s.l.], v.51, n.9, p.4738–4739, mai., 2017. Disponível em: <<https://doi.org/10.1021/acs.est.7b01427>>. Acesso em: 01/06/2024.

GROPPO, J.D. et al. Changes in soil carbon, nitrogen, and phosphorus due to land-use changes in Brazil. **Biogeosciences**, [s.l.], v.12, n.15, p.4765–4780, 7 ago. 2015. Disponível em: <<https://doi.org/10.5194/bg-12-4765-2015>>. Acesso em: 01/06/2024.

GUERRERO, A.; DE NEVE, S.; MOUAZEN, A. M. **Current sensor technologies for in situ and on-line measurement of soil nitrogen for variable rate fertilization**: A review. Em: SPARKS, D.L. *Advances in Agronomy*. [s.l.]: Academic Press, 2021. v.168, p.1-38. Disponível em: <<https://doi.org/10.1016/bs.agron.2021.02.001>>. Acesso em: 01/06/2024.

HAIR JR., J.F. et al. **Análise Multivariada de Dados**. 6ed. Porto Alegre: Bookman, 2009. Disponível em: <<https://digitalcommons.kennesaw.edu/facpubs/2925>>. Acesso em: 01/06/2024.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: concepts and techniques**. 3ed. Waltham: Elsevier, 2012. Disponível em: <<https://doi.org/10.1016/C2009-0-61819-5>>. Acesso em: 01/06/2024.

HANDCOCK, R.N.; DONALD, G.E.; GHERARDI, S.G. Three regionalised analyses of a time-series of annual pasture production for southwest Western Australia. In: IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 27, 2007, Barcelona. **Anais...** [s.l.]: IEEE, 2007. p.801–804. Disponível em: <<https://doi.org/10.1109/IGARSS.2007.4422918>>. Acesso em: 01/06/2024.

HÄNSCH, R.; JAGDHUBER, T.; FERSCH, B. Soil-Permittivity Estimation Under Grassland Using Machine-Learning and Polarimetric Decomposition Techniques. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.59, n.4, p.2877–2887, abr., 2021. Disponível em: <<https://doi.org/10.1109/TGRS.2020.3010104>>. Acesso em: 01/06/2024.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. Support Vector Machines and Flexible Discriminants. Em: HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. 2ed. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, NY: Springer, 2009. p.417–458. Disponível em: <https://doi.org/10.1007/978-0-387-84858-7_12>. Acesso em: 01/06/2024.

HELFER, G.A. et al. A computational model for soil fertility prediction in ubiquitous agriculture. **Computers and Electronics in Agriculture**, v.175, p.105602, ago., 2020. Disponível em: <<https://doi.org/10.1016/j.compag.2020.105602>>. Acesso em: 01/06/2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo agropecuário: Resultados definitivos**. Brasília: IBGE, 2017. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9827-censo-agropecuario.html>>. Acesso em: 09/04/2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Pecuária Municipal**. Brasília: IBGE, 2024. Disponível em: <<https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2022>>. Acesso em: 09/04/2024.

JAFARZADEH, H. et al. Enhanced Crop Discrimination and Monitoring Using Compact-Polarimetric SAR Signature Analysis From RADARSAT Constellation Mission. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.17, p.6308–6327, 2024. Disponível em: <<https://doi.org/10.1109/JSTARS.2024.3366883>>. Acesso em: 01/06/2024.

JAKIMOW, B.; GRIFFITHS, P.; LINDEN, S.; HOSTERT, P. Mapping pasture management in the Brazilian Amazon from dense Landsat time series. **Remote Sensing of Environment**, [s.l.], v.205, p.453–468, 2018. Disponível em: <<https://doi.org/10.1016/j.rse.2017.10.009>>. Acesso em: 01/06/2024.

JAMES, G. et al. **An Introduction to Statistical Learning: with Applications in Python**. Cham: Springer International Publishing, 2023. Disponível em: <<https://doi.org/10.1007/978-3-031-38747-0>>. Acesso em: 01/06/2024.

JANK, L. et al. The value of improved pastures to Brazilian beef production. **Crop and Pasture Science**, [s.l.], v.65, n.11, p.1132–1137, mar., 2014. Disponível em: <<https://doi.org/10.1071/CP13319>>. Acesso em: 01/06/2024.

JIANG, N. et al. NDVI Reconstruction by Synthesizing Optical and Synthetic Aperture Radar Images Based on CNN. SAR in Big Data Era (BIGSAR DATA). In: 2023 SAR IN BIG DATA ERA (BIGSAR DATA), 2023, Beijing. **Anais...** [s.l.]: IEEE, 2023, p.1-4. Disponível em: <<https://doi.org/10.1109/BIGSAR DATA59007.2023.10295019>>. Acesso em: 20 abr. 2024

JIAO, X. et al. Integrating Sentinel-1 SAR and Sentinel-2 optical imagery with a crop structure dynamics model to track crop condition. **International Journal of Remote Sensing**, [s.l.], v.43, n.17, p.6509–6537, set., 2022. Disponível em: <<https://doi.org/10.1080/01431161.2022.2142077>>. Acesso em: 01/06/2024.

JIN, Y.; XU, F. **Polarimetric Scattering and SAR Information Retrieval**. Singapore: John Wiley & Sons, 2013. Disponível em: <<https://doi.org/10.1002/9781118188149>>. Acesso em: 01/06/2024.

JONES, P.G.; THORNTON, P.K. Croppers to livestock keepers: livelihood transitions to 2050 in Africa due to climate change. **Environmental Science & Policy**, Special Issue: Food Security and Environmental Change, [s.l.], v.12, n.4, p.427–437, jun., 2009. Disponível em: <<https://doi.org/10.1016/j.envsci.2008.08.006>>. Acesso em: 01/06/2024.

JONSSON, P.; EKLUNDH, L. Seasonality extraction by function fitting to time-series of satellite sensor data. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.40, n.8, p.1824–1832, ago., 2002. Disponível em: <<https://doi.org/10.1109/TGRS.2002.802519>>. Acesso em: 01/06/2024.

JÖNSSON, P.; EKLUNDH, L. TIMESAT—a program for analyzing time-series of satellite sensor data. **Computers & Geosciences**, [s.l.], v.30, n.8, p.833–845, out., 2004. Disponível em: <<https://doi.org/10.1016/j.cageo.2004.05.006>>. Acesso em: 01/06/2024.

KALKHORAN, S.S. et al. Optimal lime rates for soil acidity mitigation: impacts of crop choice and nitrogen fertiliser in Western Australia. **Crop and Pasture Science**, [s.l.], v.71, n.1, p.36–46, jan., 2020. Disponível em: <<https://doi.org/10.1071/CP19101>>. Acesso em: 01/06/2024.

KANG, M.S.; BAEK, J.M. Efficient SAR Imaging Integrated With Autofocus via Compressive Sensing. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.19, p.1–5, 2022. Disponível em: <<https://doi.org/10.1109/LGRS.2022.3213251>>. Acesso em: 01/06/2024.

KORDI, F.; YOUSEFI, H. Crop classification based on phenology information by using time series of optical and synthetic-aperture radar images. **Remote Sensing Applications: Society and Environment**, [s.l.], v.27, p.100812, ago., 2022. Disponível em: <<https://doi.org/10.1016/j.rsase.2022.100812>>. Acesso em: 01/06/2024.

KROUPNIK, G. et al. RADARSAT Constellation Mission Overview and Status. In: 2021 IEEE Radar Conference (RadarConf21), 2021, Atlanta. **Anais...** [s.l.]: IEEE, 2021, p.1-5. Disponível em: <<https://doi.org/10.1109/RadarConf2147009.2021.9455298>>. Acesso em: 28 mar. 2024.

LAHSEN, M.; BUSTAMANTE, M.M.C.; DALLA-NORA, E.L. Undervaluing and Overexploiting the Brazilian Cerrado at Our Peril. **Environment: Science and Policy for Sustainable Development**, [s.l.], v.58, n.6, p.4–15, nov., 2016. Disponível em: <<https://doi.org/10.1080/00139157.2016.1229537>>. Acesso em: 01/06/2024.

LAPOLA, D.M. et al. Pervasive transition of the Brazilian land-use system. **Nature Climate Change**, [s.l.], v.4, n.1, p.27–35, jan., 2014. Disponível em: <<https://doi.org/10.1038/nclimate2056>>. Acesso em: 01/06/2024.

LASSALETTA, L. et al. Nitrogen use in the global food system: past trends and future trajectories of agronomic performance, pollution, trade, and dietary demand. **Environmental Research Letters**, [s.l.], v.11, n.9, p.095007, set., 2016. Disponível em: <<https://doi.org/10.1088/1748-9326/11/9/095007>>. Acesso em: 01/06/2024.

LATAWIEC, A. E. et al. Improving land management in Brazil: A perspective from producers. **Agriculture, Ecosystems & Environment**, [s.l.], v.240, p.276–286, mar., 2017. Disponível em: <<https://doi.org/10.1016/j.agee.2017.01.043>>. Acesso em: 01/06/2024.

LEE, J.S. et al. Improved Sigma Filter for Speckle Filtering of SAR Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.47, n.1, p.202–213, jan., 2009. Disponível em: <<https://doi.org/10.1109/TGRS.2008.2002881>>. Acesso em: 01/06/2024.

LEE, J.S.; POTTIER, E. **Polarimetric Radar Imaging: From Basics to Applications**. Boca Raton: CRC Press, 2017.

LEVENE, H. **Robust tests for equality of variances**. Em: Hotelling, I.O. et al. Contributions to Probability and Statistics: Essays in Honor of Harold, Stanford: Stanford University Press, 1960. p.278-292.

LI, C. et al. Deep Soil C, N, and P Stocks and Stoichiometry in Response to Land Use Patterns in the Loess Hilly Region of China. **PLOS ONE**, [s.l.], v.11, n.7, p.e0159075, jul., 2016. Disponível em: <<https://doi.org/10.1371/journal.pone.0159075>>. Acesso em: 01/06/2024.

