

UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO DEPARTAMENTO DE ENGENHARIA AGRÍCOLA PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

MODELAGEM ESPAÇO-TEMPORAL DA VULNERABILIDADE DA TERRA E SUA INFERÊNCIA NAS BACIAS LEITEIRAS DOS ESTADOS DE PERNAMBUCO E ALAGOAS

RECIFE – PE 2023

JÉSSICA BRUNA ALVES DA SILVA

MODELAGEM ESPAÇO-TEMPORAL DA VULNERABILIDADE DA TERRA E SUA INFERÊNCIA NAS BACIAS LEITEIRAS DOS ESTADOS DE PERNAMBUCO E ALAGOAS

Dissertação apresentada à Universidade Federal Rural de Pernambuco como parte dos requisitos do Programa de Pós-Graduação em Engenharia Agrícola para obtenção do título de Mestre em Engenharia Agrícola.

Área de Concentração: Engenharia de Água e Solo **Orientador:** Prof. Dr. Gledson Luiz Pontes de Almeida

RECIFE – PE 2023

Dados Internacionais de Catalogação na Publicação Universidade Federal Rural de Pernambuco Sistema Integrado de Bibliotecas Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

 Silva, Jéssica Bruna Alves da MODELAGEM ESPAÇO-TEMPORAL DA VULNERABILIDADE DA TERRA E SUA INFERÊNCIA NAS BACIAS LEITEIRAS DOS ESTADOS DE PERNAMBUCO E ALAGOAS: Dissertação de Mestrado / Jéssica Bruna Alves da Silva. - 2023. 163 f. : il.

> Orientador: Gledson L. Pontes de Almeida. Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Engenharia Agrícola, Recife, 2023.

1. Água. 2. Caatinga. 3. Geoprocessamento. 4. Pastagens. 5. Semiárido. I. Almeida, Gledson L. Pontes de, orient. II. Título

CDD 630

JÉSSICA BRUNA ALVES DA SILVA

MODELAGEM ESPAÇO-TEMPORAL DA VULNERABILIDADE DA TERRA E SUA INFERÊNCIA NAS BACIAS LEITEIRAS DOS ESTADOS DE PERNAMBUCO E ALAGOAS

Dissertação apresentada a Universidade Federal Rural de Pernambuco como parte dos requisitos para obtenção do grau de Mestre em Engenharia Agrícola. Sob a orientação do Prof. Dr. Gledson Luiz Pontes de Almeida

Dissertação Defendida e Aprovada em 28 de fevereiro de 2023

BANCA EXAMINADORA

Prof. Dr. Gledson Luiz Pontes de Almeida (Orientador) Universidade Federal Rural de Pernambuco (UFRPE)

Prof. Dr. Héliton Pandorfi (Examinador Interno) Universidade Federal Rural de Pernambuco (UFRPE)

Prof. Dr. Pedro Rogerio Giongo (Examinador Externo) Universidade Estadual de Goiás (UEG)

Prof. Dr. José Francisco de Oliveira Júnior (Examinador Externo) Universidade Federal de Alagoas (UFAL)

RECIFE-PE 2023

O meu combustível pra continuar Jesus é a calmaria, o aconchego dos meus dias O meu alicerce pra não desistir Não tá sendo fácil aqui, mas eu tenho que seguir

Tá tão complicado, Pai Eu confesso, eu tô cansado e não quero mais Tô exausto e com medo

> Tem dias que o peito aperta Tem dias que o fardo pesa Nem que for se arrastando Eu não volto pra trás Fica aqui comigo e não sai mais

És o meu alívio Tudo o que eu preciso bem aqui comigo pra eu continuar Que me impulsiona todos os dias pra eu não parar Tu és o motivo, Jesus, que eu tenho pra avançar Ah, ah, ah

És o meu alívio A força e o ânimo que eu necessito pra prosseguir Se eu não desisti, o motivo é porque sempre esteve aqui Nos piores momentos dizendo que nunca desiste de mim Pra onde eu irei se o que eu preciso só encontro em Ti?

