

UFRRJ

**PRÓ-REITORIA DE EXTENSÃO
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO,
LEVANTAMENTO E INTERPRETAÇÃO DE SOLOS**

TRABALHO DE CONCLUSÃO DE CURSO

**Suscetibilidade à Degradação do Solo em Áreas de
Produção Leiteira a Partir da Análise de Covariáveis
Ambientais Utilizando Geoprocessamento**

Débora Pantojo de Souza

2025



UNISOLOS

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
PRÓ-REITORIA DE EXTENSÃO
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO,
LEVANTAMENTO E INTERPRETAÇÃO DE SOLOS**

**SUSCETIBILIDADE À DEGRADAÇÃO DO SOLO EM ÁREAS DE
PRODUÇÃO LEITEIRA A PARTIR DA ANÁLISE DE COVARIÁVEIS
AMBIENTAIS UTILIZANDO GEOPROCESSAMENTO**

DÉBORA PANTOJO DE SOUZA

Sob a Supervisão da Professora
Lúcia Helena Cunha dos Anjos

E da Professora
Niriele Rodrigues

Trabalho de Conclusão de Curso
submetido como requisito parcial para
obtenção do título de **Especialista** em
Geoprocessamento, Levantamento e
Interpretação de Solos.

Seropédica, RJ
Julho de 2025



Universidade Federal Rural do Rio de Janeiro
Biblioteca Central/Seção de Processamento Técnico

Ficha catalográfica elaborada
Com os dados fornecidos pelo(a) autor(a)

Ps

Pantojo de Souza, Débora, 1992-

Suscetibilidade à Degradação do Solo em Áreas de Produção Leiteira a Partir da Análise de Covariáveis Ambientais Utilizando Geoprocessamento / Débora Pantojo de Souza. - Dourado/MS, 2025.

32 f.

Orientadora: Lúcia Helena Cunha dos Anjos.
Coorientadora: Niriele Rodrigues.

Trabalho de conclusão de curso(Especialização). -
- Universidade Federal Rural do Rio de Janeiro,
ESPECIALIZAÇÃO EM GEOPROCESSAMENTO, LEVANTAMENTO E
INTERPRETAÇÃO DE SOLOS, 2025.

1. Saúde do solo. 2. SIG. 3. Vegetação. 4.
Degradação do solo. I. Cunha dos Anjos, Lúcia Helena ,
1957-, orient. II. Rodrigues, Niriele , 1994-,
coorient. III Universidade Federal Rural do Rio de
Janeiro. ESPECIALIZAÇÃO EM GEOPROCESSAMENTO,
LEVANTAMENTO E INTERPRETAÇÃO DE SOLOS. IV. Título.

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

É permitida a cópia parcial ou total deste documento, desde que seja citada a fonte.

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
PRÓ-REITORIA DE EXTENSÃO
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO, LEVANTAMENTO
E INTERPRETAÇÃO DE SOLOS**

DÉBORA PANTOJO DE SOUZA

Este Trabalho de Conclusão de Curso (TCC) foi submetido como requisito parcial para obtenção do título de Especialista em Geoprocessamento, Levantamento e Interpretação de Solos.

TCC APROVADO EM 18 de Julho de 2025.

Prof.(a) Lúcia Helena Cunha dos Anjos
(Supervisora)

Max Paulo Rocha Pereira
UFMG

Amanda Sales Alves
UFRRJ

RESUMO

Souza, Débora Pantojo de. **Suscetibilidade à degradação do solo em áreas de produção leiteira a partir da análise de covariáveis ambientais utilizando geoprocessamento**. 2025. 32f. Trabalho de Conclusão de Curso (Especialização em Geoprocessamento, Levantamento e Interpretação de Solos). Pró-reitoria de Extensão, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

O objetivo do trabalho foi avaliar a suscetibilidade à degradação do solo em área com fazendas produtoras de leite à pasto no Rio Grande do Sul. O trabalho foi realizado utilizando a análise multicritério espacial para classificar áreas quanto a suscetibilidade à degradação do solo, considerando a relação entre variáveis ambientais e dados produtivos. A metodologia combina o uso de geotecnologias com o método de Análise Hierárquica por Processo (AHP), aplicados sobre dados de vegetação, solo e produção leiteira. Os dados foram espacializados e tratados em ambiente de Sistema de Informação Geográfica (SIG), com normalização dos critérios e atribuição de pesos por especialistas. A classificação gerada permitiu identificar diferentes níveis na área de estudo, apontando áreas prioritárias para ações de gestão territorial, políticas públicas e sustentabilidade produtiva. O estudo demonstrou a aplicabilidade de métodos multicritério para suporte à decisão em planejamento agropecuário, com foco regionalizado e fundamentado em bases técnico-científicas.

Palavras-chave: Saúde do solo. SIG. Vegetação. Degradação do solo

ABSTRACT

Souza, Débora Pantojo de. **Susceptibility to soil degradation in dairy production areas based on the analysis of environmental covariates using geoprocessing**. 2025. 32p. Trabalho de Conclusão de Curso (Specialization in Geoprocessing, Soil Survey and Interpretation) Pró-reitoria de Extensão, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2025.

The objective of the work was to evaluate the susceptibility to soil degradation of an area with pasture-based dairy farms in Rio Grande do Sul. The study was conducted using spatial multicriteria analysis to classify areas according to the susceptibility of soil degradation, considering the relationship between environmental variables and productive data. The methodology combines the use of geotechnologies with the Analytic Hierarchy Process (AHP) method, applied to vegetation, soil, and dairy production data. The data were spatialized and processed within a Geographic Information System (GIS) environment, with criteria normalization and weight assignment by experts. The resulting classification allowed the identification of different levels within the study area, highlighting priority zones for territorial management actions, public policies, and productive sustainability. The study demonstrated the applicability of multicriteria methods as a decision support tool in agricultural planning, with a regional focus and a sound scientific basis.

Keywords: Soil Health. GIS. Vegetation. Soil degradation.

SUMÁRIO

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	2
2.1. Produção de Leite do Rio Grande do Sul e na Região de Estudo	2
2.2. Fatores Ambientais na Produção Leiteira	2
2.3. Suscetibilidade à Degradação.....	3
2.4. Índices Utilizados como Indicadores	3
2.5. Método para Classificação de Áreas	4
3. MATERIAL E MÉTODOS.....	5
4. RESULTADOS E DISCUSSÃO	15
5. CONSIDERAÇÕES FINAIS	19
6. REFERÊNCIAS BIBLIOGRÁFICAS	20
7. APÊNDICES.....	23

1. INTRODUÇÃO

As mudanças climáticas são um fenômeno global com implicações regionais e locais, caracterizadas por alterações de longo prazo nos padrões climáticos, incluindo aumento da temperatura média global, intensificação de eventos climáticos extremos, como secas e inundações, e mudanças nos regimes de precipitação. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) destaca a influência humana como o principal fator impulsionador dessas mudanças, principalmente devido à emissão de gases de efeito estufa (GEE) provenientes de atividades antrópicas (IPCC, 2023).

Na pecuária leiteira, as mudanças climáticas afetam a produção de diversas maneiras, desde o conforto térmico dos animais e a disponibilidade de recursos hídricos, tendo reflexo no solo e na vegetação, afetando na oferta de alimentos para produção animal. A pecuária leiteira no Brasil é essencial para a economia e segurança alimentar nacional, tendo como os maiores estados produtores do país: Minas Gerais, Paraná, Rio Grande do Sul, Santa Catarina, São Paulo e Goiás, produção de leite no Brasil em 2023 foi de 35 bilhões de litros de leite (IBGE, 2024).

Locais com solos mais suscetíveis a degradação torna-se um grande problema na produção de forragem para o gado leiteiro, a qual depende tanto da segurança da disponibilidade de biomassa forrageira, seja essa vinda do pastejo, silagem ou feno. Temperaturas elevadas, secas prolongadas e chuvas intensas podem prejudicar o crescimento e o desenvolvimento das pastagens, reduzindo a disponibilidade de alimento para o gado leiteiro (Barbosa, 2017; MARANHÃO, 2021). A qualidade da forragem também pode ser afetada, com redução do valor nutritivo, impactando a produção de leite e a saúde dos animais (BARBOSA, 2017).

A avaliação de áreas de produção leiteira quanto à suscetibilidade à degradação do solo torna-se instrumento essencial para a mitigação de impactos ambientais e para o planejamento sustentável e continuidade da atividade diante dos cenários críticos impostos pelas mudanças climáticas. Essas alterações são caracterizadas pelo aumento no volume e intensidade de chuva, o que causam maior volume de escoamento superficial e conseqüentemente maior perda de solo, além do maior aquecimento da superfície que gera maior taxa de decomposição do carbono orgânico, pendendo assim sua qualidade (FAO, 2015). A perda da qualidade do solo está intrinsecamente ligada à sua saúde, assim a utilização do índice de saúde do solo, o qual integra propriedades físicas, químicas e biológicas do solo (POPPIEL et al., 2025), torna-se importante fator a ser considerado, dado que solos saudáveis estão diretamente associados à maior produtividade e a resiliência frente às mudanças climáticas.

Com base nos conceitos da pedologia e suas relações com a paisagem, aliados aos de pedometria e geoprocessamento, foi utilizado o método de Análise Multicritério AHP (*Analytic Hierarchy Process*), para avaliação da suscetibilidade à degradação do solo considerando fatores e propriedades do solo importantes no contexto de produção leiteira. Assim, o objetivo desse trabalho foi classificar uma área de produção leiteira localizada no estado do Rio Grande do Sul quanto a suscetibilidade à degradação do solo a partir de fatores relacionados ao solo e a vegetação.



2. REVISÃO DE LITERATURA

2.1. Produção de Leite do Rio Grande do Sul e na Região de Estudo

O estado do Rio Grande do Sul se destaca na produção nacional, sendo o terceiro maior estado produtor, onde existem 122.079 estabelecimentos que produzem leite, porém apenas 27,05% executam atividade econômica formal e 95,08 % são enquadrados como agricultores familiares e 84% produzem em sistemas de produção à pasto com suplementação (silagem e ração) (Emater, 2025).

No sistema produtivo no estado, durante o verão são produzidas silagem de milho, milheto, sorgo forrageiro e capim sudão e pastagens perenes dos gêneros Panicum, Cynodon e Pennisetum. Durante o inverno, 90% utilizam de pastagens anuais de inverno (aveia e azevém, principalmente) (Emater, 2025).

No relatório publicado pela Emater, 2025, que analisou as mudanças entre 2015 e 2023, apontam redução de estabelecimentos produtores de leite, porém os que permaneceram observou-se aumento na produção anual, principalmente pela mudança no rebanho. Também na pesquisa realizada os produtores relatam que as principais dificuldades na produção e comercialização de leite é a insatisfação com a remuneração, seguida pelo alto custo de produção e pela escassez ou deficiência de mão de obra e a falta de sucessão familiar.

A Emater/RS possui 28 divisões regionais para o atendimento no estado (Conselhos Regionais de Desenvolvimento), a região ‘Serra’ localizada no Noroeste do estado, abrange 32 municípios, entre esses Guaporé, Montauri, Serafina Corrêa e União da Serra), a região representa 8,5% da produção anual de estabelecimentos que vendem leite cru para industrialização e a região é a maior produtora de leite com processamento em agroindústria própria (Emater, 2025).