LIMA, A.F.L. et al. Soil chemical attributes in areas under conversion from forest to pasture in southern Brazilian Amazon. **Scientific Reports**, [s.l.], v.12, n.1, p.1–21, dez., 2022. Disponível em: <<https://doi.org/10.1038/s41598-022-25406-9>>. Acesso em: 01/06/2024.

LIMA, R.F. et al. Climate change in Brazil: future scenarios classified by Thornthwaite (1948). **Theoretical and Applied Climatology**, [s.l.], v.146, n.3, p.1367–1386, nov., 2021. Disponível em: <<https://doi.org/10.1007/s00704-021-03803-w>>. Acesso em: 01/06/2024.

LU, n. et al. Estimation of Nitrogen Nutrition Status in Winter Wheat From Unmanned Aerial Vehicle Based Multi-Angular Multispectral Imagery. **Frontiers in Plant Science**, [s.l.], v.10, dez., 2019. Disponível em: <<https://doi.org/10.3389/fpls.2019.01601>>. Acesso em: 01/06/2024.

LUZ, F.B. et al. Monitoring soil quality changes in diversified agricultural cropping systems by the Soil Management Assessment Framework (SMAF) in southern Brazil. **Agriculture, Ecosystems & Environment**, [s.l.], v.281, p.100–110, set., 2019. Disponível em: <<https://doi.org/10.1016/j.agee.2019.05.006>>. Acesso em: 01/06/2024.

MA, W. et al. Change detection in SAR images based on matrix factorisation and a Bayes classifier. **International Journal of Remote Sensing**, [s.l.], v.40, n.3, p.1066–1091, fev., 2019. Disponível em: <<https://doi.org/10.1080/01431161.2018.1524172>>. Acesso em: 01/06/2024.

MA, X. et al. A Review on Recent Developments in Fully Polarimetric SAR Image Despeckling. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote**

Sensing, [s.l.], v.11, n.3, p.743–758, mar., 2018. Disponível em: <<https://doi.org/10.1109/JSTARS.2017.2768059>>. Acesso em: 01/06/2024.

MA, Y. et al. Evaluating the Ability of the Sentinel-1 Cross-Polarization Ratio to Detect Spring Maize Phenology Using Adaptive Dynamic Threshold. **Remote Sensing**, [s.l.], v.16, n.5, p.826, jan., 2024. Disponível em: <<https://doi.org/10.3390/rs16050826>>. Acesso em: 01/06/2024.

MACIEL, A.M. et al. Identifying Land Use Change Trajectories in Brazil's Agricultural Frontier. **Land**, [s.l.], v.9, n.12, p.506, dez. 2020. Disponível em: <<https://doi.org/10.3390/land9120506>>. Acesso em: 01/06/2024.

MAIA, A.G.; MIYAMOTO, B.C.B.; GARCIA, J.R. Climate Change and Agriculture: Do Environmental Preservation and Ecosystem Services Matter? **Ecological Economics**, [s.l.], v.152, p.27–39, out., 2018. Disponível em: <<https://doi.org/10.1016/j.ecolecon.2018.05.013>>. Acesso em: 01/06/2024.

MAIONE, C.; NELSON, D.R.; BARBOSA, R.M. Research on social data by means of cluster analysis. **Applied Computing and Informatics**, [s.l.], v.15, n.2, p.153–162, jul., 2019. Disponível em: <<https://doi.org/10.1016/j.aci.2018.02.003>>. Acesso em: 01/06/2024.

MANLY, B.F.J., ALBERTO, J.A.N. **Multivariate Statistical Methods: A Primer**. 4ed. New York: CRC, 2016. Disponível em: <<https://doi.org/10.1201/9781315382135>>. Acesso em: 01/06/2024.

MANZATTO, C.V.; PEREIRA, S.E.M.; PEDREIRA, B.C. Zoneamento do risco de ocorrência da síndrome da morte do capim-marandu do Estado do Mato Grosso. 29p. **Relatório Técnico** – Embrapa Meio Ambiente, Empresa Brasileira de Pesquisa Agropecuária, Jaguariúna, 2017.

MARTHA Jr., G.B.; ALVES, E.; CONTINI, E. Land-saving approaches and beef production growth in Brazil. **Agricultural Systems**, [s.l.], v.110, p.173–177, 2012. Disponível em: <<https://doi.org/10.1016/j.agsy.2012.03.001>>. Acesso em: 01/06/2024.

MASCOLO, L.; CLOUDE, S.R.; LOPEZ-SANCHEZ, J.M. Model-Based Decomposition of Dual-Pol SAR Data: Application to Sentinel-1. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.60, p.1–19, 2022. Disponível em: <<https://doi.org/10.1109/TGRS.2021.3137588>>. Acesso em: 01/06/2024.

MASON, E.; CORNU, S.; CHENU, C. Stakeholders' point of view on access to soil knowledge in France. What are the opportunities for further improvement? **Geoderma Regional**, [s.l.], v.35, p.e00716, dez. 2023. Disponível em: <<https://doi.org/10.1016/j.geodrs.2023.e00716>>. Acesso em: 01/06/2024.

MASSRUHÁ, S.M.F.S., LEITE, M.A.A., OLIVEIRA, S.R.M., et al., 2020. **Agricultura digital: pesquisa, desenvolvimento e inovação nas cadeias produtivas**. Brasília: Empresa Brasileira de Pesquisa Agropecuária, 2020. Disponível em: <<https://www.embrapa.br/en/busca-de-publicacoes/-/publicacao/1126213/agricultura-digital-pesquisa-desenvolvimento-e-inovacao-nas-cadeias-produtivas>>. Acesso em: 01/06/2024.

MATTILA, T.J.; RAJALA, J. Do different agronomic soil tests identify similar nutrient deficiencies? **Soil Use and Management**, [s.l.], v.38, n.1, p.635–648, 2022. Disponível em: <<https://doi.org/10.1111/sum.12738>>. Acesso em: 01/06/2024.

McINNES, W.S.; SMITH, B.; MCDERMID, G.J. Discriminating native and Nonnative Grasses in the Dry Mixedgrass Prairie with MODIS NDVI Time Series. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.8, n.4, p.1395–1403, 2015. Disponível em: <<https://doi.org/10.1109/JSTARS.2015.2416713>>. Acesso em: 01/06/2024.

McNAIRN, H.; BRISCO, B. The application of C-band polarimetric SAR for agriculture: a review. **Canadian Journal of Remote Sensing**, [s.l.], v.30, n.3, p.525–542, jan., 2004. Disponível em: <<https://doi.org/10.5589/m03-069>>. Acesso em: 01/06/2024.

MEAT & LIVESTOCK AUSTRALIA. GLOBAL SNAPSHOT | BEEF. 10p. Relatório Técnico – MEAT & LIVESTOCK AUSTRALIA, [s.l.], 2020. Disponível em: <<https://www.mla.com.au/globalassets/mla-corporate/prices--markets/documents/os-markets/red-meat-market-snapshots/2020/global-beef-snapshot-jan2020.pdf>>. Acesso em: 4 nov. 2023.

MEDASANI, S.; REDDY, G.U. Speckle Filtering and its Influence on the Decomposition and Classification of Hybrid Polarimetric Data of RISAT-1. **Remote Sensing Applications: Society and Environment**, [s.l.], v.10, p.1–6, abr., 2018. Disponível em: <<https://doi.org/10.1016/j.rsase.2018.02.002>>. Acesso em: 01/06/2024.

MEHLICH, A. Mehlich 3 soil test extractant: A modification of Mehlich 2 extractant. **Communications in Soil Science and Plant Analysis**, [s.l.], v.15, n.12, p.1409–1416, 1 dez. 1984. Disponível em: <<https://doi.org/10.1080/00103628409367568>>. Acesso em: 01/06/2024.

MIRZAEI, F. et al. Soil textural class modeling using digital soil mapping approaches: Effect of resampling strategies on imbalanced dataset predictions. **Geoderma Regional**, [s.l.], v.38, p.e00821, 1 set. 2024. Disponível em: <<https://doi.org/10.1016/j.geodrs.2024.e00821>>. Acesso em: 01/06/2024.

MOODY, P.W. et al. A decision support framework for identifying soil constraints to the agricultural productivity of tropical upland soils. **Soil Use and Management**, [s.l.], v.24, n.2, p.148–155, 2008. Disponível em: <<https://doi.org/10.1111/j.1475-2743.2008.00145.x>>. Acesso em: 01/06/2024.

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v.66, n.3, p.247–259, mai., 2011. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2010.11.001>>. Acesso em: 01/06/2024.

MURO, J. et al. Predicting plant biomass and species richness in temperate grasslands across regions, time, and land management with remote sensing and deep learning. **Remote Sensing of Environment**, [s.l.], v.282, p.113262, dez., 2022. Disponível em: <<https://doi.org/10.1016/j.rse.2022.113262>>. Acesso em: 01/06/2024.

MURTY, D. et al. Does conversion of forest to agricultural land change soil carbon and nitrogen? a review of the literature. **Global Change Biology**, [s.l.], v.8, n.2, p.105–123, 2002. Disponível em: <<https://doi.org/10.1046/j.1354-1013.2001.00459.x>>. Acesso em: 01/06/2024.

NAJEM, S. et al. Detection and Mapping of Cover Crops Using Sentinel-1 SAR Remote Sensing Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote**

Sensing, [s.l.], v.17, p.1446–1461, 2024. Disponível em: <<https://doi.org/10.1109/JSTARS.2023.3337989>>. Acesso em: 01/06/2024.

NETTLE, R. et al. Factors associated with farmers' use of fee-for-service advisors in a privatized agricultural extension system. **Land Use Policy**, [s.l.], v.104, p.105360, mai., 2021. Disponível em: <<https://doi.org/10.1016/j.landusepol.2021.105360>>. Acesso em: 01/06/2024.