> Tá tão complicado, Pai Eu confesso, eu tô cansado e não quero mais Tô exausto e com medo

> > Tem dias que o peito aperta Tem dias que o fardo pesa Nem que for se arrastando Eu não volto pra trás Fica aqui comigo e não sai mais

> > > (Alívio – Jessé Aguiar) V

DEDICATÓRIA

À Valdirene (mãe) e Iracema (avó – *in memoriam*) pelo dom da vida, amor imensurável, apoio incondicional, exemplo, sacrifício e doação. A Ragnar pela felicidade diária. A Marcello, pelo amor e companheirismo, mesmo na distância.

DEDICO!

AGRADECIMENTOS

Agradeço a Deus, ao acaso, a natureza e a toda experiência transcendental que demonstre os limites da lógica científica diante da imensidão do Universo. Às forças visíveis e invisíveis que, de uma forma ou de outra, contribuíram para a execução de mais um trabalho.

Meus mais sinceros agradecimentos à melhor mãe (Valdirene) e avó (Iracema – *in memoriam*) do mundo, palavras nunca serão suficientes, gratidão e amor eternos!

Tia Bia, Tio Quinca (*in memoriam*), as primas Fabíola e Priscila, e meus afilhados Fábio e Flávia, por poder chamar a todos de família.

Marcello Victor pelo amor e companheirismo durante os últimos 15 anos, e pela certeza de dias cheios de compreensão, amor e carinho.

Ao meu Orientador, Gledson Luiz Pontes de Almeida, pela disponibilidade e paciência, mas principalmente pela humanidade que demonstrou diante de todo processo que eu vivenciei no período do Mestrado. Peço a Deus que conserve todas as coisas boas na sua vida, obrigada por tornar essa jornada menos pesarosa!

Ao meu co-orientador, que se tornou um amigo querido, Marcos Vinícius da Silva, por ter me acompanhado durante a jornada, sempre me incentivando e dando palavras de apoio. Querido, tu és fera, voa que o céu é o limite pra tu!

Ao Grupo de Pesquisa em Ambiência UFRPE – GPESA.

Agradeço também ao professor Ênio Farias de França e Silva, pela atenção dada nos primeiros momentos pós meu ingresso no PGEA.

Aos professores e professoras que integram o PGEA que contribuíram para minha formação.

A Universidade Federal Rural de Pernambuco pela oportunidade de galgar novas conquistas pessoais, profissionais e acadêmicas.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo consentimento da bolsa, foi de fundamental importância para a manutenção da minha permanência até o fim do Mestrado.

A todas as pessoas que fizeram e fazem parte da minha vida!

Por fim, mais do que as teorias que li, o que me motiva são as histórias que vi e vivi e vivo e viverei!

SUMÁRIO

LISTA DE FIGURASXI
LISTA DE TABELAS XV
RESUMO GERAL18
GENERAL ABSTRACT19
CAPÍTULO I 20
1.1. INTRODUÇÃO GERAL21
1.2. OBJETIVOS
1.2.1. Objetivo Geral
1.2.2. Objetivos Específicos
1.3. REFERENCIAL TEÓRICO
1.3.1. Mudanças Climáticas
1.3.2. Semiárido Brasileiro
1.3.3. Agropecuária e Pastagem25
1.3.4. Sensoriamento Remoto e Geoprocessamento
1.4. MATERIAL E MÉTODOS
1.4.1. Área de estudo28
1.4.2. Caracterização temporal de Rebanho Efetivo, Vacas Ordenhadas e Produção de Leite por município
1.4.3. Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI
1.4.4. Dados de satélite orbital – TerraClimate
1.4.5. Caracterização pluviométrica via estações meteorológicas do Instituto Nacional de Meteorologia (INMET)
1.4.6. Dinâmica da cobertura vegetal via MapBiomas Brasil
1.4.7. Determinação e Classificação da Declividade da Terra
1.4.8. Índice de Diferença Normalizada da Água (NDWI)
1.4.9. Índice de Vegetação de Diferença Normalizada (NDVI)
1.4.10. Índice de Biomassa da Vegetação Lenhosa (IBVL)
1.4.11. Índice de Vulnerabilidade da Vegetação (IVV)
1.4.12. Índice de Vulnerabilidade das Terras (IVT)