2.2. Fatores Ambientais na Produção Leiteira

Além da genética e saúde do rebanho, a produção leiteira é fortemente influenciada por fatores ambientais que afetam tanto o bem-estar dos animais quanto a qualidade e quantidade do leite produzido. Entre os principais fatores destacam-se os elementos climáticos sob o bem-estar dos animais (COSTA et al., 2022; LEMOS et al. 2023; MORAES et al., 2020), a disponibilidade e qualidade das pastagens, o tipo de solo e os recursos hídricos, esses todos relacionados a produção de alimento para os animais. Práticas para a garantia de oferta de forragem durante todo o ano, são adoção de espécies de forrageiras mais produtivas, adubação e conservação de forragem através da silagem e feno. A qualidade das pastagens e dos seus subprodutos, está diretamente influenciada pela qualidade do solo e práticas de manejo adotados, solos pobres em nutrientes, limitam o desenvolvimento das forrageiras e impactam negativamente o valor nutritivo da dieta ofertada ao rebanho, exigindo suplementações que elevam os custos de produção.

O relevo e a topografia exercem papel determinante em sistemas baseados em pastagem. Áreas com relevo suavemente ondulado a plano são geralmente mais adequadas, pois facilitam o manejo do rebanho, a mecanização de práticas agrícolas e o estabelecimento de pastagens. Em contrapartida, áreas com declividade acentuada apresentam maiores riscos de erosão do solo e dificultam a formação de cobertura vegetal contínua e uniforme, impactando



negativamente a disponibilidade e a qualidade das forragens (PENNY et al., 2016; SOUZA et al., 2021).

A topografia também influencia diretamente os padrões de escoamento superficial e drenagem, afetando a umidade do solo, a disponibilidade de água para as plantas forrageiras e, conseqüentemente, a produtividade das pastagens. Regiões com drenagem deficiente tendem a apresentar áreas encharcadas ou compactadas, com baixa oxigenação do solo, o que compromete o desenvolvimento radicular das plantas. A drenagem também é influenciada pelas características dos solos, solos profundos, bem drenados, com boa estrutura e fertilidade natural favorecem a implantação de pastagens mais produtivas, solos rasos, pedregosos ou com baixa fertilidade química requerem manejos para viabilizar sua utilização com forrageiras.

Além desses fatores, o pastejo animal, quando não é bem conduzido, pode resultar em perdas de solo por erosão e na redução dos nutrientes disponíveis para o crescimento das plantas, além de reduzir a capacidade de retenção de água, com potencial para diminuir a produção de culturas ou pastagens (PENNY et al., 2016).

2.3. Suscetibilidade à Degradação

Segundo Jenny, 1941 o processo de formação do solo envolve os fatores relacionados ao material de origem, clima, organismos, topografia e os processos pedogenéticos que ocorrem ao longo do tempo resultando na grande diversidade de tipos de solos. No Brasil são treze ordens de solos com subordens e subgrupos que descrevem características específicas entre eles (SANTOS, et al., 2025).

Na agricultura, o solo tem a função de ser a base para o crescimento e sustentação das plantas, sendo base para a ciclagem de nutrientes e na regulação do clima, porém a intensificação de atividades antrópicas sobre o mesmo, intensifica os processos de degradação, dentre os quais são a erosão, compactação, acidificação, perda da fertilidade e desertificação. A caracterização dos solos em propriedades rurais torna-se um instrumento de gestão, uma vez que devem ser adotadas práticas de manejo em solos específicos para manutenção da sua saúde, diminuindo a suscetibilidade aos processos de degradação.

2.4. Índices Utilizados como Indicadores

Imagens de satélite e técnicas de geoprocessamento possibilitam o monitoramento da disponibilidade hídrica, identificando áreas com risco de escassez hídrica e avaliando o impacto das mudanças climáticas sobre os recursos hídricos (Maranhão, 2021; Oliveira et al. 2024; Santos et al., 2020).

Dentre os índices de vegetação, calculados a partir das bandas espectrais das imagens de satélites pode-se destacar o Índice de Vegetação Diferença Normalizada (NDVI), Índice de Vegetação Melhorado (EVI) e o Índice de Vegetação Ajustado ao Solo (SAVI), os três bastante utilizados na pesquisa e permitem monitorar a produção de forragem, avaliando o vigor vegetativo (BOLFE et al., 2023; HUETE, 1988; MARANHÃO, 2021; OLIVEIRA et al., 2024).

Dentre os Índice que avaliam água, tem-se o Índice de diferença normalizada da água (NDWI), Índice de diferença normalizada da água Modificado (MNDWI) e o índice Variante do NDWI com foco na umidade vegetal (NDWI_VEG). O NDWI é muito utilizado para



identificação de planícies de inundação (McFeeters, 1996). O NDWI_VEG foi criado por Gao, 1996 em modificação ao NDWI afim de estimar teor de água na vegetação. Já o MNDWI melhora a estimativa diminuindo o ruído causado pela cobertura do solo, em áreas que incluem sombras e superfícies escuras (XU, 2006).

A avaliação da saúde do solo é fundamental para abordar desafios como a segurança alimentar, a mitigação e adaptação às mudanças climáticas e a saúde humana, especialmente em uma região vulnerável como a LAC, onde a degradação do solo é um problema urgente (POPPIEL et al., 2025). Um índice recentemente criado pelos autores citados, o Índice de Saúde do Solo (SHI), foi utilizado para avaliar a saúde do solo em grande escala na América Latina e no Caribe (LAC). O SHI envolve 15 indicadores, incluindo atributos físicos como densidade do solo, água disponível para plantas e porosidade total; atributos químicos como pH, capacidade de troca catiônica (CTC) e nutrientes (N, P, K); e atributos biológicos como carbono (C) e estoque de C, além da densidade de minhocas e nematoides. Estes indicadores são derivados de mapas digitais de atributos do solo, utilizando o modelo SCORPAN e técnicas de sensoriamento remoto e aprendizado de máquina (algoritmo Random Forest) para mapeamento em alta resolução (POPPIEL et al., 2025).

2.5. Método para Classificação de Áreas

As técnicas de análise multicritério são abordagens valiosas utilizadas para auxiliar na tomada de decisões complexas que envolvem múltiplos critérios. Dentre elas, o *Analytic Hierarchy Process* (AHP), desenvolvido por Saaty (1988), é um dos métodos mais populares e amplamente aplicado. O AHP consiste em decompor um problema em níveis hierárquicos, comparar as alternativas em pares e transformar julgamentos subjetivos em valores numéricos objetivos para determinar a importância relativa de cada elemento, também inclui uma verificação de consistência para assegurar a coerência dos julgamentos.

Nos estudos de mapeamento de suscetibilidade ambiental, o AHP demonstrou eficácia para identificar áreas suscetíveis a erosão (CALDAS et al., 2019; LIMA et al., 2021), áreas com riscos a inundação (VARGEM, 2024), análise de riscos à degradação ambiental (FALCÃO, 2013) e suscetibilidade a movimentos de massa (MEIRELLES et al., 2018).

3. MATERIAL E MÉTODOS

3.1. Localização da Área de Estudo

A área de interesse do estudo é de cerca de 150 km² e está localizada entre os municípios de Montauri, Serafina Corrêa, União da Serra e Guaporé, no estado do Rio Grande do Sul. A área integra uma bacia leiteira com 57 produtores em sistema à pasto (Figura 1) e os dados da produção leiteira utilizados nesse trabalho são do ano de 2018 (CARRA et al., 2022).

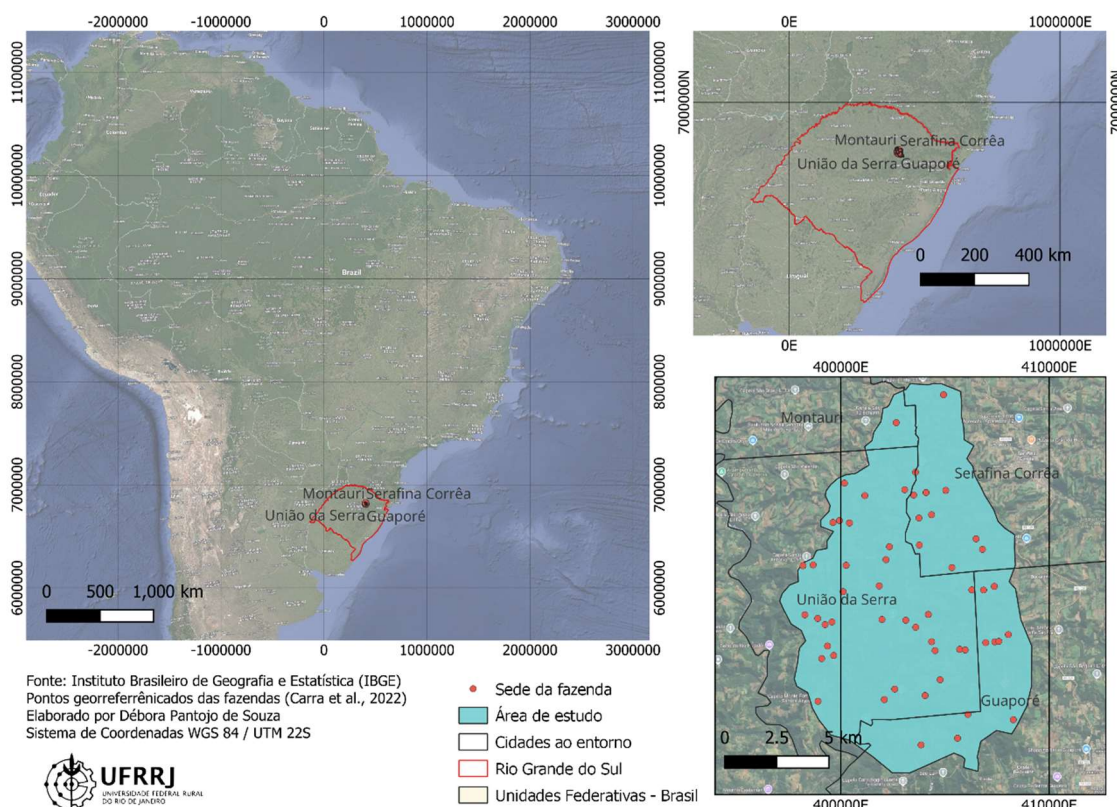


Figura 1 – Localização da área de estudo no estado do Rio Grande do Sul.

Fonte: elaborado pelo autor

A região é caracterizada pelo clima Cfa (clima subtropical úmido) pela classificação climática de Köppen (ALVARES et al., 2013) com média de Temperatura de: 12,4°C (mínima) e 24°C (máxima) e Precipitação anual 1213 mm no ano de 2018, segundo os dados obtidos a partir da base de dados climáticos em grade (XAVIER et al., 2022).