NEVES, M.C.R. et al. The Role of Cooperatives in Brazilian Agricultural Production. **Agriculture**, [s.l.], v.11, n.10, p.948, out., 2021. Disponível em: <<https://doi.org/10.3390/agriculture11100948>>. Acesso em: 01/06/2024.

NOWAK, B.; MICHAUD, A.; MARLIAC, G. Soil-climate factors have a greater influence on the presence of winter cover crops than regulatory constraints in France. **Agronomy for Sustainable Development**, [s.l.], v.42, n.2, p.28, abr., 2022. Disponível em: <<https://doi.org/10.1007/s13593-022-00770-y>>. Acesso em: 01/06/2024.

OCCELLI, M. et al. Traditional knowledge affects soil management ability of smallholder farmers in marginal areas. **Agronomy for Sustainable Development**, [s.l.], v.41, n.1, p.9, jan., 2021. Disponível em: <<https://doi.org/10.1007/s13593-020-00664-x>>. Acesso em: 01/06/2024.

OLIVEIRA, D.C. et al. Changes in soil carbon and soil carbon sequestration potential under different types of pasture management in Brazil. **Regional Environmental Change**, [s.l.], v.22, n.3, p.87, jun., 2022. Disponível em: <<https://doi.org/10.1007/s10113-022-01945-9>>. Acesso em: 01/06/2024.

OLIVEIRA, P.D.D. et al. Critical limits of the degree of compactness and soil penetration resistance for the soybean crop in N Brazil. **Journal of Plant Nutrition and Soil Science**, [s.l.], v.179, n.1, p.78–87, 2016. Disponível em: <<https://doi.org/10.1002/jpln.201400315>>. Acesso em: 01/06/2024.

OLIVEIRA, R.A. et al. Machine learning estimators for the quantity and quality of grass swards used for silage production using drone-based imaging spectrometry and photogrammetry. **Remote Sensing of Environment**, [s.l.], v.246, p.111830, set., 2020. Disponível em: <<https://doi.org/10.1016/j.rse.2020.111830>>. Acesso em: 01/06/2024.

OLOFSSON, P. et al. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, [s.l.], v.148, p.42–57, mai., 2014. Disponível em: <<https://doi.org/10.1016/j.rse.2014.02.015>>. Acesso em: 01/06/2024.

PANAGOS, P. et al. Soil priorities in the European Union. **Geoderma Regional**, [s.l.], v.29, p.e00510, jun., 2022. Disponível em: <<https://doi.org/10.1016/j.geodrs.2022.e00510>>. Acesso em: 01/06/2024.

PANAGOS, P. et al. Soil bulk density assessment in Europe. **Agriculture, Ecosystems & Environment**, [s.l.], v.364, p.108907, abr., 2024. Disponível em: <<https://doi.org/10.1016/j.agee.2024.108907>>. Acesso em: 01/06/2024.

PARENTE, L. et al. Monitoring the brazilian pasturelands: A new mapping approach based on the landsat 8 spectral and temporal domains. **International Journal of Applied Earth Observation and Geoinformation**, [s.l.], v.62, p.135–143, out., 2017. Disponível em: <<https://doi.org/10.1016/j.jag.2017.06.003>>. Acesso em: 01/06/2024.

PARENTE, L.; FERREIRA, L. Assessing the Spatial and Occupation Dynamics of the Brazilian Pasturelands Based on the Automated Classification of MODIS Images from 2000 to 2016. **Remote Sensing**, [s.l.], v.10, n.4, p.606, abr., 2018. Disponível em: <<https://doi.org/10.3390/rs10040606>>. Acesso em: 01/06/2024.

PAVÃO, Q.S. et al. Texture prediction of natural soils in the Brazilian Amazon through proximal sensors. **Geoderma Regional**, v.37, p.e00813, jun., 2024. Disponível em: <<https://doi.org/10.1016/j.geodrs.2024.e00813>>. Acesso em: 01/06/2024.

PEDREIRA, C.G.; TONATO, F.; LARA, M.A.S. **Forrageiras Brachiaria, Panicum e Cynodon**. Em: MONTEIRO, J.E.B.A. Agrometeorologia dos Cultivos: O fator meteorológico na produção agrícola. Brasília: Instituto Nacional de Meteorologia, 2009, p.427-447.

PEREIRA, O.J.R. et al. Assessing Pasture Degradation in the Brazilian Cerrado Based on the Analysis of MODIS NDVI Time-Series. **Remote Sensing**, [s.l.], v.10, n.11, p.1761, nov., 2018. Disponível em: <<https://doi.org/10.3390/rs10111761>>. Acesso em: 01/06/2024.

PEREIRA-FLORES, M.E. et al. Seasonal climate impact on Brazilian pasture (*Brachiaria brizantha* cv. Marandu): growth rate, CO₂ efflux, and irrigation strategies. **Theoretical and Applied Climatology**, [s.l.], v.151, n.1, p.651–666, jan., 2023. Disponível em: <<https://doi.org/10.1007/s00704-022-04295-y>>. Acesso em: 01/06/2024.

PEZZOPANE, J.R.M. et al. Simple agrometeorological models for estimating Guineagrass yield in Southeast Brazil. **International Journal of Biometeorology**, [s.l.], v.58, n.7, p.1479–1487, set., 2014. Disponível em: <<https://doi.org/10.1007/s00484-013-0751-y>>. Acesso em: 01/06/2024.

PHAM, V.; WEINDORF, D.C.; DANG, T. Soil profile analysis using interactive visualizations, machine learning, and deep learning. **Computers and Electronics in Agriculture**, [s.l.], v.191, p.106539, dez., 2021. Disponível em: <<https://doi.org/10.1016/j.compag.2021.106539>>. Acesso em: 01/06/2024.

PHELAN, L.; CHAPMAN, P. J.; ZIV, G. The emerging global agricultural soil carbon market: the case for reconciling farmers' expectations with the demands of the market. **Environmental Development**, [s.l.], v.49, p.100941, mar., 2024. Disponível em: <<https://doi.org/10.1016/j.envdev.2023.100941>>. Acesso em: 01/06/2024.

PIRES, M.V. et al. Nitrogen-Use Efficiency, Nitrous Oxide Emissions, and Cereal Production in Brazil: Current Trends and Forecasts. **PLOS ONE**, [s.l.], v.10, n.8, p.e0135234, ago., 2015. Disponível em: <<https://doi.org/10.1371/journal.pone.0135234>>. Acesso em: 01/06/2024.

PITTARELLO, M. et al. Environmental factors and management intensity affect in different ways plant diversity and pastoral value of alpine pastures. **Ecological Indicators**, [s.l.], v.115, p.106429, ago., 2020. Disponível em: <<https://doi.org/10.1016/j.ecolind.2020.106429>>. Acesso em: 01/06/2024.

PONTIUS Jr, R.G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, [s.l.], v.32, n.15, p.4407–4429, ago., 2011. Disponível em: <<https://doi.org/10.1080/01431161.2011.552923>>. Acesso em: 01/06/2024.

PONTIUS Jr., R.G. **Metrics That Make a Difference: How to Analyze Change and Error**. Cham: Springer International Publishing, 2022. Disponível em: <<https://doi.org/10.1007/978-3-030-70765-1>>. Acesso em: 01/06/2024.

PRASAD, P. et al. Evaluation and comparison of the earth observing sensors in land cover/land use studies using machine learning algorithms. **Ecological Informatics**, [s.l.], v.68, p.101522, 1 mai., 2022. Disponível em: <<https://doi.org/10.1016/j.ecoinf.2021.101522>>. Acesso em: 01/06/2024.

PRINCE, S.D. A model of regional primary production for use with coarse-resolution satellite data, **International Journal of Remote Sensing**, [s.l.], v.12, n.6, p.1313-1330, abr., 1991. Disponível em: <<https://doi.org/10.1080/01431169108929728>>. Acesso em: 01/06/2024.

PRUDENTE, V.H.R. et al. Multisensor approach to land use and land cover mapping in Brazilian Amazon. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v.189, p.95–109, jul., 2022. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2022.04.025>>. Acesso em: 01/06/2024.

PULLANAGARI, R.R. et al. The Use Of Optical Sensors To Estimate Pasture Quality. **International Journal on Smart Sensing and Intelligent Systems**, [s.l.], v.4, n.1, p.125–137, 31 dez., 2010. Disponível em: <<https://doi.org/10.21307/ijssis-2017-430>>. Acesso em: 01/06/2024.

RAAB, C. et al. Target-oriented habitat and wildlife management: estimating forage quantity and quality of semi-natural grasslands with Sentinel-1 and Sentinel-2 data. **Remote Sensing in Ecology and Conservation**, [s.l.], v.6, n.3, p.381–398, 2020. Disponível em: <<https://doi.org/10.1002/rse2.149>>. Acesso em: 01/06/2024.

RANEY, R.K. Dual-polarized SAR and Stokes parameters. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.3, n.3, p.317–319, jul., 2006. Disponível em: <<https://doi.org/10.1109/LGRS.2006.871746>>. Acesso em: 01/06/2024.

RANEY, R.K. Radar Polarimetry: Classical Versus Quad-Pol Methodologies. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.21, p.1–4, 2024. Disponível em: <<https://doi.org/10.1109/LGRS.2024.3352987>>. Acesso em: 01/06/2024.

REIS, J.C. et al. Assessing the economic viability of integrated crop–livestock systems in Mato Grosso, Brazil. **Renewable Agriculture and Food Systems**, [s.l.], v.35, n.6, p.631–642, dez., 2020. Disponível em: <<https://doi.org/10.1017/S1742170519000280>>. Acesso em: 01/06/2024.

REIS, J.C. et al. Integrated crop-livestock systems: A sustainable land-use alternative for food production in the Brazilian Cerrado and Amazon. **Journal of Cleaner Production**, [s.l.], v.283, p.124580, fev., 2021. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.124580>>. Acesso em: 01/06/2024.