1.4.13	Dinâmica da cobertura de pastagem via Atlas da Pastagens (LAPIG/UFG) 39
1.4.14	. Qualidade de pastagens via MapBiomas Pastagem
1.4.15	Análises estatísticas
1.5. R	EFERÊNCIAS
CAPÍTUL	О П 53
2.1. II	NTRODUÇÃO
2.2. N	IATERIAL E MÉTODOS
2.2.1.	Área de estudo
2.2.2.	Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI
2.2.3.	Dados de satélite orbital – TerraClimate
2.2.4. Meteor	Caracterização pluviométrica via estações meteorológicas do Instituto Nacional de rologia (INMET)
2.2.5.	Dinâmica da cobertura vegetal via MapBiomas Brasil
2.2.6.	Índice de Diferença Normalizada da Água (NDWI)
2.2.7.	Índice de Vegetação de Diferença Normalizada (NDVI)
2.2.8.	Índice de Biomassa da Vegetação Lenhosa (IBVL)
2.2.9.	Índice de Vulnerabilidade da Vegetação (IVV)
2.2.10	. Análises estatísticas
2.3. R	ESULTADOS E DISCUSSÃO69
2.3.1.	Análise e caracterização de precipitação (chuva) via TerraClimate
2.3.2.	Classes de cobertura vegetal via MapBiomas Brasil75
2.3.3.	Análise dos índices para detecção de mudanças hídricas
2.3.4.	Análise dos índices para detecção de cobertura vegetal
2.4. C	ONCLUSÃO
2.5. R	EFERÊNCIAS
CAPÍTUL	0 III 111
3.1. II	NTRODUÇÃO114
3.2. N	IATERIAL E MÉTODOS 116
3.2.1.	Área de estudo116
3.2.2.	Dinâmica da cobertura vegetal via MapBiomas Brasil 119
3.2.3.	Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI

3.2.4.	Determinação e Classificação da Declividade da Terra 121
3.2.5.	Índice de Vulnerabilidade das Terras (IVT) 122
3.2.6. de Leit	Caracterização da série temporal de Efetivo Bovino, Vacas Ordenhadas e Produção te por município
3.2.7.	Dinâmica da cobertura de pastagem via Atlas da Pastagens (LAPIG/UFG) 125
3.2.8.	Qualidade de pastagens via MapBiomas Pastagem125
3.2.9.	Análises estatísticas 126
3.3. R	ESULTADOS E DISCUSSÃO 126
3.3.1.	Classes de cobertura vegetal via MapBiomas Brasil 126
3.3.2.	Análise de Declividade e Índice de Vulnerabilidade de Degradação (IVD) 130
3.3.3.	Análise do Índice de Vulnerabilidade das Terras (IVT)131
3.3.4. Leite	Análise da Série Temporal do Rebanho Efetivo, Vacas Ordenhadas e Produção de 134
3.3.5.	Análise da Dinâmica de Cobertura e Qualidade de Pastagem 140
3.3.6.	Análises Estatísticas
3.4. C	ONCLUSÃO 151
3.5. R	EFERÊNCIAS 152
CONSIDE	RAÇÕES FINAIS 163

LISTA DE FIGURAS

CAPÍTULO I

 Figura 2. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na

 Bacia Hidrográfica do Rio Ipanema.
 30

CAPÍTULO II

Figura 3. Localização espacial da área de estudo. (A) Delimitação do leito principal do Rio
Ipanema e identificação do exutório; (B) Hipsometria com base no modelo de elevação digital
(DEM) Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m; (C)
Classificação climática de Köppen-Geiger, Bacia Hidrográfica do Rio Ipanema, Pernambuco e
Alagoas, Brasil
Figura 4. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na BHRI
Figura 5. Dinâmica espacial das chuvas, via TerraClimate, para o período seco de 2010-2020 na BHRI
Figura 6. Dinâmica espacial das chuvas, via TerraClimate, para o período chuvoso de 2010- 2020 na BHRI
Figura 7. Dados observados pelo INMET nas estações meteorológicas dos municípios e dados
observados do TerraClimate para os anos de 2010 a 202073
Figura 8. Validação dos dados observados pela estação meteorológica do INMET com os dados observados do TerraClimate para os anos de 2010 a 2020
Figura 9. Dinâmica espaço-temporal anual do LULC dos anos de 2010 a 2020 na BHRI 76
Figura 10. Quantificação de áreas (ha) de uso e cobertura da terra para os anos de 2010 a 2020 na BHRI