3.2. Procedimentos Metodológicos

A metodologia adotada para esse trabalho seguir o fluxograma de processos apresentado na Figura 2, o qual, baseou-se primeiramente em pesquisa bibliográfica, para selecionar e avaliar os dados disponíveis. Foram utilizados diferentes dados de entrada, como mapas pedológicos, uso e cobertura do solo, dados de produção leiteira, mapas de saúde do solo, modelo digital de terreno (incluindo declividade, altitude, curvatura de perfil e índices

topográficos de umidade entre outros), além de índices de vegetação e hídricos extraídos de imagens Landsat 8.

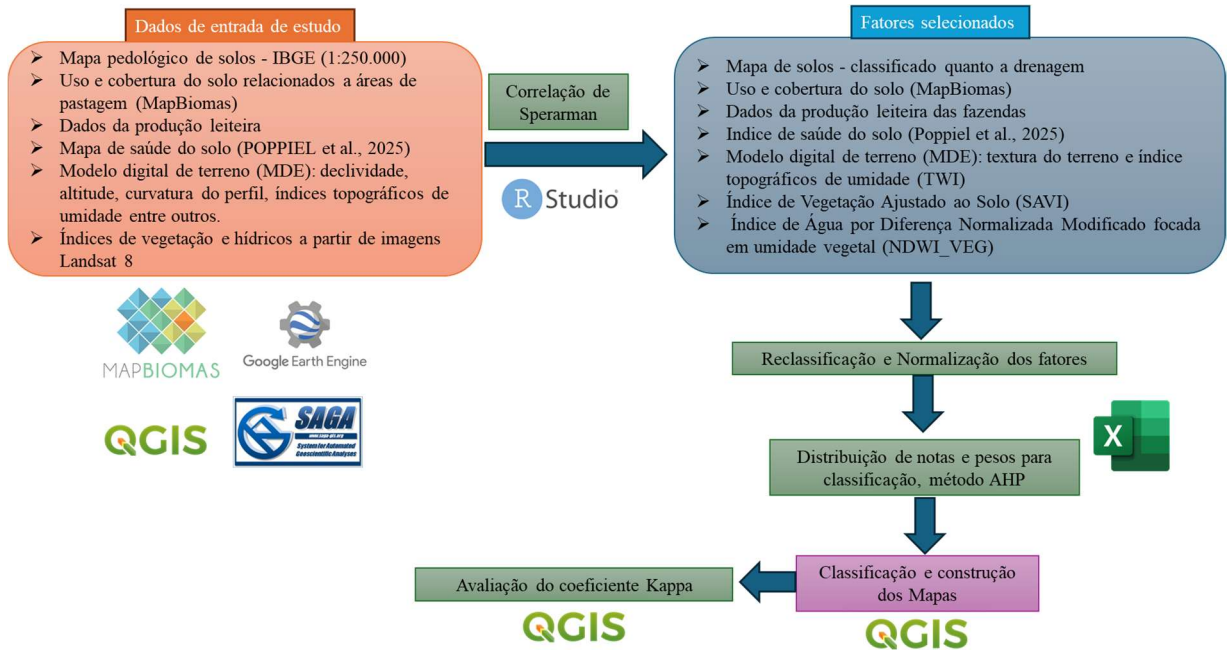


Figura 2. Fluxograma com as etapas do trabalho

Fonte: elaborado pelo autor

A partir da correlação de Spearman (SPEARMAN, 1904) dos dados de entrada estudados, foram selecionados os fatores (Tabela 2) mais relevantes a serem adotados para a classificação pelo método AHP, resultando na construção dos mapas nos dois períodos estudados (verão e inverno). Por fim, foi calculado o coeficiente Kappa, para verificar a consistência e acurácia da classificação final dos mapas.

Para a execução do trabalho foram utilizados os seguintes softwares: Quantum GIS v. 3.28 (QGIS, 2025), Saga GIS v. 7.8.2 (SAGA, 2025), RStudio versão 3.6.1 (R CORE TEAM, 2021), Google Earth Engine (GORELICK, 2017) e o Excel versão 365, as imagens de classificação do Mapbiomas foram obtidas através do site de acesso (MAPBIOMAS, 2025).

3.3. Construção do Banco de Dados Espaciais

Para esse trabalho foi realizada busca e agrupamento dos dados disponíveis a serem posteriormente selecionados como fatores na classificação. A princípio foram selecionados dados de uso e cobertura do solo, dados de vigor de pastagem e de carbono no solo (MapBiomas), mapa de saúde do solo (POPPIEL et al., 2025), modelo digital de elevação (MDE) o qual foi utilizado para extração das covariáveis (declividade, altitude, curvatura do perfil, índices topográficos de umidade entre outras) a partir do programa Saga GIS (SAGA, 2025).

Também foram extraídas as bandas espectrais a partir das imagens da coleção Landsat 8 e foram calculados os índices de vegetação e hídricos (NDVI, SAVI, EVI, NDWI, MNDWI e NDWI_Veg) utilizando programação elaborada no Google Earth Engine (GEE) (ver Apêndices A e B).

A análise da normal climatológica da área de estudo e dos dados do ano de 2018 extraídos a partir da base de dados climáticos em grade (XAVIER et al., 2022) revelaram poucas diferenças dos elementos climatológicos entre as fazendas (Tabela 1). Portanto, como a análise dos dados da área mostrou-se bastante homogênea, os dados climáticos não foram considerados como variável para a classificação.

Tabela 1 – Dados Climáticos médios entre as fazendas no ano de 2018: Precipitação (Ppt), Radiação Solar (RS), Temperatura máxima (Tmax), Temperatura mínima (Tmin) e Umidade Relativa (UR).

Comparação das fazendas	Ppt (mm)	RS (MJ dia ⁻¹)	Tmax (°C)	Tmin (°C)	UR (%)
Menor valor	1871,2	15,4	23,6	11,7	78,5
Maior valor	2155,5	15,7	24,4	13,1	78,9
Diferença	284,3	0,3	0,8	1,4	0,5
Média	2013,4	15,5	24,0	12,4	78,7

Os dados foram pré-processados para o recorte da área de estudo e padronização da resolução de 30 metros utilizando o software Quantum GIS versão 3.28 (QGIS, 2025). Os pontos georreferenciados das fazendas foram adotados para extração dos dados do Rasters. Os dados foram separados por época do ano, considerando como dados produtivos de verão, os dados de produção total de leite por fazenda nos meses de janeiro a abril e outubro a dezembro e dados produtivos de inverno nos meses de maio a setembro de 2018. Os dados de índice de vegetação e hídricos também foram extraídos considerando esses períodos. Em seguida, as covariáveis selecionadas nessa primeira etapa foram analisadas a partir da análise de correlação de Spearman (SPEARMAN, 1904) a fim de verificar quais as covariáveis possuíam maior correlação juntamente com os dados de produção de leite, e para exclusão por alta correlação utilizando o pacote Caret via o software RStudio versão 3.6.1. A identificação das variáveis é apresentada na Tabela 2.

Tabela 2 – Relação das variáveis selecionadas em primeira etapa e adotada para classificação

Variável	Interpretação	Fonte	Adotada para classificação
Mapa de solo	Mapa pedológico IBGE (1:250.000)	ANA	x
Carbono	Estoque de carbono no solo na camada de 0 a 0,3m – ano 2018	Mapbiomas	
Cobertura	Classificação de Uso e Cobertura da Terra – Coleção 9 – ano 2018	Mapbiomas	x
Desmatamento	Classificação de desmatamento – ano 2018	Mapbiomas	x



Vigor de Pastagem	Mapa com a classificação do vigor das pastagens (classificadas em 1, 2 e 3)	Mapbiomas	
GPP Pastagem	Estimativa de produtividade de Pastagem	Mapbiomas	
LAC_SHI	Índice de Saúde Hídrica do Solo (<i>Soil Health Index</i>)	Poppiel et al., 2025	x
Aspect	Exposição do Terreno		
Convexity	Convexidade do Terreno		
Curvature Flow Line	Direção do fluxo da água		
General Curvature	Curvatura Geral		
Long curvature	Curvatura longitudinal		
Max curvature	Curvatura máxima		
Mid slope position	Posição média na encosta		
Min curvature	Curvatura mínima		
Mod catchment area	Modelo de área de captação/modificação da bacia		
Mrrtf	Índice de fator de transferência de relevo modificado		
Mrvbf	Índice de base de vale modificado (<i>Multi-Resolution Valley Bottom Flatness</i>)		
Normalized Height	Altura normalizada, relativa de cada ponto em relação ao mínimo e máximo	Extraídos do Modelo Digital de Elevação (MDE) através da <i>Terrain Analysis – Morphometry</i> (SAGA)	
Plan curvature	Curvatura do plano		
Profile curvature	Curvatura do perfil		
Slope heigh	Altura da encosta ou relevo		
Slope	Inclinação (graus ou %)		
Standardized Height	Altura Padronizada		
Surface area	Área da superfície real (considerando relevo)		
Tang curvature	Curvatura tangencial		
Texture	Textura do terreno (ex: índice de rugosidade)		x
Topographic Wetness Index (TWI)	Índice topográfico geral		x
Total curvature	Curvatura total		
Valley deptpth	Profundidade de vale		
Vector Ruggedness Measure (VRM)	Rugosidade do terreno, combina inclinação (slope) e aspecto (aspect)		
NDVI	Índice de Vegetação por Diferença Normalizada (Normalized Difference Vegetation Index)	Bandas Red e NIR do Landsat8	
EVI	Índice de Vegetação Aprimorado (Enhanced Vegetation Index)	Bandas Blue Red e NIR do Landsat8	

SAVI	Índice de Vegetação Ajustado ao Solo (<i>Soil Adjusted Vegetation Index</i>)	Bandas Red e NIR do Landsat8	x
NDWI	Índice de diferença normalizada da água (<i>Normalized Difference Water Index</i>)	Bandas Green e NIR do Landsat8	
MNDWI	Índice de diferença normalizada da água Modificado (<i>Modified NDWI</i>)	Bandas Green e SWIR do Landsat8	
NDWI_VEG	Variante do NDWI focada em umidade vegetal	Bandas NIR e SWIR do Landsat8	x

As variáveis GPP Pastagem, Vigor de Pastagem, MRRTF e MRVBF foram eliminadas por apresentarem variância baixa (variância zero ou quase zero) entre os pontos amostrais das fazendas. O teste de correlação de Spearman apontou que as variáveis EVI, NDVI, *Normalized Height*, *Plan curvature*, *Surface Area*, *Slope*, *Tang Curvature* apresentaram alta correlação (>0,95), ambos os conjuntos foram removidos do banco de covariáveis para a análise da classificação.

A Figura 3 mostra a matriz de correlação de Spearman já com as covariáveis com baixa variância desconsideradas.