REYES, J. et al. Improved estimation of nitrogen uptake in grasslands using the nitrogen dilution curve. **Agronomy for Sustainable Development**, [s.l.], v.35, n.4, p.1561–1570, out., 2015. Disponível em: <<https://doi.org/10.1007/s13593-015-0321-2>>. Acesso em: 01/06/2024.

RICHARDS, J.A. Analysis of remotely sensed data: the formative decades and the future. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.43, n.3, p.422–432, mar., 2005. Disponível em: <<https://doi.org/10.1109/TGRS.2004.837326>>. Acesso em: 01/06/2024.

RICHARDS, J.A. Remote Sensing with Imaging Radar. Berlin, Heidelberg: Springer-Verlag, 2009. Disponível em: <<https://doi.org/10.1007/978-3-642-02020-9>>. Acesso em: 01/06/2024.

RICHARDSON, A.E. et al. The inorganic nutrient cost of building soil carbon. **Carbon Management**, [s.l.], v.5, n.3, p.265–268, mai., 2014. Disponível em: <<https://doi.org/10.1080/17583004.2014.923226>>. Acesso em: 01/06/2024.

RIQUETTI, N.B. et al. Rainfall erosivity in South America: Current patterns and future perspectives. **Science of The Total Environment**, [s.l.], v.724, p.138315, jul., 2020. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2020.138315>>. Acesso em: 01/06/2024.

RITCHIE, H.; ROSADO, P.; ROSER, M. Meat and Dairy Production. **Relatório Técnico – Our World in Data**, [s.l.], 2019. Disponível em: <<https://ourworldindata.org/meat-production>>. Acesso em: 01/16/2024.

ROBERTSON, L.D. et al. Compact Polarimetry for Operational Crop Inventory. In: 2022 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 42, 2022. **Anais...** [s.l.]: IEEE, 2022, p.4423–4426. Disponível em: <<https://doi.org/10.1109/IGARSS46834.2022.9884754>>. Acesso em: 30/04/2024

ROSA, R.; SANO, E.E. Determinação da produtividade primária líquida (NPP) de pastagens na bacia do rio Paranaíba, usando imagens MODIS. GeoFocus. **Revista Internacional de Ciencia y Tecnología de la Información Geográfica**, [s.l.], n.13,1, p.367–395, 2013. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2010.11.00>>. Acesso em: 01/06/2024.

ROSOLEM, C.A.; STEINER, F. Effects of soil texture and rates of K input on potassium balance in tropical soil. **European Journal of Soil Science**, [s.l.], v.68, n.5, p.658–666, 2017. Disponível em: <<https://doi.org/10.1111/ejss.12460>>. Acesso em: 01/06/2024.

ROUSE, J.W, HAAS, R.H., SCHEEL, J.A., DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. In: Proceedings, 3rd Earth Resource Technology Satellite (ERTS) Symposium, 3, 1974. **Anais...** [s.l.]: [s.n.], 1974, vol.1, p.309–317. Disponível em: <https://ntrs.nasa.gov/citations/19740022614>. Acesso em: 01/06/2024.

RUDORFF, B.F.T.; AGUIAR, D.A.; SILVA, W.F., SUGAWARA; L.M., ADAMI, M.; MOREIRA, M.A. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo State (Brazil) using Landsat data. **Remote sensing**, [s.l.], v.2, n.4, p.1057–1076, 2010. Disponível em: <<https://doi.org/10.3390/rs2041057>>. Acesso em: 01/06/2024.

SALTON, J.C. et al. Integrated crop-livestock system in tropical Brazil: Toward a sustainable production system. **Agriculture, Ecosystems & Environment**, Integrated Crop-Livestock System Impacts on Environmental Processes. [s.l.], v.190, p.70–79, jun., 2014. Disponível em: <<https://doi.org/10.1016/j.agee.2013.09.023>>. Acesso em: 01/06/2024.

SANDERMAN, J.; BALDOCK, J.A. Accounting for soil carbon sequestration in national inventories: a soil scientist's perspective. **Environmental Research Letters**, [s.l.], v.5, n.3, p.034003, ago., 2010. Disponível em: <<https://doi.org/10.1088/1748-9326/5/3/034003>>. Acesso em: 01/06/2024.

SANTOS, C.O. et al. Assessing the Wall-to-Wall Spatial and Qualitative Dynamics of the Brazilian Pasturelands 2010–2018, Based on the Analysis of the Landsat Data Archive. **Remote Sensing**, [s.l.], v.14, n.4, p.1024, jan., 2022. Disponível em: <<https://doi.org/10.3390/rs14041024>>. Acesso em: 01/06/2024.

SANTOS, C.O. et al. Livestock intensification and environmental sustainability: An analysis based on pasture management scenarios in the Brazilian savanna. **Journal of Environmental Management**, [s.l.], v.355, p.120473, mar., 2024. Disponível em: <<https://doi.org/10.1016/j.jenvman.2024.120473>>. Acesso em: 01/06/2024.

SANTOS, H.G. et al. **Brazilian Soil Classification System**. Brasília: Empresa Brasileira de Pesquisa Agropecuária, 2018. Disponível em: <<https://doi.org/>>. Acesso em: 01/06/2024.

SANTOS, J.F.S.; NAVAL, L.P. Spatial and temporal dynamics of water footprint for soybean production in areas of recent agricultural expansion of the Brazilian savannah (Cerrado). **Journal of Cleaner Production**, [s.l.], v.251, p.119482, abr., 2020. Disponível em: <<https://doi.org/10.1016/j.jclepro.2019.119482>>. Acesso em: 01/06/2024.

SANTOS, L.A. et al. Identifying Spatiotemporal Patterns in Land Use and Cover Samples from Satellite Image Time Series. **Remote Sensing**, [s.l.], v.13, n.5, p.974, jan., 2021. Disponível em: <<https://doi.org/10.3390/rs13050974>>. Acesso em: 01/06/2024.

SERRANO, J.M.; BARRETO, S.; SHAHIDIAN, S.; SILVA, J.M. Avaliação do sensor óptico de vegetação OptRx® na monitorização da variabilidade espacial e temporal de pastagens. **Revista de Ciências Agrárias**, [s.l.], v.39, n.2, p.261–280, 2016. Disponível em: <<https://doi.org/10.19084/RCA15101>>. Acesso em: 01/06/2024.

SHEN, H. et al. SAR Image Despeckling Employing a Recursive Deep CNN Prior. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.59, n.1, p.273–286, jan. 2021. Disponível em: <<https://doi.org/10.1109/TGRS.2020.2993319>>. Acesso em: 01/06/2024.

SHEYKHMOUSA, M. et al. Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.13, p.6308–6325, 2020. Disponível em: <<https://doi.org/10.1109/JSTARS.2020.3026724>>. Acesso em: 01/06/2024.

SILVA-PEREZ, C. et al. Multitemporal Polarimetric SAR Change Detection for Crop Monitoring and Crop Type Classification. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.14, p.12361–12374, 2021. Disponível em: <<https://doi.org/10.1109/JSTARS.2021.3130186>>. Acesso em: 01/06/2024.

SILVA, J.P.; ZULLO JUNIOR, J.; ROMANI, L.A.S. A Time Series Mining Approach for Agricultural Area Detection. **IEEE Transactions on Big Data**, [s.l.], v.6, n.3, p.537–546, set., 2020. Disponível em: <<https://doi.org/10.1109/TBDATA.2019.2913402>>. Acesso em: 01/06/2024.

SILVA, H.M.S. et al. Greenhouse gas mitigation and carbon sequestration potential in humid grassland ecosystems in Brazil: A review. **Journal of Environmental Management**, [s.l.], v.323, p.116269, dez., 2022. Disponível em: <<https://doi.org/10.1016/j.jenvman.2022.116269>>. Acesso em: 01/06/2024.

SINAGA, K.P.; YANG, M.S. Unsupervised K-Means Clustering Algorithm. **IEEE Access**, [s.l.], v.8, p.80716–80727, 2020. Disponível em: <<https://doi.org/10.1109/ACCESS.2020.2988796>>. Acesso em: 01/06/2024.

SINGH, B. Are Nitrogen Fertilizers Deleterious to Soil Health? **Agronomy**, [s.l.], v.8, n.4, p.48, abr. 2018. Disponível em: <<https://doi.org/10.3390/agronomy8040048>>. Acesso em: 01/06/2024.

SIRSAT, M.S. et al. Classification of agricultural soil parameters in India. **Computers and Electronics in Agriculture**, [s.l.], v.135, p.269–279, abr., 2017. Disponível em: <<https://doi.org/10.1016/j.compag.2017.01.019>>. Acesso em: 01/06/2024.

SLOAT, L.L. et al. Increasing importance of precipitation variability on global livestock grazing lands. **Nature Climate Change**, [s.l.], v.8, n.3, p.214–218, mar., 2018. Disponível em: <<https://doi.org/10.1038/s41558-018-0081-5>>. Acesso em: 01/06/2024.

SOARES-FILHO, B. et al. Cracking Brazil's Forest Code. **Science**, [s.l.], v.344, n.6182, p.363–364, abr., 2014. Disponível em: <<https://doi.org/10.1126/science.1246663>>. Acesso em: 01/06/2024.

SONG, X.P. et al. An evaluation of Landsat, Sentinel-2, Sentinel-1 and MODIS data for crop type mapping. **Science of Remote Sensing**, [s.l.], v.3, p.100018, jun., 2021. Disponível em: <<https://doi.org/10.1016/j.srs.2021.100018>>. Acesso em: 01/06/2024.

SOUZA, C.M. et al. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, [s.l.], v.12, n.17, p.2735, jan., 2020. Disponível em: <<https://doi.org/10.3390/rs12172735>>. Acesso em: 01/06/2024.

STABILE, M.C.C. et al. Solving Brazil's land use puzzle: Increasing production and slowing Amazon deforestation. **Land Use Policy**, [s.l.], v.91, p.104362, fev., 2020. Disponível em: <<https://doi.org/10.1016/j.landusepol.2019.104362>>. Acesso em: 01/06/2024.