Figura 11. Precisão do Nível 1 da Coleção 6 do MapBiomas 6 para os anos de 2010 a 2020 dos municípios produtores das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na Figura 12. Dinâmica espaço-temporal do Índice de Diferença Normalizada da Água (NDWI), para o período seco dos anos de 2010 a 2020 na BHRI...... 80 Figura 13. Dinâmica espaço-temporal do Índice de Diferença Normalizada da Água (NDWI), Figura 14. Detecção de mudanças para corpos hídricos utilizando o Índice de Diferença Normalizada da Água (NDWI), para o período seco dos anos de 2010 a 2020 na BHRI. 83 Figura 15. Detecção de mudanças para corpos hídricos utilizando o Índice de Diferença Normalizada da Água (NDWI), para o período chuvoso dos anos de 2010 a 2020 na BHRI. 85 Figura 16. Dinâmica espaço-temporal do Índice de Vegetação de Diferença Normalizada Figura 17. Dinâmica espaço-temporal do Índice de Vegetação de Diferença Normalizada Figura 18. Dinâmica espaço-temporal do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período seco dos anos de 2010 a 2020 na BHRI......90 Figura 19. Quantificação de áreas (ha) das classes do Índice de Biomassa de Vegetação Figura 20. Dinâmica espaço-temporal do Índice de Biomassa de Vegetação Lenhosa (IBVL), Figura 21. Quantificação de áreas (ha) das classes do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período chuvoso dos anos de 2010 a 2020 na BHRI.94 Figura 22. Porcentagem de perdas e ganhos das classes do Índice de Biomassa de Vegetação Figura 23. Dinâmica espaço-temporal do Índice de Vulnerabilidade da Vegetação (IVV), para o período seco dos anos de 2010 a 2020 na BHRI.96

Figura 24. Dinâmica espaço-temporal do Índice de Vulnerabilidade da Vegeta	ção (IVV), para
o período chuvoso dos anos de 2010 a 2020 na BHRI.	

CAPÍTULO III

Figura 25. Localização espacial da área de estudo. (A) Delimitação do leito principal do Rio Ipanema e identificação do exutório; (B) Hipsometria com base no modelo de elevação digital (DEM) Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m; (C) Classificação climática de Köppen-Geiger, da BHRI, Pernambuco e Alagoas, Brasil. 117

Figura 26. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na Figura 27. Fluxograma do processamento de imagens para o cálculo do Índice de Vulnerabilidade das Terras (IVT)......123 Figura 28. Dinâmica espaço-temporal anual do LULC dos anos de 2010 a 2020 na BHRI. 127 Figura 29. Quantificação de áreas (ha) de uso e cobertura da terra para os anos de 2010 a 2020 Figura 30. Precisão do Nível 1 da Coleção 6 do MapBiomas 6 para os anos de 2010 a 2020 dos municípios produtores das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na Figura 31. Classificação da Declividade de acordo com a Metodologia Embrapa (A) e o risco de degradação (B) da área dos municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na BHRI......130 Figura 32. Dinâmica espaço-temporal do Índice de Vulnerabilidade das Terras (IVT) para o período seco dos anos de 2010 a 2020 na BHRI. 132 Figura 33. Dinâmica espaço-temporal do Índice de Vulnerabilidade das Terras (IVT) para o Figura 34. Dinâmica espaço-temporal do Rebanho Efetivo (RE) dos anos de 2010 a 2020 na Figura 35. Dinâmica espaço-temporal de Vacas Ordenhadas (VO) dos anos de 2010 a 2020 na

Figura 36. Dinâmica espaço-temporal de Produção de Leite (VO) dos anos de 2010 a 2020 na BHRI. 139
Figura 37. Dinâmica espaço-temporal da Área de Cobertura de Pastagem Total dos municípios dos anos de 2010 a 2020 na BHRI
Figura 38. Dinâmica espaço-temporal da Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI
Figura 39. Representação gráfica da área das classes de Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI
Figura 40. Análise de Principais Componentes das variáveis de IVT, as classes majoritárias do MapBiomas (cinco classes), o Rebanho Efetivo e Pastagem para o período seco dos anos de 2010 a 2020 na BHRI
Figura 41. Correlação dos Principais Componentes das variáveis de IVT, as classes majoritárias do MapBiomas (cinco classes), o Rebanho Efetivo e Pastagem para o período seco dos anos de 2010 a 2020 na BHRI
Figura 42. Análise de Principais Componentes das variáveis de NDVI, IVV, IBVL, IVT, as classes majoritárias do MapBiomas (cinco classes) e o Rebanho Efetivo para o período chuvoso dos anos de 2010 a 2020 na BHRI
Figura 43. Correlação dos Principais Componentes das variáveis de NDVI, IVV, IBVL, IVT, as classes majoritárias do MapBiomas (cinco classes) e o Rebanho Efetivo para o período chuvoso dos anos de 2010 a 2020 na BHRI