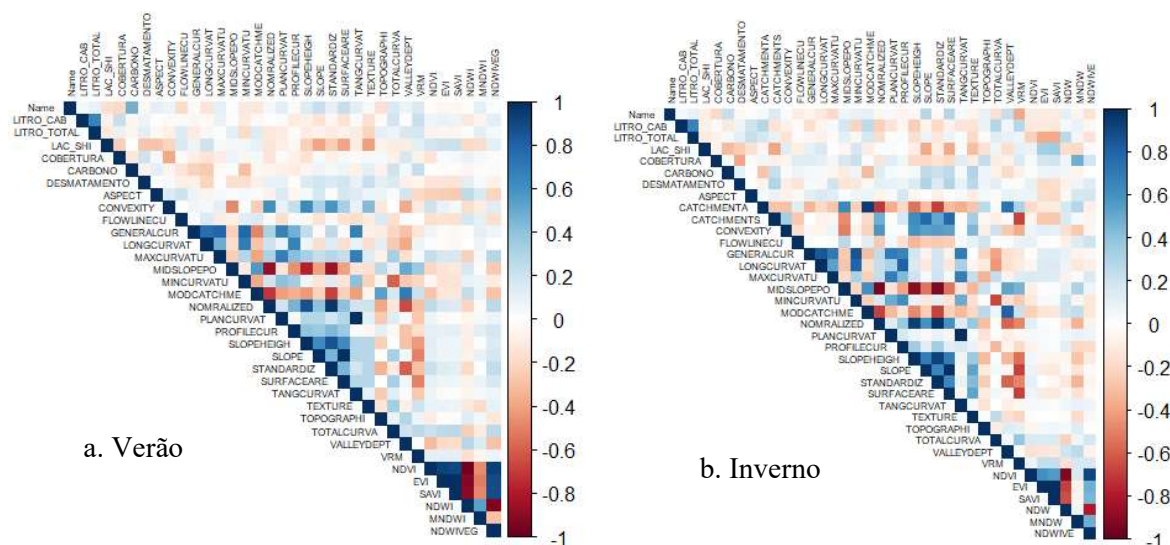


Figura 3 – Matriz de correlação de Spearman para as variáveis estudadas nos dois períodos: (a) verão, (b) inverno.

Fonte: elaborado pelo autor (2025)

3.4. Análise Multicritério AHP

Para a composição da classificação, foram selecionados os seguintes fatores: solo, cobertura, desmatamento, LAC_SHI, SAVI, NDWI_veg, TWI e Texture. Para a classificação da área foi adotado o método AHP (*Analytic Hierarchy Process*) com atribuição de pesos proposta por Saaty (1980). Como os fatores selecionados eram baseados em valores reais, foi necessária a reclassificação a qual foi baseada na interpretação de que os valores podem representar em termos de suscetibilidade a degradação, atribuindo classes de suscetibilidade de

1 a 5 (muito baixo, baixo, moderado, alto, muito alto). Após essa etapa todos os fatores foram transformados e normalizados para escala zero a 1, esse processo foi realizado utilizando as ferramentas de análise de *raster* no Quantum GIS versão 3.28.

Os dados vetoriais de produção de leite foram interpolados utilizando a ferramenta Distância Inversa Ponderada (IDW) do Quantum GIS versão 3.28 (QGIS, 2025). Os critérios utilizados para a execução da reclassificação estão apresentados na Tabela 3, os mapas com as visualizações dos fatores reclassificados estão apresentados na Figura 4.

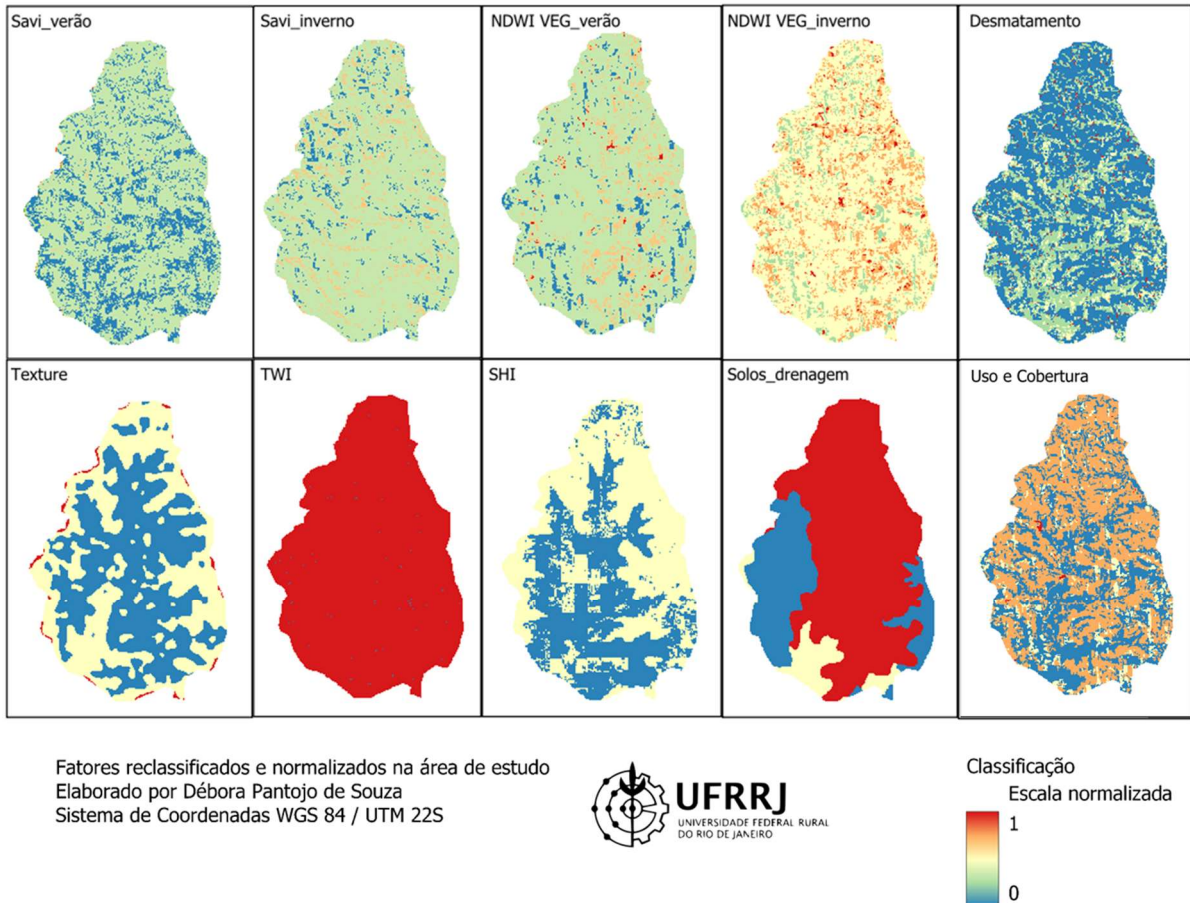


Figura 4 – Fatores reclassificados e normalizados dentro da área de estudo quanto a suscetibilidade a degradação.

Fonte: elaborado pelo autor



Tabela 3 – Fatores selecionados, características e atribuição realizada na reclassificação da área de estudo

Solos da área	Características quanto a drenagem (COSTA et al. 2017)	Suscetibilidade de degradação	Classe
Chernossolo Argilúvico Férrico	Moderadamente a imperfeitamente drenado	Alto	4
Neossolo Litólico Chernossólico	Bem a mal drenado	Médio	3
Nitossolo Bruno Alumínico	Bem drenado	Baixo	2
Uso e Cobertura da Terra (Coleção 9) - n° das classes	Características	Suscetibilidade de degradação	Classe
1, 3, 4, 5, 6, 49	Formação florestal, savânica, mangue, floresta alagável e restinga arbórea	Muito baixo	1
10, 11, 12, 29, 32, 50	Vegetação Herbácea e arbustiva	Baixo	2
9, 15, 35, 36, 46, 47, 48	Silvicultura, Pastagem, Lavoras Perenes,	Médio	3
14, 18, 19, 20, 21, 39, 40, 41, 62	Lavoura Temporária e mosaico agropecuário	Alto	4
22, 23, 24, 25, 26, 27, 30, 31, 33	Áreas não vegetadas e água	Muito alto	5
Desmatamento	Características	Suscetibilidade de degradação	Classe
1	O índice varia de 1 a 7 na escala de milhões de hectares, quando mais próximo de 7 a área apresenta maior área desmatada.	Muito Baixo	1
2		Baixo	2
3		Médio	3
4		Médio	3
5		Alto	4
6		Alto	4
7		Muito alto	5
LAC_SHI	Características	Suscetibilidade de degradação	Classe
<0,2	O índice varia de 0 a 1, quando mais próximo de 1 os solos são considerados mais saudáveis	Muito alto	5
0,2 a 0,4		Alto	4
0,4 a 0,6		Médio	3
0,6 a 0,8		Baixo	2
>0,8		Muito Baixo	1
SAVI	Interpretação	Suscetibilidade de degradação	Classe
< 0	Água, sombra, superfícies escuras	Muito alto	5



0,0 a 0,2	Solo descoberto, vegetação escassa	Alto	4
0,2 a 0,5	Vegetação média a moderada	Médio	6
0,5 a 0,8+	Vegetação densa e vigorosa	Baixo	2
>0,8	Vegetação densa e vigorosa	Muito Baixo	1
NDWI_VEG	Interpretação	Suscetibilidade de degradação	Classe
< 0	Índice negativo – possível solo seco, áreas urbanas ou vegetação esparsa	Muito alto	5
0,0 a 0,2	Baixo teor de umidade	Alto	4
0,2 a 0,5	Umidade moderada	Médio	3
0,5 a 0,8	Alta umidade	Baixo	2
>0,8	Muito alta umidade - possível encharcamento	Muito alto	1
TWI	Interpretação típica	Suscetibilidade de degradação	Classe
< 5	Áreas secas, encostas íngremes	Alto risco de erosão	4
5 – 10	Áreas de transição	Risco moderado – depende do uso do solo e cobertura vegetal	3
> 10	Áreas saturadas, fundos de vale, várzeas	Alto risco de compactação, encharcamento, perda de estrutura	4
Texture	Interpretação	Risco de degradação	Classe
0 – 2 m		Muito Baixo	1
2 – 10 m	Medida da rugosidade da superfície do terreno, quando	Baixo	2
10 – 30 m	mais rugoso, mais propenso à erosão	Médio	3
> 30 m		Alto	4

A atribuição de pesos para classificação foi realizada conforme a metodologia proposta, executada em planilha Excel, construindo-se a matriz de comparação de pares dos fatores ($n \times n$), na qual foi calculado o vetor de prioridades, conforme os pesos atribuídos aos fatores (variando de 1 – igual importância, até 9 – importância absoluta). A matriz é apresentada na Tabela 4.