STRASSBURG, B.B.N.; LATAWIEC, A.E.; BARIONI, L.G.; NOBRE, C.A.; SILVA, V.P.; VALENTIM, J.F.; VIANNA, M.; ASSAD, E.D. When enough should be enough: improving the use of current agricultural lands could meet production demands and spare natural habitats in Brazil. **Global Environmental Change**, [s.l.], v.28, p.84–97, 2014. Disponível em: <<https://doi.org/10.1016/j.gloenvcha.2014.06.001>>. Acesso em: 01/06/2024.

STUMPF, F. et al. Spatial monitoring of grassland management using multi-temporal satellite imagery. **Ecological Indicators**, [s.l.], v.113, p.106201, jun., 2020. Disponível em: <<https://doi.org/10.1016/j.ecolind.2020.106201>>. Acesso em: 01/06/2024.

SUN, J. et al. Cross-Comparison Between Jilin-1GF03B and Sentinel-2 Multi-Spectral Measurements and Phenological Monitors. **IEEE Access**, [s.l.], v.12, p.43540–43551, 2024. Disponível em: <<https://doi.org/10.1109/ACCESS.2024.3379322>>. Acesso em: 01/06/2024.

SURIGA, S.; HASHIMOTO, M.; HOSHINO, B.; GANZORIG, S. Change detection method for pasture degradation using RGB color composite image of multitemporal Landsat TM-A case study of the Inner Mongolian settlement region. In: 2012 IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 32, 2012, Munich. **Anais...** [s.l.]: IEEE, 2012,

p.6267–6270. Disponível em: <<https://doi.org/10.1109/IGARSS.2012.6352691>>. Acesso em: 01/06/2024.

TAMM, T. et al. Relating Sentinel-1 Interferometric Coherence to Mowing Events on Grasslands. **Remote Sensing**, [s.l.], v.8, n.10, p.802, out., 2016. Disponível em: <<https://doi.org/10.3390/rs8100802>>. Acesso em: 01/06/2024.

TEY, Y.S.; BRINDAL, M. Factors influencing the adoption of precision agricultural technologies: a review for policy implications. **Precision Agriculture**, [s.l.], v.13, n.6, p.713–730, dez., 2012. Disponível em: <<https://doi.org/10.1007/s11119-012-9273-6>>. Acesso em: 01/06/2024.

THE REDD-PAC PROJECT. MODELLING LAND USE CHANGES IN BRAZIL, 2000-2050. 12p. **Relatório Técnico – The REDD-PAC Project**, [São José dos Campos], 2015. Disponível em: <http://www.redd-pac.org/reports/lucc_brazil_folder.pdf>. Acesso em: 23 out. 2023.

THORNTHWAITE, C.W. An Approach toward a Rational Classification of Climate. **Geographical Review**, v.38, n.1, p.55–94, 1948. Disponível em: <<https://www.jstor.org/stable/210739>>. Acesso em: 01/06/2024.

THORNTHWAITE, C.W.; MATHER, J.R. The water balance. **Publications in climatology**, Centerton, v.8, n.1, p.1-104, 1955.

TIAN, H. et al. Pattern and variation of C:N:P ratios in China's soils: a synthesis of observational data. **Biogeochemistry**, [s.l.], v.98, n.1, p.139–151, abr., 2010. Disponível em: <<https://doi.org/10.1007/s10533-009-9382-0>>. Acesso em: 01/06/2024.

TIECHER, T. et al. Soil fertility and nutrient budget after 23-years of different soil tillage systems and winter cover crops in a subtropical Oxisol. **Geoderma**, [s.l.], v.308, p.78–85, dez., 2017. Disponível em: <<https://doi.org/10.1016/j.geoderma.2017.08.028>>. Acesso em: 01/06/2024.

TISCHER, A.; POTTHAST, K.; HAMER, U. Land-use and soil depth affect resource and microbial stoichiometry in a tropical mountain rainforest region of southern Ecuador. **Oecologia**, [s.l.], v.175, n.1, p.375–393, mai., 2014. Disponível em: <<https://doi.org/10.1007/s00442-014-2894-x>>. Acesso em: 01/06/2024.

TONATO, F.; BARIONI, L.G.; PEDREIRA, C.G.S.; DANTAS, O.D.; MALAQUIAS, J.V. Desenvolvimento de modelos preditores de acúmulo de forragem em pastagens tropicais. **Pesquisa Agropecuária Brasileira**, Brasília, v.45, n.5, p.522–529, 2010. Disponível em: <<https://doi.org/10.1590/S0100-204X2010000500012>>. Acesso em: 01/06/2024.

TORRES, R. et al. GMES Sentinel-1 mission. **Remote Sensing of Environment**, The Sentinel Missions - New Opportunities for Science, [s.l.], v.120, p.9–24, mai., 2012. Disponível em: <<https://doi.org/10.1016/j.rse.2011.05.028>>. Acesso em: 01/06/2024.

TU, B. et al. Hyperspectral Imagery Noisy Label Detection by Spectral Angle Local Outlier Factor. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.15, n.9, p.1417–1421, set., 2018. Disponível em: <<https://doi.org/10.1109/LGRS.2018.2842792>>. Acesso em: 01/06/2024.

VAGHELA, B. et al. Modelling above ground biomass of Indian mangrove forest using dual-pol SAR data. **Remote Sensing Applications: Society and Environment**, [s.l.], v.21, p.100457, jan., 2021. Disponível em: <<https://doi.org/10.1016/j.rsase.2020.100457>>. Acesso em: 01/06/2024.

VALE, T.M.C. et al. Climate and water balance influence on agricultural productivity over the Northeast Brazil. **Theoretical and Applied Climatology**, [s.l.], v.155, n.2, p.879–900, fev., 2024. Disponível em: <<https://doi.org/10.1007/s00704-023-04664-1>>. Acesso em: 01/06/2024.

VALERIANO, D.M. et al. METODOLOGIA DO SISTEMA DETER – B (SISTEMA DE DETECÇÃO DO DESMATAMENTO E ALTERAÇÕES NA COBERTURA FLORESTAL EM TEMPO QUASE REAL): MAPEAMENTO DE ALERTAS COM IMAGENS DOS SENSORES AWIFS-RESOURCESAT-2 E WFI-CBERS-4. 18p. **Relatório Técnico** – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016a. Disponível em: <<http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtc-m21b/2016/06.03.17.54/doc/publicacao.pdf>>. Acesso em: 01/06/2024.

VALERIANO, D.M. et al. NOTA TÉCNICA DO SISTEMA DETER – B (SISTEMA DE DETECÇÃO DO DESMATAMENTO E ALTERAÇÕES NA COBERTURA FLORESTAL EM TEMPO QUASE REAL): MAPEAMENTO DE ALERTAS COM IMAGENS DOS SENSORES AWIFS-RESOURCESAT-2 E WFI-CBERS-4. 18p. **Relatório Técnico** – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016b. Disponível em: <<http://mtc-m21b.sid.inpe.br/col/sid.inpe.br/mtc-m21b/2016/06.02.16.11/doc/thisInformationItemHomePage.html>>. Acesso em: 01/06/2024.

VALERIANO, T.T.B. et al. Evaluation of air temperature and rainfall from ECMWF and NASA gridded data for southeastern Brazil. **Theoretical and Applied Climatology**, [s.l.], v.137, n.3, p.1925–1938, ago., 2019. Disponível em: <<https://doi.org/10.1007/s00704-018-2706-z>>. Acesso em: 01/06/2024.

VELOSO, G.A. et al. Modelling gross primary productivity in tropical savanna pasturelands for livestock intensification in Brazil. **Remote Sensing Applications: Society and Environment**, [s.l.], v.17, p.100288, jan., 2020. Disponível em: <<https://doi.org/10.1016/j.rsase.2020.100288>>. Acesso em: 01/06/2024.

VERMA, A. et al. Built-up area mapping using Sentinel-1 SAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, [s.l.], v.203, p.55–70, set., 2023. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2023.07.019>>. Acesso em: 01/06/2024.

VIANA, C.M.; GIRÃO, I.; ROCHA, J. Long-Term Satellite Image Time-Series for Land Use/Land Cover Change Detection Using Refined Open Source Data in a Rural Region. **Remote Sensing**, [s.l.], v.11, n.9, p.1104, jan., 2019. Disponível em: <<https://doi.org/10.3390/rs11091104>>. Acesso em: 01/06/2024.

VILORIA, A.; LEZAMA, O.B.P. Improvements for Determining the Number of Clusters in k-Means for Innovation Databases in SMEs. **Procedia Computer Science**, [s.l.], v.151, p.1201–1206, mai., 2019. Disponível em: <<https://doi.org/10.1016/j.procs.2019.04.172>>. Acesso em: 01/06/2024.

WANG, H. et al. Crop phenology retrieval via polarimetric SAR decomposition and Random Forest algorithm. **Remote Sensing of Environment**, [s.l.], v.231, p.111234, set., 2019. Disponível em: <<https://doi.org/10.1016/j.rse.2019.111234>>. Acesso em: 01/06/2024.

WANG, L. et al. Modification of Statistical Metric Biases in Large-Region and Long-Time-Series Landsat Dataset Due to Insufficient Observations. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.61, p.1–14, 2023. Disponível em: <<https://doi.org/10.1109/TGRS.2023.3323319>>. Acesso em: 01/06/2024.

WANG, Y. et al. Estimation of maize plant height in North China by means of backscattering coefficient and depolarization parameters using Sentinel-1 dual-pol SAR data. **International Journal of Remote Sensing**, [s.l.], v.43, n.6, p.1960–1982, mar., 2022. Disponível em: <<https://doi.org/10.1080/01431161.2022.2054294>>. Acesso em: 01/06/2024.

WARNER, J.M. et al. Estimating acid soil effects on selected cereal crop productivities in Ethiopia: Comparing economic cost-effectiveness of lime and fertilizer applications. **PLOS ONE**, [s.l.], v.18, n.1, p.e0280230, jan., 2023. Disponível em: <<https://doi.org/10.1371/journal.pone.0280230>>. Acesso em: 01/06/2024.