LISTA DE TABELAS

CAPÍTULO I

Tabela 1. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat 8
(OLI)
Tabela 2. Classes de declividade referentes ao risco de degradação da terra
Tabela 3. Classes de declividade de acordo com a metodologia da EMBRAPA (2006)35
Tabela 4. Classes e limites de Detecção de Mudanças para Corpos Hídricos (DMCH) de acordo
com McFeeters (1996)
Tabela 5. Classes de vegetação e valores de reflectância baseados na metodologia de Chaves
et al. (2008)
Tabela 6. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade
da Vegetação
Tabela 7. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade
das terras

CAPÍTULO II

Tabela 8. Comparação da pecuária leiteira entre o Total por Estado, na Bacia do Rio Ipanema
e a porcentagem representativa entre eles
Tabela 9. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat 8
(OLI)
Tabela 10. Classes e limites de Detecção de Mudanças para Corpos Hídricos (DMCH) de
acordo com McFeeters (1996)
Tabela 11. Classes de vegetação e valores de reflectância baseados na metodologia de Chaves
et al. (2008)
Tabela 12. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade
da Vegetação

Tabela 13. Estatística descritiva para os mapas de precipitação (chuvas) via TerraClimate para
os períodos seco e chuvoso de 2010-2020 com valores de mínimo, máximo, média, desvio
padrão, variância e coeficiente de variação (CV, %)72
Tabela 14. Coeficiente de correlação de Pearson (r) e suas classificações de acordo com
Hopkins (2009)
Tabela 15. Estatística descritiva para o NDWI no período seco e chuvoso de 2010 a 2020.
Tabela 16. Estatística descritiva para o NDVI no período seco e chuvoso de 2010 a 202089
CAPÍTULO III
Tabela 17. Comparação da pecuária leiteira entre o Total por Estado, na BHRI e a porcentagem
representativa entre eles
Tabela 18. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat
8 (OLI)
Tabela 19. Classes de declividade referentes ao risco de degradação da terra
Tabela 20. Classes de declividade de acordo com a metodologia da EMBRAPA (2006) 122
Tabela 21. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade
das terras124
Tabela 22. Porcentagem representativa das áreas das classes do Índice de Vulnerabilidade das
Terras (IVT) para os períodos seco e chuvoso dos anos de 2010 a 2020 na BHRI 134
Tabela 23. Ranking dos cinco Municípios com maior número de RE dos anos de 2010 a 2020
na BHRI
Tabela 24. Ranking dos cinco Municípios com maior número de VO dos anos de 2010 a 2020
na BHRI
Tabela 25. Ranking dos cinco Municípios com maior PL dos anos de 2010 a 2020 na BHRI.
Tabela 26. Ranking dos cinco Municípios com maior área de Cobertura de Pastagem dos anos
de 2010 a 2020 na BHRI
Tabela 27. Área das classes de Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI.143

 SILVA, J. B. A. Modelagem Espaço-Temporal da Vulnerabilidade da Terra e sua Inferência nas Bacias Leiteiras dos Estados de Pernambuco e Alagoas. 2023. Dissertação de Mestrado em Engenharia Agrícola. Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal Rural de Pernambuco – UFRPE. Recife, 20023.