Tabela 4 – Matriz de Comparação Pareada AHP

Variáveis	Uso e cobertura	SHI	SAVI	NDWI VEG	TWI	Textura	Leite	Desm.	Dren.
Uso e cobertura	1	2	2	4	5	5	6	7	7
SHI	0,5	1	6	4	2	2	3	7	7
SAVI	0,5	0,2	1	3	2	2	3	4	4
NDWI VEG	0,25	0,3	0,3	1	3	2	2	3	3
TWI	0,2	0,5	0,5	0,3	1	3	3	3	5
Textura	0,2	0,5	0,5	0,5	0,3	1	3	3	3
Leite	0,2	0,3	0,3	0,5	0,3	0,3	1	3	3
Desm.	0,1	0,1	0,3	0,3	0,3	0,3	0,3	1	3
Drenagem	0,1	0,1	0,3	0,3	0,2	0,3	0,3	0,3	1

A partir da matriz (Tabela 4), calculou-se o autovalor da matriz (λ_{max}), Índice de Consistência (CI) e o Índice de Consistência Relativo (CR), as equações estão descritas em sequência (1 a 3).

$$\lambda_{max} = \frac{\sum \frac{(D \times W)_i}{W_i}}{n} \quad (1)$$

Onde,

W – Autovetor, valor da soma de cada linha da matriz dividido pela soma total das linhas

D - Os valores da linha da matriz i comparado com os outros

$$CI = \frac{\lambda_{max} - 1}{n - 1} \quad (2)$$

Onde,

λ_{max} = maior autovalor da matriz

n = número de critérios (ordem da matriz)

Índice de Consistência Relativo (CR)

$$CR = \frac{CI}{RI} \quad (3)$$

Onde,

CI – Índice de Consistência

RI - Índice Aleatório, varia com o número de critérios, tabelado para o método, no caso de 9 critérios o valor de RI = 1,45.

O CR calculado foi de 0,0994, ou seja < 0,1, dessa forma a matriz tornou-se aceitavelmente consistente, utilizando os seguintes pesos aos fatores:

- Uso e Cobertura da Terra = 26%
- LAC_SHI= 21%
- SAVI = 13%
- TWI = 11%
- NDWI_VEG = 10%
- TEXTURE = 8%
- Produção total de Leite = 6%
- Desmatamento = 4%
- Solo-drenagem = 2%

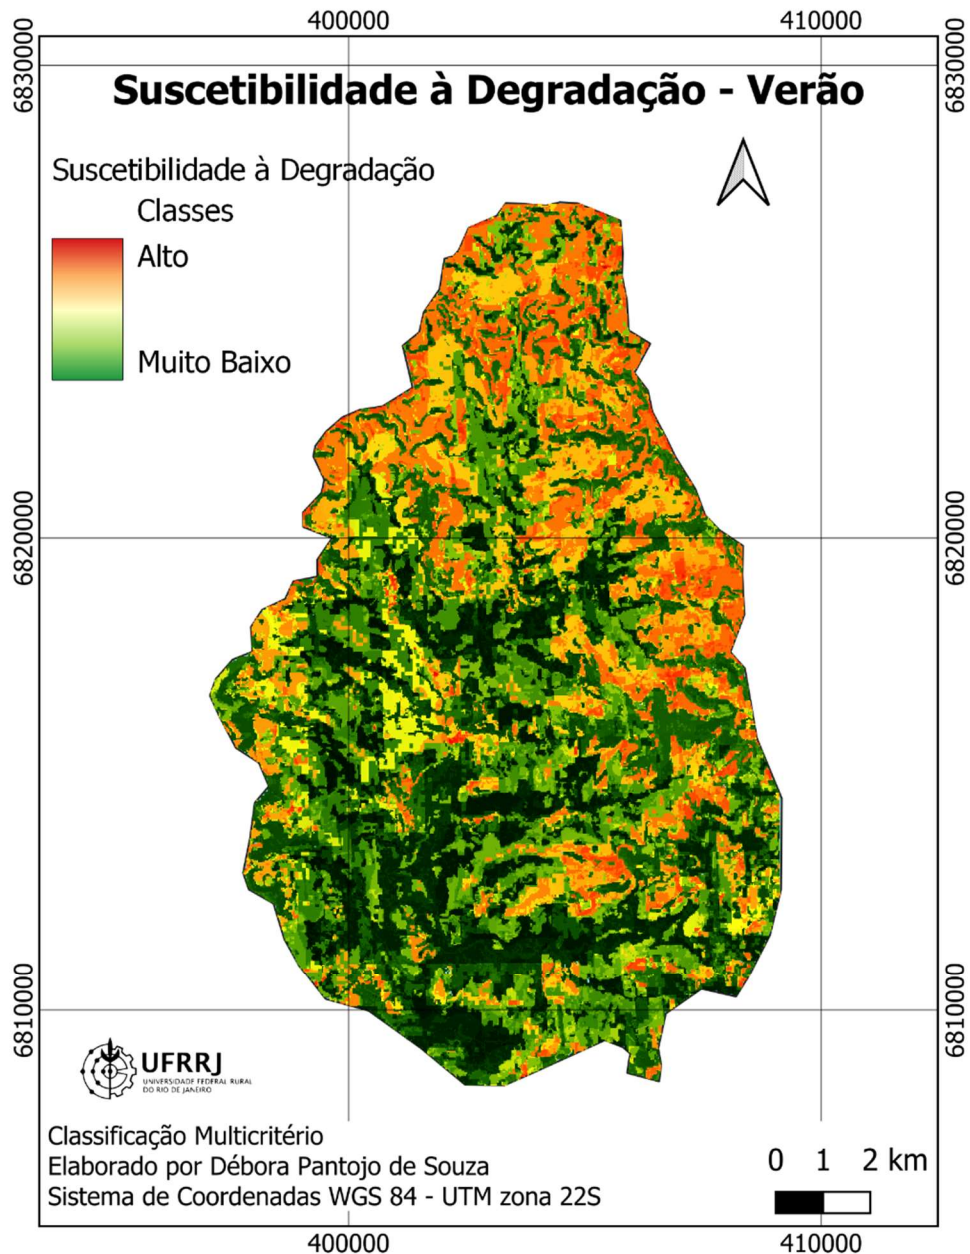
	Uso e cobertura	LAC_SHI	SAVI	NDWI	TWI	TEXTURE	Leite
Uso e cobertura	1	2	2	4	5	5	6
LAC_SHI	0.5	1	6	4	2	2	3
SAVI	0.5	0.2	1	3	2	2	3
NDWI	0.25	0.3	0.3	1	3	2	2
TWI	0.2	0.5	0.5	0.3	1	3	3
TEXTURE	0.2	0.5	0.5	0.5	0.3	1	3
Leite	0.2	0.3	0.3	0.5	0.3	0.3	1
Desmatamento	0.1	0.1	0.3	0.3	0.3	0.3	0.3
Drenagem	0.1	0.1	0.3	0.3	0.2	0.3	0.3

A classificação foi gerada a partir da calculadora Raster e a acurácia foi avaliada pelo índice Kappa com classificação de MONSERUD e LEEMANS, 1992, ambos realizados no Quantum GIS versão 3.28 (QGIS, 2025). Foi realizada a diferenciação das áreas considerando os dados analisados da seguinte forma, quanto à suscetibilidade a degradação: Alta, Moderada, Baixa e Muito Baixa, considerando as respostas quando aos cenários aplicados.



4. RESULTADOS E DISCUSSÃO

Os mapas de Suscetibilidades à degradação nas duas estações do ano, verão e inverno são apresentados na Figura 5. A classificação (clas) foi padronizada na escala de 0 a 1, sendo criadas quatro classes de Suscetibilidade: $0 < \text{clas} \leq 0,25$ (Muito baixa), $0,25 < \text{clas} \leq 0,5$ (Baixa), $0,50 < \text{clas} \leq 0,70$ (Moderada), $0,70 < \text{clas} \leq 1$ (Alta). A classificação para o período de Verão resultou em valores de 0,05 a 0,77 e no inverno de 0,13 a 0,79. Para cada classificação são apresentadas as respectivas áreas na Tabela 5.



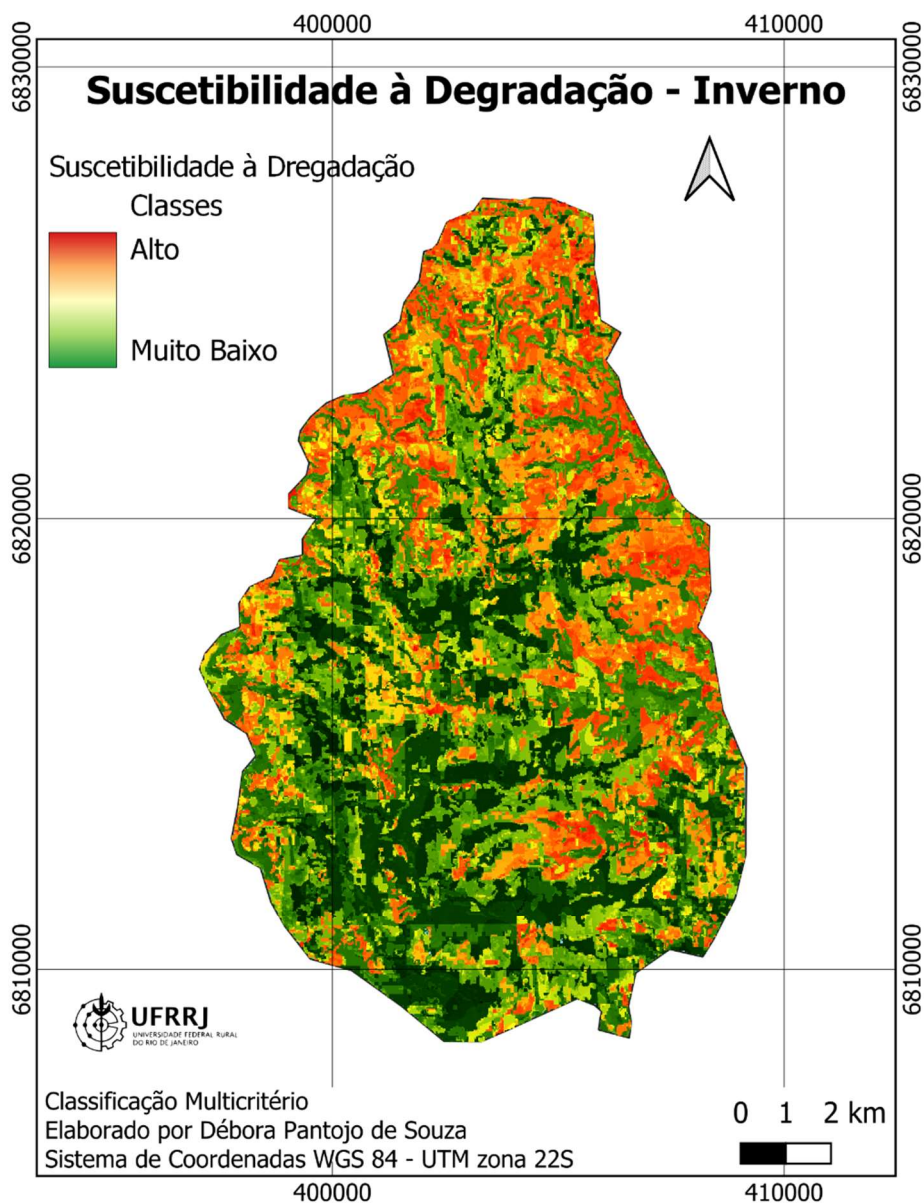


Figura 5 – Mapas de suscetibilidade à degradação nos dois períodos analisados (Verão e Inverno)

Fonte: elaborado pelo autor

Tabela 5 – Distribuição da classificação da área nos dois períodos estudados

Faixa	Verão		Inverno		Classificação
	Tamanho (km ²)	%	Tamanho (km ²)	%	
0 a 0,25	24,8	17%	14,2	10%	Muito baixa
0,25 a 0,5	95,2	64%	91,3	61%	Baixa
0,5 a 0,70	28,9	19%	43,4	29%	Moderada
0,70 a 1,0	0,02	0.01%	0,04	0,03%	Alta

A classificação de Suscetibilidade a degradação revela que a maior parte da área (> 70%) está sob suscetibilidade *Muito baixa* e *Baixa* nos dois períodos analisados, porém, durante o inverno 29% da área foi classificada como *Moderada* suscetibilidade contra 19% no verão (Tabela 5). A diferença entre os períodos é atribuída a diferença na cobertura do solo, conforme indicado pelo índice SAVI e o NDWI_VEG. Durante o período de inverno a média das imagens mostrou áreas com menores valores para esses dois índices, resultando assim em maior suscetibilidade (Figura 4), em função do menor vigor da vegetação e a menor disponibilidade hídrica para a cobertura vegetal. Essas condições contribuem para a maior susceptibilidade da área aos processos de degradação, com consequente maior área classificada como *Baixo* risco no inverno. As áreas classificadas *Moderada* a *Alta* suscetibilidade tem o SHI mais baixo com uso predominante de cultivos agrícolas (Figura 5).