WHITE, H.J. et al. Predicting future stability of ecosystem functioning under climate change. **Agriculture, Ecosystems & Environment**, [s.l.], v.320, p.107600, out., 2021. Disponível em: <<https://doi.org/10.1016/j.agee.2021.107600>>. Acesso em: 01/06/2024.

XAVIER, A.C. et al. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, [s.l.], v.42, n.16, p.8390–8404, 2022. Disponível em: <<https://doi.org/10.1002/joc.7731>>. Acesso em: 01/06/2024.

WOLD, S.; ESBENSEN, K.; GELADI, P. Principal component analysis. **Chemometrics and Intelligent Laboratory Systems**, Proceedings of the Multivariate Statistical Workshop for Geologists and Geochemists. [s.l.], v.2, n.1-3, p.37–52, ago., 1987. Disponível em: <[https://doi.org/10.1016/0169-7439\(87\)80084-9](https://doi.org/10.1016/0169-7439(87)80084-9)>. Acesso em: 01/06/2024.

XIAO, X. et al. Temporal Series Crop Classification Study in Rural China Based on Sentinel-1 SAR Data. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [s.l.], v.14, p.2769–2780, 2021. Disponível em: <<https://doi.org/10.1109/JSTARS.2021.3057903>>. Acesso em: 01/06/2024.

YANG, C. et al. Suppressing Range Ambiguity by Pattern Synthesis for SAR via Semidefinite Relaxation. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.19, p.1–5, 2022. Disponível em: <<https://doi.org/10.1109/LGRS.2020.3041826>>. Acesso em: 01/06/2024.

YU, S. et al. Hyperspectral Anomaly Detection Based on Low-Rank Representation Using Local Outlier Factor. **IEEE Geoscience and Remote Sensing Letters**, [s.l.], v.18, n.7, p.1279–1283, jul., 2021. Disponível em: <<https://doi.org/10.1109/LGRS.2020.2994745>>. Acesso em: 01/06/2024.

ZANTEN, H.H.E. et al. Global food supply: land use efficiency of livestock systems. **The International Journal of Life Cycle Assessment**, [s.l.], v.21, n.5, p.747–758, mai., 2016. Disponível em: <<https://doi.org/10.1007/s11367-015-0944-1>>. Acesso em: 01/06/2024.

ZERAATPISHEH, M. et al. Integration of PCA and Fuzzy Clustering for Delineation of Soil Management Zones and Cost-Efficiency Analysis in a Citrus Plantation. **Sustainability**, [s.l.],

v.12, n.14, p.5809, jan., 2020. Disponível em: <<https://doi.org/10.3390/su12145809>>. Acesso em: 01/06/2024.

ZHANG, J. et al. The response of productivity and its sensitivity to changes in precipitation: A meta-analysis of field manipulation experiments. **Journal of Vegetation Science**, [s.l.], v.32, n.1, p.e12954, 2021. Disponível em: <<https://doi.org/10.1111/jvs.12954>>. Acesso em: 01/06/2024.

ZHANG, L.; REN, H. Estimation of grassland height using optical and SAR remote sensing data. **Advances in Space Research**, [s.l.], v.72, n.10, p.4298–4310, nov., 2023. Disponível em: <<https://doi.org/10.1016/j.asr.2023.08.018>>. Acesso em: 01/06/2024.

ZHANG, Y. et al. Signal Reconstruction Algorithm for Azimuth Multichannel SAR System Based on a Multiobjective Optimization Model. **IEEE Transactions on Geoscience and Remote Sensing**, [s.l.], v.58, n.6, p.3881–3893, jun., 2020. Disponível em: <<https://doi.org/10.1109/TGRS.2019.2959217>>. Acesso em: 01/06/2024.

ZHU, Q. et al. Scale-dependent effects of environmental factors on soil organic carbon, soil nutrients and stoichiometry under two contrasting land-use types. **Soil Use and Management**, [s.l.], v.37, n.2, p.243–256, 2021. Disponível em: <<https://doi.org/10.1111/sum.12695>>. Acesso em: 01/06/2024.

ZULLO JUNIOR, J.; PEREIRA, V.R.; KOGA-VICENTE, A. Sugar-energy sector vulnerability under CMIP5 projections in the Brazilian central-southern macro-region. **Climatic Change**, [s.l.], v.149, n.3, p.489–502, ago., 2018. Disponível em: <<https://doi.org/10.1007/s10584-018-2249-4>>. Acesso em: 01/06/2024.

APÊNDICES

APÊNDICE 1 — “Estatística descritiva dos resultados das análises de solo estratificadas por uso da terra, grupo textural e profundidade”

Tabela 11 — Valores médios dos atributos químicos e físicos resultantes de análise de solo estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais (GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).

Atributo				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unidade				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Média											
1	P	0-5	Aren	39	1,48	10,59	0,58	4,85	2,34	10,50	90,73	1,75	0,79	0,19	3,08
2			Méd	43	1,46	16,32	0,80	4,94	3,28	8,53	124,53	2,61	1,20	0,14	3,99
3			Arg	27	1,26	22,63	1,03	5,02	4,83	7,77	133,69	3,22	1,80	0,29	6,00
4			M.Arg	6	1,28	30,58	1,40	4,68	5,57	11,53	166,93	3,55	1,75	0,45	7,25
5		5-10	Aren	36	1,54	7,86	0,46	4,71	1,89	9,28	68,40	1,67	0,54	0,29	3,08
6			Méd	49	1,54	12,06	0,68	4,80	2,52	6,43	82,18	2,48	0,94	0,19	3,81
7			Arg	33	1,33	18,40	0,94	4,82	3,79	4,54	100,84	3,15	1,27	0,41	6,07
8			M.Arg	9	1,22	21,95	1,00	4,62	4,59	7,56	109,82	2,93	1,41	0,66	7,58
9		10-20	Aren	32	1,57	6,54	0,80	4,60	1,60	6,78	55,56	1,51	0,52	0,36	3,15
10			Méd	50	1,53	9,69	1,05	4,71	1,96	3,52	53,62	1,79	0,59	0,26	3,82
11			Arg	37	1,32	15,14	1,48	4,67	3,13	3,01	68,07	2,32	0,90	0,56	5,99
12			M.Arg	7	1,15	21,55	1,95	4,70	3,73	4,84	92,61	3,37	1,41	0,37	6,87
13		20-30	Aren	27	1,57	5,72	0,73	4,58	1,26	5,51	43,99	1,39	0,48	0,47	2,90
14			Méd	48	1,54	7,62	0,86	4,65	1,58	2,04	46,95	1,53	0,53	0,31	3,56

continua

continuação

Atributo				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unidade				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Média											
15			Arg	38	1,35	11,81	1,17	4,59	2,38	2,49	47,39	1,69	0,72	0,43	4,91
16			M.Arg	10	1,19	15,19	1,30	4,65	3,22	2,16	67,21	1,88	0,81	0,69	6,69
17	SI	0-5	Aren	11	1,35	13,49	0,62	5,04	2,15	31,20	104,86	2,58	1,05	0,14	2,64
18			Méd	24	1,39	15,39	0,76	4,97	2,40	18,01	109,48	2,68	1,00	0,08	2,68
19			Arg	11	1,20	28,98	1,24	5,12	3,77	28,35	212,92	4,43	1,99	0,08	4,20
20			M.Arg	2	1,13	36,96	1,40	4,40	4,75	9,60	136,85	3,85	0,80	0,35	7,35
21		5-10	Aren	14	1,44	10,29	0,50	4,69	1,54	20,52	60,61	2,08	0,78	0,21	2,81
22			Méd	23	1,44	10,52	0,52	4,85	1,73	19,20	82,11	2,18	0,88	0,15	2,96
23			Arg	15	1,24	20,09	0,89	4,79	2,88	21,30	106,35	3,72	1,74	0,18	4,92
24			M.Arg	3	1,15	29,79	1,13	4,13	3,80	8,17	78,20	2,60	0,47	0,67	7,57
25		10-20	Aren	10	1,51	9,00	0,86	4,74	1,29	15,88	36,75	1,58	0,61	0,22	2,36
26			Méd	28	1,41	10,50	1,03	4,65	1,50	12,10	61,72	1,99	0,80	0,22	3,33
27			Arg	14	1,32	16,57	1,48	4,70	2,52	10,36	68,15	2,36	1,09	0,25	4,79
28			M.Arg	3	1,09	29,25	2,07	4,27	3,67	5,53	65,17	3,33	0,47	0,37	7,17
29		20-30	Aren	11	1,39	8,30	0,63	4,45	1,08	7,01	47,28	1,16	0,50	0,43	2,92
30			Méd	25	1,44	7,77	0,79	4,64	1,16	5,04	42,85	1,64	0,73	0,27	3,13
31			Arg	16	1,29	13,74	1,14	4,55	2,00	5,35	54,98	1,77	0,89	0,32	4,68
32			M.Arg	3	1,09	25,48	1,74	4,27	3,23	4,67	39,10	2,77	0,33	0,50	6,93

conclusão

Atributo				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unidade				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Média											
33	VN	0-5	Aren	11	1,29	14,91	0,69	4,65	2,41	7,59	72,16	2,65	0,75	0,48	3,53
34			Méd	13	1,27	21,77	0,84	4,62	3,14	4,87	110,68	2,79	1,01	0,30	4,67
35			Arg	5	1,08	33,98	1,27	4,35	4,86	5,70	124,14	2,83	1,15	0,68	8,71
36			M.Arg	1	0,97	33,15	1,15	4,20	4,20	3,20	78,20	3,50	1,20	0,40	6,80
37		5-10	Aren	11	1,36	12,90	0,70	4,48	1,73	4,76	49,05	1,37	0,70	0,52	4,21
38			Méd	15	1,34	15,32	0,76	4,31	2,04	4,79	66,21	1,93	0,75	0,37	4,80
39			Arg	5	1,18	23,42	1,03	4,28	3,46	3,92	68,77	2,55	0,80	0,52	7,35
40			M.Arg	2	1,26	20,87	0,97	4,00	3,15	1,55	124,60	0,80	0,30	1,15	7,20
41		10-20	Aren	8	1,33	10,03	0,98	4,45	1,33	4,06	35,19	1,23	0,50	0,65	4,01
42			Méd	19	1,38	12,08	1,27	4,22	1,70	4,57	45,89	2,06	0,74	0,39	4,36
43			Arg	5	1,08	23,48	1,72	3,99	3,00	4,82	35,97	0,92	0,62	0,95	7,57
44			M.Arg	3	1,24	16,97	1,78	4,23	2,80	1,03	80,37	2,60	0,57	1,03	7,03
45		20-30	Aren	8	1,37	6,83	0,63	4,39	1,10	3,78	20,04	0,83	0,41	0,76	3,96
46			Méd	15	1,36	10,16	1,07	4,20	1,32	4,17	39,10	1,43	0,67	0,36	3,82
47			Arg	7	1,27	15,83	1,15	4,01	2,25	3,50	35,19	0,61	0,37	0,50	6,41
48			M.Arg	3	1,23	14,19	1,54	4,23	2,20	0,97	56,03	2,33	0,47	0,97	6,13
Total				835											

conclusão

Tabela 12 — Desvio padrão dos atributos químicos e físicos resultantes de análise de solo estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais (GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).