RESUMO GERAL

A escassez hídrica no semiárido brasileiro, associado a dinâmica de atividades antrópicas, implicam substancialmente na degradação da Caatinga. O objetivo deste estudo foi avaliar a dinâmica espaço-temporal da vulnerabilidade da terra e sua inferência nas bacias leiteiras dos estados de Pernambuco e Alagoas, inseridas na Bacia Hidrográfica do Rio Ipanema (BHRI), utilizando Sensoriamento Remoto. O estudo identificou mudanças nas condições de uso da terra, levando à perda da cobertura vegetal e dos corpos d'água, afetando o microclima local e contribuindo com o déficit hídrico na BHRI, que foi intensificado pela variabilidade das chuvas e devido a baixos totais anuais, também impactou diretamente na dinâmica e resiliência da vegetação e na disponibilidade hídrica da bacia. Constatou-se que os efeitos severos da estiagem favoreceram a vulnerabilidade da terra ocasionando processos de degradação ambiental e pressões antrópicas. O estudo evidenciou, de acordo com a metodologia aplicada, que a área apresenta um relevo predominantemente plano com um risco de degradação e vulnerabilidade muito altos. O Município de Itaíba (PE) detém os maiores números de rebanho efetivo, vacas ordenhadas e produção de leite (x1000) entre todos os municípios das bacias leiteiras de Pernambuco e Alagoas, bem como a maior área de pastagem. Em relação a qualidade das pastagens, constatou-se que o período com maior área de pastagens severamente degradadas ocorreu entre os anos que apresentaram uma das piores secas no Nordeste Brasileiro, 2012 a 2017. Apesar das limitações encontradas na divisão temporal entre os períodos seco e chuvoso, na qual a presença de nuvens no período chuvoso interferiu nos resultados, o sensoriamento remoto foi eficiente na identificação da variabilidade dos parâmetros físico-hídricos, fornecendo uma compreensão substancial sobre a vulnerabilidade da terra, mudanças nas condições de uso do solo, disponibilidade hídrica e desenvolvimento da pecuária leiteira na BHRI.

PALAVRAS-CHAVE: água, caatinga, geoprocessamento, pastagens, semiárido.

SILVA, J. B. A. **Space-Time Modeling of Earth Vulnerability and its Inference in the Dairy Basins of the States of Pernambuco and Alagoas**. 2023. Master's Dissertation in Agricultural Engineering. Graduate Program in Agricultural Engineering, Federal Rural University of Pernambuco – UFRPE. Recife, 20023.

GENERAL ABSTRACT

Water scarcity in the Brazilian semi-arid region, associated with the dynamics of anthropic activities, substantially imply the degradation of the Caatinga. The objective of this study was to evaluate the space-time dynamics of land vulnerability and its inference in the dairy basins of the states of Pernambuco and Alagoas, inserted in the Ipanema River Basin (BHRI), using Remote Sensing. The study identified changes in land use conditions, leading to the loss of vegetation cover and water bodies, affecting the local microclimate and contributing to the water deficit in the BHRI, which was intensified by rainfall variability and due to low annual totals, also directly impacted the dynamics and resilience of the vegetation and water availability in the basin. It was found that the severe effects of the drought favored the vulnerability of the land, causing processes of environmental degradation and anthropic pressures. The study showed, according to the applied methodology, that the area has a predominantly flat relief with a very high risk of degradation and vulnerability. The Municipality of Itaíba (PE) has the highest numbers of effective herd, cows milked and milk production (x1000) among all municipalities in the dairy basins of Pernambuco and Alagoas, as well as the largest pasture area. Regarding the quality of the pastures, it was found that the period with the largest area of severely degraded pastures occurred between the years that had one of the worst droughts in the Brazilian Northeast, 2012 to 2017. Despite the limitations found in the temporal division between the dry and dry periods rainy season, in which the presence of clouds in the rainy season interfered with the results, remote sensing was efficient in identifying the variability of the physical-water parameters, providing a substantial understanding of the vulnerability of the land, changes in soil use conditions, water availability and development of dairy farming at BHRI.

KEY WORDS: water, caatinga, geoprocessing, pastures, semiarid.

CAPÍTULO I

1.1. INTRODUÇÃO GERAL

As mudanças climáticas e seus impactos estão entre as ameaças mais desafiadoras que o mundo enfrenta atualmente (IPCC, 2021). Segundo Burney et al. (2014) modelos climáticos demonstram o grande impacto das mudanças climáticas, afetando a vazão dos rios, o armazenamento de água e a produtividade agropecuária, indicando uma redução substancial da disponibilidade das águas superficiais.