Também foi avaliada a concordância da classificação, nos dois períodos, com o índice Kappa (Coeficiente Kappa de Cohen), é apresentada na Tabela 6 com as respectivas classificações segundo MONSERUD e LEEMANS, 1992.

Tabela 6 – Índice Kappa e classificação do grau de concordância entre os fatores e a classificação quanto a suscetibilidade à degradação.

Fator	Inverno		Verão	
	Kappa	Classificação	Kappa	Classificação
Uso e cobertura	0,48	Razoável	0,42	Razoável
LAC_SHI	0,53	Razoável	0,50	Razoável
SAVI	0,01	Ruim	0,01	Ruim
NDWI VEG	0,06	Muito pobre	0,18	Muito pobre
TWI	0,001	Ruim	0,001	Ruim
Texture	0,07	Muito pobre	0,08	Muito pobre
Desmatamento	-0,18	Discordância extrema	-0,18	Discordância extrema
Solo drenagem	0,07	Muito pobre	0,11	Muito pobre
Leite	0,01	Ruim	0,01	Ruim

A partir da análise dos fatores selecionados para classificação, verificou-se que “Uso e Cobertura” foi uma das variáveis com melhor desempenho (Tabela 6), consistente nas duas estações, assim a mesma deve ser mantida como principal base classificatória. Outros trabalhos utilizaram como fatores o uso e ocupação do solo com pesos de 15 a 48% (LIMA et al., 2021; MEIRELLES et al, 2018), e declividade do terreno com peso de 15 a 25 % (CALDAS et al., 2019; LIMA et al., 2021; MEIRELLES et al, 2018).

Outro fator que se mostrou com potencial para uso na classificação foi o Índice de Saúde do solo, SHI, com valor de Kappa semelhante (0,53 e 0,50) nos dois períodos analisados (Tabela 5). O NDWI VEG apresentou melhor resultado nos dados de verão com relação ao inverno. Os índices SAVI e NDWI VEG foram calculados a partir da média dos valores observados nas imagens de cada período, porém só foram encontradas nove imagens para o ano de 2018, o que pode não trazer um resultado significativo, dado as mudanças na vegetação durante o ano.



Destaca-se que Lima et al., (2021) aplicaram a análise multicritério para avaliação de vulnerabilidade à erosão, porém utilizaram o NDVI e atribuíram peso de 25%. Imagens do Sentinel 2 possuem maior resolução e podem oferecer melhor detalhamento, mas para o período avaliado foram encontrados poucas imagens e por isso adotou-se o uso do Landsat 8.

Variáveis com Kappa $< 0,050$, não têm valor explicativo significativo neste contexto, os fatores devem ser avaliados em outras áreas a fim de reavaliar a relevância para que possam ser descartados ou ainda considerados para classificação. A variável “Desmatamento” apresentou Kappa negativo, indicando que esse fator não está espacialmente alinhado com a classe de referência na área de estudo, o que pode indicar uma outra dinâmica, já que essa variável não apresentou variabilidade. Salienta-se que o Kappa mede a concordância estatística, mas não a importância prática ou causal de um fator. Assim o desmatamento pode ter baixa correlação espacial com a classe de referência, mas ser fundamental para explicar a degradação futura dos solos.

Mesmo considerando que grande parte dessa classificação, apontou áreas com *Baixa* suscetibilidade a degradação, medidas de conservação de solo devem ser adotadas para que as mesmas áreas continuem produtivas, dado que o pastejo animal e a taxa de lotação não foi considerada neste trabalho, fator esse com grande potencial e perda de solo, evitando assim que áreas principalmente classificadas como *Moderadas* avancem para estágios mais severos de degradação. O ajuste de lotação animal considerando a oferta de biomassa forrageira e a divisão da área em piquetes no pastejo rotacionado auxilia no manejo e na diminuição do pisoteio, diminuindo a compactação e resultando em quantidade adequada de resíduo vegetal após pastejo para rebrota, permanecendo que solo não fique descoberto, aumentando a infiltração de água do solo e sua fertilidade (GALINDO et al., 2020; XU et al., 2018). A divisão de áreas também favorece a terraceamento, possibilitando o correto manejo em área declivosas, diminuindo o impacto do escoamento superficial sobre o talude e garantindo sua estabilidade.

Práticas sustentáveis como o uso de pastagem em sistemas consorciados entre gramíneas e leguminosas, favorecem a manutenção de biomassa sobre o solo, oferecendo maior capacidade de suporte do pasto, melhoram a fixação de nitrogênio no solo, e melhoram o aporte nutricional proteico na dieta dos animais (DUARTE et al., 2025; SILVA et al., 2022). O manejo adequado dos dejetos da ordenha e sua reutilização com disposição controlada no solo também favorecem a fertilidade do solo. Essas práticas oferecem ao sistema produtivo leiteiro resiliência quando a degradação do solo frente às mudanças climáticas.



5. CONSIDERAÇÕES FINAIS

A avaliação da suscetibilidade à degradação em áreas de produção leiteira, a partir da integração de dados pedológicos, índices de vegetação e dados morfométricos, mostrou-se uma ferramenta eficaz para identificação de áreas prioritárias para intervenções. A metodologia adotada, baseada na classificação supervisionada com pesos definidos pelo método AHP, permitiu a geração de mapas temáticos que identificam zonas de suscetibilidade à degradação com distintos níveis de severidade, considerando as especificidades locais.

Entre os fatores analisados, o Uso e Cobertura da Terra destacou-se como o mais relevante e consistente nas duas estações do ano, apresentando os maiores valores de concordância estatística (índice Kappa $\geq 0,63$). O índice LAC_SHI, relacionado à saúde do solo, também demonstrou potencial na classificação, reforçando a importância de considerar atributos físicos e biológicos do solo em estudos de vulnerabilidade ambiental, sendo um fator a ser considerado a fim de propor práticas agrícolas para prevenção da perda de solo. Por outro lado, variáveis como SAVI, NDWI_VEG, Texture e TWI apresentaram baixo desempenho explicativo (Kappa $< 0,10$), sugerindo a necessidade de revisão de seu uso ou ajustes metodológicos, como o refinamento temporal das imagens.



6. REFERÊNCIAS BIBLIOGRÁFICAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. DE M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. doi:10.1127/0941-2948/2013/0507
- BARBOSA, V. V. Cenários de mudanças climáticas e ambiente: influência da variabilidade do clima na produção de leite do Agreste de Pernambuco, Brasil. 2017. **Dissertação** (Mestrado em Desenvolvimento e Meio Ambiente) – Universidade Federal de Pernambuco, Recife, 2017.
- BOLFE, E.; SANO, E.; MASSRUHÁ, S.; VICTORIA, D.; BAYMA, G.; OLIVEIRA, A. de. Potencial de expansão agrícola em áreas de pastagem degradadas no Brasil. **Sustentabilidade**, 2023.
- CALDAS, V. I. S.; SILVA, A. S. da; SANTOS, J. P. C. Suscetibilidade à erosão dos solos da Bacia Hidrográfica Lagos – São João, no estado do Rio de Janeiro – Brasil, a partir do método AHP e análise multicritério. **Revista Brasileira de Geografia Física**, v. 12, n. 4, p. 1415–1430, 2019. DOI: 10.26848/rbgf.v12.4.p1415-1430.
- CARRA, S. H. Z.; PALHARES, J. C. P.; DRASTIG, K.; SCHNEIDER, V. E.; EBERT, L.; GIACOMELLO, C. P. Water productivity of milk produced in three different dairy production systems in Southern Brazil. **Science of The Total Environment**, v. 844, p. 157117, 2022. Disponível em: <https://doi.org/10.1016/j.scitotenv.2022.157117>.
- COSTA, A. M. da; VIANA, J. H. t M.; EVANGELISTA, L. P.; CARVALHO, D. C. de; PEDRAS, K. I. C.; HORTA, I. de M.; SALIS, H. H. de C.; PEREIRA, M. P. R.; SAMPAIO, J. L. D. Ponderação de variáveis ambientais para determinação do potencial de uso conservacionista para o Estado de Minas Gerais. **Geografias**, Belo Horizonte, v. 13, n. 1, p. 118–133, jan./jun. 2017.
- COSTA, T. C.; MARTINS, J. T. da S.; SILVA, P. do S. C. da; LEÃO, J. J. B.; GATTI, V. C. do M.; SILVA, M. O.; SOUZA, J. F. M. de; SILVA, C. R. da; SILVA, V. F. A.; SILVA, P. A. Inovações tecnológicas no manejo da pastagem e do pastejo frente às perspectivas de mudanças climáticas. **Research, Society and Development**, v. 11, n. 4, e28211426472, 2022. DOI: <http://dx.doi.org/10.33448/rsd-v11i4.26472>.
- DUARTE, A. C. S.; OLIVEIRA, J. de C. de; OLIVEIRA, W. R. de; FREITAS, I. C. de; CARDOSO, Á. de Sá; COUTO, A. J. S.; MATRANGOLO, W. J. R.; SILVA, K. T. da; PEGORARO, R. F.; FRAZÃO, L. A. Restoring Soil health with legume-based integrated farming systems. **Sustainability**, v. 17, n. 8, p. 3340, 2025. DOI: 10.3390/su17083340.
- EMATER/RS-ASCAR. **Relatório socioeconômico da cadeia produtiva do leite no Rio Grande do Sul**: 2023. Porto Alegre: Emater/RS-Ascar; 2025. 166 p.
- FALCÃO, Ermano Cavalcante. Análise de riscos à degradação ambiental utilizando avaliação multicritério espacial, no município de Boa Vista-PB. **Tese** (Doutorado em Engenharia Agrícola) – Universidade Federal de Campina Grande, Campina Grande/PB, 2013.
- FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **Status of the World's Soil Resources: Technical Summary**. Roma, 2015. Disponível em: <https://openknowledge.fao.org/items/24649fa9-93f9-4120-8ec4-0d2b960d90ca>. Acesso em: 30 de junho de 2025.
- GALINDO, F. S.; DELATE, K.; HEINS, B.; PHILLIPS, H.; SMITH, A.; PAGLIARI, Paulo H. Cropping system and rotational grazing effects on soil fertility and enzymatic activity in an integrated organic crop-livestock system. **Agronomy**, v. 10, n. 6, p. 803, 5 jun. 2020. DOI: 10.3390/agronomy10060803



GAO, B.C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, v. 58, n.3, 257-266, 1996.