Atrib.				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unid.				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Desvio padrão											
1	P	0-5	Aren	39	0,16	6,60	0,37	0,49	1,18	10,81	68,22	1,14	0,49	0,24	1,41
2			Méd	43	0,14	7,35	0,36	0,55	1,11	10,95	92,12	2,35	1,26	0,27	1,74
3			Arg	27	0,15	7,83	0,41	0,43	1,19	11,70	82,22	1,71	0,83	1,05	2,77
4			M.Arg	6	0,23	11,79	0,40	0,41	2,15	20,49	50,11	2,39	0,67	0,87	3,80
5		5-10	Aren	36	0,13	3,41	0,22	0,73	0,77	13,11	68,43	1,58	0,43	0,30	1,54
6			Méd	49	0,15	6,07	0,33	0,56	0,91	11,12	64,02	2,61	1,43	0,32	1,91
7			Arg	33	0,16	5,75	0,40	0,58	1,02	9,37	89,46	2,31	0,87	1,00	2,60
8			M.Arg	9	0,18	10,00	0,39	0,50	1,67	10,65	36,40	2,30	1,05	1,07	2,80
9		10-20	Aren	32	0,13	3,22	0,38	0,68	0,82	10,49	55,61	1,54	0,50	0,29	1,64
10			Méd	50	0,16	4,58	0,54	0,55	0,71	5,91	55,02	1,63	0,61	0,37	1,77
11			Arg	37	0,15	5,51	0,58	0,59	0,93	6,98	63,87	1,95	0,79	1,17	2,84
12			M.Arg	7	0,10	5,76	0,23	0,48	1,47	7,77	51,79	2,63	1,11	0,73	1,14
13		20-30	Aren	27	0,14	3,16	0,40	0,66	0,54	12,59	42,47	1,44	0,64	0,62	1,54
14			Méd	48	0,15	3,59	0,46	0,56	0,58	1,91	65,16	1,39	0,58	0,37	1,60
15			Arg	38	0,15	4,03	0,44	0,57	0,65	6,93	43,06	1,75	0,76	0,50	1,94
16			M.Arg	10	0,16	5,63	0,41	0,52	0,95	3,78	54,54	1,47	0,63	1,11	2,47

continua

continuação

Atrib.				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unid.				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Desvio padrão											
17	SI	0-5	Aren	11	0,19	12,15	0,52	0,62	1,00	21,34	59,88	1,75	0,61	0,17	1,58
18			Méd	24	0,19	9,30	0,35	0,48	0,95	16,06	48,96	1,42	0,46	0,13	1,69
19			Arg	11	0,19	12,95	0,39	0,40	0,77	21,21	106,58	2,43	1,08	0,07	1,86
20			M.Arg	2	0,01	1,96	0,03	0,28	0,50	4,67	82,94	1,20	0,42	0,21	1,06
21		5-10	Aren	14	0,22	8,07	0,23	0,55	0,67	16,62	27,81	1,53	0,36	0,23	1,66
22			Méd	23	0,16	6,25	0,35	0,46	0,80	16,67	59,56	1,44	0,51	0,26	1,91
23			Arg	15	0,19	5,52	0,23	0,38	0,60	18,60	62,56	2,52	1,33	0,16	1,75
24			M.Arg	3	0,07	3,38	0,08	0,21	0,53	1,63	0,00	0,90	0,15	0,31	0,75
25		10-20	Aren	10	0,20	7,68	0,42	0,60	0,64	16,83	17,79	1,05	0,34	0,27	1,31
26			Méd	28	0,20	6,62	0,59	0,49	0,58	10,99	34,26	1,40	0,57	0,27	1,82
27			Arg	14	0,16	6,22	0,69	0,38	0,69	9,21	41,63	1,26	0,72	0,30	1,84
28			M.Arg	3	0,04	4,52	0,35	0,06	0,81	3,44	22,57	0,59	0,15	0,06	0,55
29		20-30	Aren	11	0,23	7,93	0,33	0,37	0,70	3,62	39,78	0,82	0,27	0,57	2,03
30			Méd	25	0,25	4,65	0,48	0,61	0,49	3,92	29,55	1,29	0,63	0,31	1,79
31			Arg	16	0,18	4,14	0,47	0,41	0,58	4,69	43,41	1,36	0,85	0,37	2,08
32			M.Arg	3	0,03	6,52	0,52	0,23	0,87	0,29	0,00	1,05	0,15	0,26	0,42
33	VN	0-5	Aren	11	0,16	4,68	0,24	0,79	0,82	5,30	48,31	3,01	0,53	0,47	2,13
34			Méd	13	0,19	10,72	0,64	0,50	0,96	2,71	69,57	2,30	0,78	0,53	2,27

Atrib.				#	DS	C	N	pH	O.M.	P	K	Ca	Mg	Al	P.A.
Unid.				-	g.dm ⁻³	g.kg ⁻¹	Mg.ha ⁻¹	-	dag.kg ⁻¹	mg.dm ⁻³		cmolc.dm ⁻³			
id	UT	Prof. (cm)	GT	Desvio padrão											
35			Arg	5	0,18	5,28	0,44	0,62	1,33	8,03	107,43	3,58	1,25	0,79	2,05
36			M.Arg	1	*ND	*ND	*ND	*ND	*ND	*ND	*ND	*ND	*ND	*ND	*ND
37		5-10	Aren	11	0,16	4,96	0,31	0,73	0,74	2,19	30,71	1,37	0,67	0,49	2,62
38			Méd	15	0,18	8,29	0,49	0,43	0,83	3,52	51,76	2,16	0,76	0,45	1,94
39			Arg	5	0,18	6,05	0,41	0,44	0,96	5,71	59,51	3,41	0,92	0,51	1,85
40			M.Arg	2	0,20	11,41	0,25	0,14	0,64	1,63	65,62	0,71	0,14	0,21	1,27
41		10-20	Aren	8	0,12	5,62	0,33	0,73	0,52	1,60	22,80	0,91	0,32	0,51	2,27
42			Méd	19	0,19	6,04	0,72	0,31	0,84	5,02	35,74	2,20	0,86	0,42	2,25
43			Arg	5	0,17	7,55	0,47	0,21	0,67	4,47	19,43	1,06	0,65	0,59	2,27
44			M.Arg	3	0,16	6,33	0,41	0,51	0,44	1,02	35,86	3,73	0,64	0,85	2,05
45		20-30	Aren	8	0,14	4,74	0,29	0,73	0,60	0,78	7,37	0,63	0,30	0,64	2,68
46			Méd	15	0,18	6,74	0,68	0,28	0,64	5,16	28,92	1,42	0,77	0,45	1,73
47			Arg	7	0,25	7,57	0,58	0,19	0,89	2,77	29,78	0,51	0,29	0,46	1,96
48			M.Arg	3	0,13	6,57	0,38	0,45	0,56	0,91	18,64	3,27	0,55	0,74	1,72
Total				835											

*Não disponível (ND): Não foi possível calcular o parâmetro em função do tamanho da amostra

conclusão

APÊNDICE 2 — “Estatística descritiva dos resultados das análises de solo estratificadas por uso da terra, grupo textural e profundidade transformados em índices de fertilidade e acidez”

Tabela 13 — Média e desvio padrão dos indicadores de fertilidade e acidez extraídos do modelo PCA estratificados por sistema de uso da terra (UT), profundidade amostral e grupos texturais (GT) correspondentes às texturas arenosa (Aren), média (Méd), argilosa (Arg) e muito argilosa (M.Arg) de solos extraídos de áreas de pastagem (P), sistemas integrados (SI) e vegetação nativa (VN).