GORELICK, N., HANCHER, M.; DIXON, M.; ILYUSHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988. DOI: 10.1016/0034-4257(88)90106-X

IPCC. **Mudanças Climáticas 2023: Relatório Síntese**. Genebra: IPCC, 2023.

JENNY, H. **Factors of Soil Formation: A System of Quantitative Pedology**. New York: McGraw-Hill, 1941.

LEMOS, M. J. de. Efeito climático sobre a produção de leite de vacas Guzerá criadas em dois ambientes diferentes. **Brazilian Journal of Animal and Environmental Research**, Curitiba, v. 6, n. 2, p. 1721-1726, abr./jun. 2023. DOI: 10.34188/bjaerv6n2-062.

LIMA, M. T. V.; OLIVEIRA, C. W.; MOURA-FÉ, M. M.. Análise multicritério em geoprocessamento como contribuição ao estudo da vulnerabilidade à erosão no estado do Ceará. **Revista Brasileira de Geografia Física**, v. 14, n. 5, p. 3156–3172, 2021. DOI: 10.26848/rbgf.v14.5.p3156-3172. ISSN 1984-2295.

MAPBIOMAS. Projeto MapBiomass – Coleção 9: Dados de cobertura e uso da terra do Brasil do ano 2018. MapBiomass, 2025. Disponível em: <https://mapbiomas.org/>

MARANHÃO, S. R. Modelagem de sistemas aplicada à produção de forragem e ao uso da água, nas condições atuais e sob mudanças climáticas, no semiárido brasileiro. 2021. **Dissertação** (Mestrado em Zootecnia) - Programa de Pós-Graduação em Zootecnia, Universidade Federal do Ceará, Fortaleza, 2021.

McFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, 17(7), 1425–1432, 1996. <https://doi.org/10.1080/01431169608948714>

MEIRELLES, E. de O.; DOURADO, F.; COSTA, V. C. da. Análise multicritério para mapeamento da suscetibilidade a movimentos de massa na bacia do rio Paqueta-RJ. **GeoUERJ**, Rio de Janeiro, n. 33, e26037, 2018. DOI: 10.12957/geouerj.2018.26037.

MONSERUD, R. A. e LEEMANS, R. Comparing global vegetation maps with the Kappa statistic. **Ecological modelling**, v. 62, n.4, p. 275-293, 1992.

MORAES, E. R. de; ISHIHARA, J. H.; SOUZA, D. E. S. e. Efeito do bem-estar e conforto térmico na produção pecuária: uma revisão bibliográfica. **Research, Society and Development**, v. 9, n. 9, e921997913, 2020. DOI: 10.33448/rsd-v9i9.7913

OLIVEIRA, W.; SOUZA, P.; ASSUNÇÃO, J. **O impacto do crédito do Programa ABC para a recuperação de pastagens: Evidências para o Cerrado**. Rio de Janeiro: Climate Policy Initiative, 2024. Disponível em: bit.ly/RecuperacaoDePastagens. Acesso em: 07 jan. 2025

PENNY, V.M., ALMOND, P.C., LAURENSEN, S., & KLIK, A. The effects of hillslope forage crop grazing in winter on soil erosion. **NZGA Research and Practice Series**, 16, 2016. DOI: 10.33584/rps.16.2016.3228

POPPIEL, R. R.; CHERUBIN, M. R.; NOVAIS, J. J. M.; DEMATTÊ, J. A. M. Soil health in Latin America and the Caribbean. **Communications Earth & Environment**, v. 6, n. 141, 2025. Disponível em: <https://doi.org/10.1038/s43247-025-02021-w>.



QGIS DEVELOPMENT TEAM. QGIS Geographic Information System. Open Source Geospatial Foundation Project, 2025. Disponível em: <https://qgis.org/>

R Core Team. **R: A Language and Environment for Statistical Computing**; R Foundation for Statistical Computing: Vienna, Austria, 2021

SAATY, T.L. **The Analytic Hierarchy Process**. McGraw-Hill, New York, 1980.

SAGA, System for Automated Geoscientific Analyses (SAGA) – Version 7.8.2, 2025. Disponível em: <http://www.saga-gis.org/>

SANTOS, H. G. dos; JACOMINE, P. K. T.; ANJOS, L. H. C. dos; OLIVEIRA, V. A. de; LUMBRERAS, J. F.; COELHO, M. R.; ALMEIDA, J. A. de; ARAUJO FILHO, J. C. de; LIMA, H. N.; MARQUES, F. A.; OLIVEIRA, J. B. de; CUNHA, T. J. F. **Sistema Brasileiro de Classificação de Solos**. 6. ed. Brasília, DF: Embrapa Solos, 2025. 393 p.

SILVA, L. S.; LAROCA, J. V. dos S.; COELHO, A. P.; GONÇALVES, E. C.; GOMES, R. P.; PACHECO, L. P.; CARVALHO, P. C. de F.; PIRES, G. C.; OLIVEIRA, R. L.; SOUZA, J. M. A. de; FREITAS, C. M.; CABRAL, C. E. A.; WRUCK, F. J.; SOUZA, E. D. de. Does grass-legume intercropping change soil quality and grain yield in integrated crop-livestock systems? **Applied Soil Ecology**, v. 170, p. 104257, fev. 2022. DOI: 10.1016/j.apsoil.2021.104257.

SOUZA, L. D.; SOUZA, L. da S.; XAVIER, F. A. da S. **Aptidão agrícola do solo**. In: BORGES, A. L. (Ed.). **Recomendações de calagem e adubação para abacaxi, acerola, banana, citros, mamão, mandioca, manga e maracujá**. Brasília, DF: Embrapa, 2021. Cap. 2, p. 27-49. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1134660/1/cap2-livro-RecomendacaoCalagemAdubacao-AnaLuciaBorges-AINFO.pdf>. Acesso em: 30 junho 2025

SPEARMAN, C. The proof and measurement of association between two things. **The American Journal of Psychology**, v. 15, n. 1, p. 72–101, 1904. DOI: <https://doi.org/10.2307/1412159>.

VARGEM, M. C. Identificação de áreas susceptíveis a inundações em Sorocaba usando GIS e análise multicritério. 2024. 55 f. **Trabalho de Conclusão de Curso** (Bacharelado em Engenharia Ambiental) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Ciência e Tecnologia de Sorocaba, Sorocaba, 2024.

XAVIER, A. C.; SCANLON, B. R.; KING, C. W.; ALVES, A. I. New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, 42(16), 8390–8404, 2022. <https://doi.org/10.1002/joc.7731>

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, 27(14), 3025–3033, 2006. <https://doi.org/10.1080/01431160600589179>

XU, S.; JAGADAMMA, S.; ROWNTREE, J. Response of grazing land soil health to management strategies: A summary review. **Sustainability**, v. 10, n. 12, p. 4769, dez. 2018. DOI: 10.3390/su10124769



7. APÊNDICES

Apêndice A – Código para Exportação dos índices de vegetação – Google Earth Engine

//Gráficos

//Referência: <https://developers.google.com/earth-engine/guides>

//Definindo a área de estudo

```
var area_estudo = ee.FeatureCollection('projects/ee-deborapdsouza/assets/area_regiaodados')
```

```
var empty = ee.Image().byte();
```

```
var contorno = empty.paint({  
  featureCollection: area_estudo,  
  color: 1,  
  width: 2  
});
```

```
Map.addLayer(contorno, {palette: 'Blue'}, 'area_estudo');
```

```
//Map.setOptions('HYBRID')
```

```
Map.centerObject(area_estudo,8)
```

/******Aplicando uma máscara de nuvens na coleção landsat******/

```
function maskL8sr(image){
```

```
  // Bit 0 - Fill
```

```
  // Bit 1 - Dilated Cloud
```

```
  // Bit 2 - Cirrus
```

```
  // Bit 3 - Cloud
```

```
  // Bit 4 - Cloud Shadow
```

```
  // Bit 5 - Snow
```

```
  var qaMask = image.select(['QA_PIXEL']).bitwiseAnd(parseInt('111111', 2)) //analisar  
  .eq(0) //2 = Unused //eq = 0 condições claras
```

```
  var saturationMask = image.select("QA_RADSAT").eq(0) //Radiometric saturation QA
```

```
  // Apply the scaling factors to the appropriate bands
```

```
  var opticalBands = image.select("SR_B.").multiply(0.0000275).add(-0.2)
```

```
  var thermalBands = image.select("ST_B.*").multiply(0.00341802).add(149.0)
```

```
  // Replace the original bands with the scaled ones and apply the masks.
```

```
  return image
```

```
    .addBands(opticalBands, null, true)
```



```
//.addBands(thermalBands, null, true)
.updateMask(qaMask)
.updateMask(saturationMask)
.copyProperties(image, image.propertyNames()) //copia a propriedade da coleção
}

/*****Importando coleção Landsat 8*****/
var l8 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
    .filterDate('2018-01-01','2018-04-30')
    .filterBounds(area_estudo)
    .filter(ee.Filter.lt('CLOUD_COVER',5))
    .map(maskL8sr)

print('1 - Coleção Landsat 8', l8)
print('2 - Quantas imagens estou utilizando?',l8.size())

//Adicionando Layers
Map.addLayer(l8.median().clip(area_estudo),{bands: ['SR_B4', 'SR_B3', 'SR_B2'], min: 0.0081, max:
0.19},'L8')

/*****Índices para coleção
*****/
function indices (image) {
//Índices de Vegetação
var ndvi = image.normalizedDifference(['SR_B5', 'SR_B4']).rename('NDVI');// Rouse 1973

var evi = image.expression('2.5 * ((N - R) / (N + (6 * R) - (7.5 * B) + 1))',
{ //Huete 2002
'N': image.select('SR_B5'), 'R': image.select('SR_B4'), 'B': image.select('SR_B2')}).rename('EVI');

var savi = image.expression('(1 + L ) * float(nir - red)/ (nir + red + L)',{ 'nir': image.select('SR_B5'),
'red': image.select('SR_B4'),'L':1}).rename('SAVI');

return image.addBands([ndvi,evi,savi]).clipToCollection(area_estudo)
    .copyProperties(image, image.propertyNames())
    .set('date', image.date().format('YYYY-MM-dd'))
}
```



```

/*****Aplicando os índices na
coleção*****/
var l8_indices = ee.select("SR_B.").map(indices) //bandas B
print('3 - Landsat 8 índices', l8_indices)
print('4 - Nº Landsat 8 índices?',l8_indices.size())

/*****Aplicando os índices a
coleção*****/
//As bandas dos índices foram adicionadas a coleção landsat?
var image = ee.Image(l8_indices.median())
var bandNames = image.bandNames();
print('5 - Bandas',bandNames)

//Aplique um redutor a cada elemento de uma coleção, usando os seletores fornecidos para determinar
as entradas.
//Retorna um dicionário de resultados, codificado com os nomes de saída.
var range = l8_indices.reduceColumns(ee.Reducer.minMax(), ["system:time_start"])
print('6 - Intervalo de datas: ', ee.Date(range.get('min')), ee.Date(range.get('max'))))

/*****Adicionando
Layers*****/
Map.addLayer(l8_indices.select('NDVI').median(), {min: -0.36, max: 0.90,
palette: ['red','orange','yellow','green'] }, 'NDVI',0)

Map.addLayer(l8_indices.select('EVI').median(), {min: -0.06, max: 0.56,
palette: ['red','orange','yellow','green'] }, 'EVI',0)

Map.addLayer(l8_indices.select('SAVI').median(), {min: -0.06, max: 0.56,
palette: ['red','orange','yellow','green'] }, 'SAVI',0)

var spectral = require("users/dmlmont/spectral:spectral");

var ndvi_median = l8_indices.select('NDVI').median().clip(area_estudo);

Export.image.toDrive({
image: ndvi_median,
description: 'NDVI_median_Landsat8_2018',

```



```
folder: 'GEE_Exports',
fileNamePrefix: 'NDVI_L8_2018',
region: area_estudo.geometry(),
scale: 30,
crs: 'EPSG:4326',
maxPixels: 1e13
});

var evi_median = l8_indices.select('EVI').median().clip(area_estudo);
var savi_median = l8_indices.select('SAVI').median().clip(area_estudo);

Export.image.toDrive({
  image: evi_median,
  description: 'EVI_median_Landsat8_2018',
  folder: 'GEE_Exports',
  fileNamePrefix: 'EVI_L8_2018',
  region: area_estudo.geometry(),
  scale: 30,
  crs: 'EPSG:4326',
  maxPixels: 1e13
});

Export.image.toDrive({
  image: savi_median,
  description: 'SAVI_median_Landsat8_2018',
  folder: 'GEE_Exports',
  fileNamePrefix: 'SAVI_L8_2018',
  region: area_estudo.geometry(),
  scale: 30,
  crs: 'EPSG:4326',
  maxPixels: 1e13
});

var ndvi_s2 = S2.select('NDVI');
```



Apêndice B – Código para Exportação dos índices de hídricos - Google Earth Engine

//Gráficos

//Referência: <https://developers.google.com/earth-engine/guides>

//Definindo a área de estudo

```
var area_estudo = ee.FeatureCollection('projects/ee-deborapdsouza/assets/area_regiaodados')
```

```
var empty = ee.Image().byte();
```

```
var contorno = empty.paint({  
  featureCollection: area_estudo,  
  color: 1,  
  width: 2  
});
```

```
Map.addLayer(contorno, {palette: 'Blue'}, 'area_estudo');
```

```
//Map.setOptions('HYBRID')
```

```
Map.centerObject(area_estudo,8)
```

```
/******Aplicando uma máscara de núvens na coleção landsat******/
```

```
function maskL8sr(image){
```

```
  // Bit 0 - Fill
```

```
  // Bit 1 - Dilated Cloud
```

```
  // Bit 2 - Cirrus
```

```
  // Bit 3 - Cloud
```

```
  // Bit 4 - Cloud Shadow
```

```
  // Bit 5 - Snow
```

```
  var qaMask = image.select(['QA_PIXEL']).bitwiseAnd(parseInt('111111', 2)) //analisar  
    .eq(0) //2 = Unused //eq = 0 condições claras
```

```
  var saturationMask = image.select("QA_RADSAT").eq(0) //Radiometric saturation QA
```

```
  // Apply the scaling factors to the appropriate bands
```

```
  var opticalBands = image.select("SR_B.").multiply(0.0000275).add(-0.2)
```

```
  var thermalBands = image.select("ST_B.*").multiply(0.00341802).add(149.0)
```

```
  // Replace the original bands with the scaled ones and apply the masks.
```



```
return image
    .addBands(opticalBands, null, true)
    //addBands(thermalBands, null, true)
    .updateMask(qaMask)
    .updateMask(saturationMask)
    .copyProperties(image, image.propertyNames()) //copia a propriedade da coleção
}

/*****Importando coleção Landsat 8*****/
// Coleta das imagens dos dois períodos separadamente
var l8_perodo1 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
    .filterDate('2018-01-01','2018-04-30')
    .filterBounds(area_estudo)
    .filter(ee.Filter.lt('CLOUD_COVER', 5))
    .map(maskL8sr);

var l8_perodo2 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
    .filterDate('2018-10-01','2018-12-31')
    .filterBounds(area_estudo)
    .filter(ee.Filter.lt('CLOUD_COVER', 5))
    .map(maskL8sr);

// Unir as duas coleções
var l8 = l8_perodo1.merge(l8_perodo2);

print('1 - Coleção Landsat 8', l8)
print('2 - Quantas imagens estou utilizando?',l8.size())

//Adicionando Layers
Map.addLayer(l8.median().clip(area_estudo),{bands: ['SR_B4', 'SR_B3', 'SR_B2'], min: 0.0081, max:
0.19},'L8')

/*****Índices para coleção
*****/

function indices (image) {

    //Índices de Água
    var ndwi = image.normalizedDifference(['SR_B3', 'SR_B5']).rename ('NDWI'); //Mc Feeters 1996
```



```
var ndwi_veg = image.normalizedDifference(['SR_B5', 'SR_B6']).rename('NDWI_VEG'); //Gao 1996
var mndwi = image.normalizedDifference(['SR_B3', 'SR_B6']).rename('MNDWI'); // Xu 2006

return image.addBands([ndwi,ndwi_veg,mndwi]).clipToCollection(area_estudo)
    .copyProperties(image, image.propertyNames())
    .set('date', image.date().format('YYYY-MM-dd'))
}

/*****Aplicando os índices na coleção*****/
var l8_indices = l8.select("SR_B.").map(indices) //bandas B
print('3 - Landsat 8 índices', l8_indices)
print('4 - Nº Landsat 8 índices?',l8_indices.size())

/*****Aplicando os índices a coleção*****/
//As bandas dos índices foram adicionadas a coleção landsat?
var image = ee.Image(l8_indices.median())
var bandNames = image.bandNames();
print('5 - Bandas',bandNames)

//Aplique um redutor a cada elemento de uma coleção, usando os seletores fornecidos para determinar as entradas.
//Retorna um dicionário de resultados, codificado com os nomes de saída.
var range = l8_indices.reduceColumns(ee.Reducer.minMax(), ["system:time_start"])
print('6 - Intervalo de datas: ', ee.Date(range.get('min')), ee.Date(range.get('max'))))

/*****Adicionando Layers*****/
Map.addLayer(l8_indices.select('NDWI_VEG').median(), {min: -0.14, max: 0.75,
    palette: ['white','gray','cyan','blue'] }, 'NDWI_VEG',0)

Map.addLayer(l8_indices.select('NDWI').median(), {min: -0.84, max: 0.38,
    palette: ['white','gray','cyan','blue'] }, 'NDWI',0)

Map.addLayer(l8_indices.select('MNDWI').median(), {min: -0.64, max: 0.65,
    palette: ['white','gray','cyan','blue'] }, 'MNDWI',0)

var NDWIVEG_median = l8_indices.select('NDWI_VEG').median().clip(area_estudo);
```



```
var NDWI_median = l8_indices.select('NDWI').median().clip(area_estudo);  
var MNDWI_median = l8_indices.select('MNDWI').median().clip(area_estudo);
```

```
Export.image.toDrive({  
  image: NDWIVEG_median,  
  description: 'NDWI_VEG_median_Landsat8_2018',  
  folder: 'GEE_Exports',  
  fileNamePrefix: 'NDWI_VEG_L8_2018',  
  region: area_estudo.geometry(),  
  scale: 30,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```

```
Export.image.toDrive({  
  image: NDWI_median,  
  description: 'NDWI_median_Landsat8_2018',  
  folder: 'GEE_Exports',  
  fileNamePrefix: 'NDWI_L8_2018',  
  region: area_estudo.geometry(),  
  scale: 30,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```

```
Export.image.toDrive({  
  image: MNDWI_median,  
  description: 'MNDWI_median_Landsat8_2018',  
  folder: 'GEE_Exports',  
  fileNamePrefix: 'MNDWI_L8_2018',  
  region: area_estudo.geometry(),  
  scale: 30,  
  crs: 'EPSG:4326',  
  maxPixels: 1e13  
});
```



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DO RIO DE
JANEIRO
COORDENADORIA DE EDUCAÇÃO A DISTÂNCIA



ATA Nº 3539/2025 - CEAD (12.28.01.36)

Nº do Protocolo: 23083.039587/2025-36

Seropédica-RJ, 21 de julho de
2025.

ATA DE DEFESA

Aos dezoito dias do mês de julho do ano de dois mil e vinte e cinco, às dez horas, através de web conferência, instalou-se a banca examinadora de Trabalho de Conclusão do Curso de Especialização em Geoprocessamento, Levantamento e Interpretação de Solos, da cursista **Débora Pantojo de Souza**, sob a orientação da professora **Lúcia Helena Cunha dos Anjos**. A banca examinadora foi composta pelos pesquisadores **Max Paulo Rocha Pereira** e **Amanda Sales Alves**. A defesa do TCC intitulado "**Classificação de Área de Produção Leiteira a partir de Covariáveis Ambientais, Índices de Vegetação, Hídrico e de Saúde do Solo**", foi iniciada às dez horas e teve a duração de vinte minutos de apresentação seguida da avaliação pela banca. A cursista, após avaliada pela banca examinadora obteve o resultado:

(X) APROVADA, devendo a cursista proceder a eventual revisão solicitada pela supervisora e /ou pela banca, e entregar a versão final em até 15 dias à coordenação do Curso.

Seropédica, 18 de julho de 2025

Max Paulo Rocha Pereira

Primeiro Examinador

Amanda Sales Alves

Segunda Examinadora

Lúcia Helena Cunha dos Anjos

Presidente

Débora Pantojo de Souza

Cursista

(Assinado digitalmente em 21/07/2025 13:12)

LÚCIA HELENA CUNHA DOS ANJOS
PROFESSOR DO MAGISTERIO SUPERIOR DeptS (12.28.01.00.00.33)
Matricula: ###73#5

(Assinado digitalmente em 21/07/2025 20:48)

AMANDA SALES ALVES
DISCENTE



Matricula: 2022#####5

(Assinado digitalmente em 21/07/2025 13:29)

MAX PAULO ROCHA PEREIRA
ASSINANTE EXTERNO CPF: ###.###.486-##

(Assinado digitalmente em 21/07/2025 13:49)

DÉBORA PANTOJO DE SOUZA
DISCENTE
Matricula: 2024#####0

Visualize o documento original em <https://sipac.ufrj.br/public/documentos/index.jsp> informando seu número:
3539, ano: **2025**, tipo: **ATA**, data de emissão: **21/07/2025** e o código de verificação: **6fa9a8983b**