Dimensão					Fertilidade (1ª CP)		Acidez (2ª CP)	
					Média	Desvio padrão	Média	Desvio padrão
Unidade					adimensional			
id	UT	Prof. (cm)	GT	#				
1	P	0-5	Aren	39	-0,57	1,44	-0,75	1,13
2			Méd	43	0,78	1,86	-0,70	1,41
3			Arg	27	2,66	1,55	0,01	1,96
4			M.Arg	6	3,78	2,46	0,85	2,37
5		5-10	Aren	36	-1,28	1,20	-0,56	1,45
6			Méd	49	-0,26	1,57	-0,59	1,63
7			Arg	33	1,51	1,71	0,33	2,02
8			M.Arg	9	2,33	2,04	1,19	2,27
9		10-20	Aren	32	-1,41	1,22	-0,26	1,30
10			Méd	50	-0,79	1,34	-0,10	1,32
11			Arg	37	0,94	1,60	0,97	2,25
12			M.Arg	7	2,66	1,69	1,04	1,59
13		20-30	Aren	27	-1,75	1,07	-0,19	1,47

continua

continuação

Dimensão					Fertilidade (1ª CP)		Acidez (2ª CP)	
					Média	Desvio padrão	Média	Desvio padrão
Unidade					adimensional			
id	UT	Prof. (cm)	GT	#				
14			Méd	48	-1,31	1,20	-0,11	1,21
15			Arg	38	-0,12	1,43	0,64	1,45
16			M.Arg	10	0,99	1,01	1,41	2,23
17	SI	0-5	Aren	11	0,31	2,24	-1,43	1,24
18			Méd	24	0,36	1,61	-1,16	0,82
19			Arg	11	3,61	2,40	-1,23	0,89
20			M.Arg	2	3,51	1,08	1,53	1,12
21		5-10	Aren	14	-0,86	1,38	-0,84	1,08
22			Méd	23	-0,57	1,44	-1,05	0,90
23			Arg	15	1,80	1,66	-0,58	1,05
24			M.Arg	3	1,93	0,69	2,19	0,59
25		10-20	Aren	10	-1,24	1,22	-0,70	1,36
26			Méd	28	-0,52	1,49	-0,36	1,07
27			Arg	14	0,89	1,43	0,23	1,07
28			M.Arg	3	2,60	0,86	2,04	0,37
29		20-30	Aren	11	-1,49	1,25	0,04	1,64
30			Méd	25	-1,25	1,27	-0,32	1,24

continuação

Dimensão					Fertilidade (1ª CP)		Acidez (2ª CP)	
					Média	Desvio padrão	Média	Desvio padrão
Unidade					adimensional			
id	UT	Prof. (cm)	GT	#				
31			Arg	16	0,04	1,50	0,46	1,16
32			M.Arg	3	1,75	1,29	2,09	0,43
33	VN	0-5	Aren	11	0,06	1,62	0,01	1,89
34			Méd	13	1,15	1,85	0,23	1,65
35			Arg	5	3,35	2,03	2,22	2,48
36			M.Arg	1	2,91	*ND	1,73	*ND
37		5-10	Aren	11	-0,73	1,18	0,48	1,80
38			Méd	15	-0,21	1,96	0,59	1,05
39			Arg	5	1,46	2,13	1,68	1,46
40			M.Arg	2	0,64	1,27	2,58	1,08
41		10-20	Aren	8	-0,99	0,80	0,73	1,72
42			Méd	19	-0,35	2,05	0,68	0,82
43			Arg	5	1,31	1,43	2,97	0,90
44			M.Arg	3	1,18	1,49	2,20	2,32
45		20-30	Aren	8	-1,71	0,67	0,77	1,90
46			Méd	15	-0,93	1,79	0,57	0,95
47			Arg	7	-0,25	1,39	1,92	1,12

Dimensão					Fertilidade (1ª CP)		Acidez (2ª CP)	
					Média	Desvio padrão	Média	Desvio padrão
Unidade					adimensional			
id	UT	Prof. (cm)	GT	#				
48			M.Arg	3	0,43	1,17	1,90	2,02
Total					835			

*Não disponível (ND): Não foi possível calcular o parâmetro em função do tamanho da amostra

APÊNDICE 3 — “Parametrização do modelo sazonal das séries temporais de produtividade na ferramenta Timesat”

Tabela 14 — Parâmetros de configuração da ferramenta Timesat para configuração do modelo sazonal extraído das séries temporais de produtividade.

Parâmetro	Valor
Método de remoção de <i>outliers</i>	Substituição de <i>outliers</i>
Rigidez da decomposição sazonal	3 (1-10)
Número de temporadas por ano ²²	1 (0-1, decimal)
Número de iterações do envelope	3 (1-3)
Força de adaptação do modelo	5 (1-10)
Valor mínimo forçado	Indefinido
Método de definição de início da temporada	Amplitude sazonal
Critério de início e fim da temporada sazonal	20% da amplitude para ambos

²² Quanto mais próximo a 1, maior a sensibilidade do modelo para extrair apenas uma temporada sazonal por ano. Quanto mais próximo a 0, maior a sensibilidade para extrair duas temporadas.

APÊNDICE 4 — “Estatística descritiva das características de uso da terra e rebanho dos municípios não incorporados (*outliers*) na análise de agrupamento de sistemas produtivos”

Tabela 15 — Descrição do conjunto de municípios classificados como *outliers* no escopo deste trabalho.

Parâmetro	Área		Uso da terra	Taxa de	Rebanho
	Município	Pastagem	Pastagem	lotação	bovino
	(hectare)		(%)	(UA/ha)	(cabeças)
Máximo	247.035	16.795	40	54,99	108.425
75%	48.929	2.576	08	11,34	17.769
50% (mediana)	29.355	1.010	03	06,65	6.776
25%	16.172	294	01	05,38	2.905
Mínimo	5.746	25	00	04,69	426
Total	3.708.909	185.541	-	-	1.213.324

Fonte: Parente et al. (2017) e IBGE (2024).

APÊNDICE 5 — “Espacialização, em escala de município, dos indicadores máximos e mínimos das propriedades territoriais e de rebanho bovino por sistema produtivo pecuário”

Figura 42 — Amostras de municípios e sua área total, em mil hectares, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).




Figura 43 — Amostras de municípios e sua área total de pastagem, em mil hectares, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).




Figura 44 — Amostras de municípios e seu rebanho bovino médio, em mil cabeças, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).




Figura 45 — Amostras de municípios e sua ocupação relativa por pastagem, em porcentagem, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).





Figura 46 — Amostras de municípios e sua taxa de lotação, em cabeças/hectare, em subconjuntos por estado e por Sistema Produtivo Pecuário (SPP).



APÊNDICE 6 — “Agregados dos atributos dos Sistemas Produtivos Pecuários (SPP) em relação aos estados.”

Tabela 16 — Área de pastagem total, em 2015, por Sistema Produtivo Pecuário (SPP) e por estado (UF).

UF	Área de pastagem (milhões de hectares)					
	SPP 1	SPP 2	SPP 3	SPP 4	SPP 5	Total
GO	00,53	00,62	02,92	01,23	06,27	11,57
MS	00,14	00,33	01,61	03,57	06,87	12,52
MT	01,35	00,09	02,04	06,14	00,57	10,19
SP	00,73	00,74	02,23	00,00	01,08	04,78
Total	02,75	01,78	08,80	10,94	14,79	39,06

Fonte: Parente et al. (2017)


Tabela 17 — Rebanho bovino médio, entre 2015 e 2018, por Sistema Produtivo Pecuário (SPP) e por estado (UF).

UF	Rebanho bovino (milhões de cabeças)					
	SPP 1	SPP 2	SPP 3	SPP 4	SPP 5	Total
GO	00,87	02,06	05,91	01,84	11,25	21,93
MS	00,26	01,00	02,92	04,92	10,43	19,53
MT	01,74	00,24	03,47	08,49	01,07	15,01
SP	01,22	02,34	04,56	00,00	02,09	10,21
Total	04,09	05,64	16,86	15,25	24,84	66,68

Fonte: IBGE (2024)

APÊNDICE 7 — “Média espacial da produção de matéria seca por amostra e por SPP.”

Figura 47 — Distribuição da produção sazonal acumulada estimada pelo modelo de produtividade observada no período 2015-2016. A linha vermelha indica a posição do valor médio na região amostral.



APÊNDICE 8 — “Parâmetros sazonais dos modelos de produtividade observada e potencial.”

Figura 48 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Ponta-Porã-MS.




Figura 49 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Ponta-Porã-MS.




Figura 50 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Tesouro-MS.




Figura 51 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Tesouro-MT.




Figura 52 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Avaré-SP.




Figura 53 — Parâmetros sazonais dos modelos de produtividade observada (*NDVI*) e potencial (grupo C1) que configuram os *clusters* para a região de Avaré-SP.




Figura 54 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Água Fria de Goiás-GO.




Figura 55 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Água Fria de Goiás-GO.




Figura 56 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Itaporã-MS.




Figura 57 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Itaporã-MS.




Figura 58 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Rio Verde-GO.




Figura 59 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Rio Verde-GO.




Figura 60 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Birigui-SP.




Figura 61 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Birigui-SP.




Figura 62 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os *clusters* para a região de Campo Novo do Parecis-MT.




Figura 63 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os *clusters* para a região de Campo Novo do Parecis-MT.




Figura 64 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Rondonópolis-MT.




Figura 65 — Parâmetros sazonais dos modelos de produtividade observada (*NDVI*) e potencial (grupo C1) que configuram os clusters para a região de Rondonópolis-MT.




Figura 66 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Naviraí-MS.




Figura 67 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Naviraí-MS.




Figura 68 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Crixás-GO.




Figura 69 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Crixás-GO.




Figura 70 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Piracanjuba-GO.




Figura 71 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Piracanjuba-GO.




Figura 72 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Campo Grande-MS.




Figura 73 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Campo Grande-MS.




Figura 74 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Canarana-MT.




Figura 75 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Canarana-MT.




Figura 76 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Serranópolis-GO.




Figura 77 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Serranópolis-GO.




Figura 78 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Porto Murtinho-MS.




Figura 79 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Porto Murtinho-MS.




Figura 80 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Alcinópolis-MS.




Figura 81 — Parâmetros sazonais dos modelos de produtividade observada (*NDVI*) e potencial (grupo C1) que configuram os clusters para a região de Alcinópolis-MS.




Figura 82 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Montes Claros de Goiás-GO.




Figura 83 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Montes Claros de Goiás-GO.




Figura 84 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Aparecida do Taboado-MS.




Figura 85 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Aparecida do Taboado-MS.




Figura 86 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo U1) que configuram os clusters para a região de Porangatu-GO.




Figura 87 — Parâmetros sazonais dos modelos de produtividade observada (NDVI) e potencial (grupo C1) que configuram os clusters para a região de Porangatu-GO.