Ao longo dos tempos, a intensificação das ações antrópicas vem gerado diversos impactos nas paisagens naturais, em um processo de substituição e exploração destas áreas em detrimento aos mais variados tipos de uso da terra (Patel et al. 2019), tal fato pode influenciar a disponibilidade e a qualidade dos recursos naturais, de acordo com Coelho et al. (2013), uma dessas causas é a exploração intensa de áreas com agricultura e pecuária, prática comum na região semiárida do nordeste brasileiro, ocasionando queda da fertilidade do solo e intensificação dos processos erosivos, bem como perda de biodiversidade e assoreamento de reservatórios e cursos d'água.

De acordo com o relatório do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021) o crescimento de áreas desérticas no semiárido brasileiro tem aumentado mais rápido do que se imaginava devido à mudança climática. A projeção do IPCC é que até 2030 a temperatura média do planeta suba 1,5°C, e com isso algumas regiões do semiárido brasileiro podem chegar a ultrapassar 40°C durante o verão. Todas essas projeções são observadas quando se considera os extensos períodos anuais de seca no semiárido brasileiro, com destaque para a década de 2011 a 2020, considerada uma das mais graves, principalmente entre os anos de 2012 e 2016 de seca severa (Silva et al., 2023).

A região semiárida brasileira ocupa todos os estados da região Nordeste do Brasil e está sob o domínio do Bioma Caatinga, que sofre o reflexo da elevada variabilidade das chuvas, com pouca distribuição espacial e concentradas ao longo do tempo (Silva et al., 2020). Nessa região predomina a agropecuária de subsistência, na maioria das vezes prejudicada pelas estiagens, ou seja, o setor agropecuário ainda é a base da sociedade rural e a principal atividade econômica da maioria dos pequenos municípios da região. Medeiros et al. (2020) e Vieira et al. (2020), ressaltam que o sistema agrícola predominante na região é a agricultura de sequeiro, geralmente em pequenas propriedades, que cultivam lavouras de subsistência com queima de vegetação nativa e preparo convencional do solo em paralelo à pecuária extensiva.

A Bacia Hidrográfica do Rio Ipanema (BHRI), está inserida no bioma Caatinga e no clima semiárido, onde estão localizadas as principais bacias leiteiras dos Estados de Pernambuco e Alagoas, com dinâmica expansionista de áreas para produção de alimento e o fornecimento de forragem para o gado (Silva et al., 2020; Fernandes et al., 2021).

Diante do exposto, torna-se evidente a necessidade de realizar uma análise sobre o uso e ocupação da terra, mudanças na cobertura vegetal e áreas de pastagem, avaliação da condição hídrica e o desenvolvimento da pecuária leiteira e suas inferências nas BHRI, onde estão localizadas as bacias leiteiras dos Estados de Pernambuco e Alagoas.

1.2. OBJETIVOS

1.2.1. Objetivo Geral

Avaliar a dinâmica espaço-temporal da vulnerabilidade da terra e sua inferência nas bacias leiteiras dos estados de Pernambuco e Alagoas, inseridas na Bacia Hidrográfica do Rio Ipanema, utilizando Sensoriamento Remoto.

1.2.2. Objetivos Específicos

- Processar imagens de satélites orbitais, Landsat 5 e 8, via Google Earth Engine (GEE), caracterizando parâmetros biofísicos da vegetação da região no período de 2010 a 2020;
- Caracterizar os efeitos de intervenções antrópicas na dinâmica espacial da cobertura vegetal da região;
- Quantificar o crescimento do rebanho de pecuária leiteira e caracterizar as pastagens, nos municípios que abrangem a área da bacia leiteira de Pernambuco e Alagoas;
- Caracterizar a vulnerabilidade da terra e associar com a degradação da vegetação local;
- Avaliar os fatores antrópicos sob a dinâmica da cobertura vegetal do bioma Caatinga, via modelagem multivariada por componentes principais.

1.3. REFERENCIAL TEÓRICO

1.3.1. Mudanças Climáticas

As alterações climáticas são reconhecidas como um dos principais problemas ambientais do século XXI (Vaghefi et al., 2017), representando uma grande ameaça à integridade dos ecossistemas, particularmente os ecossistemas mais vulneráveis, como áridos e semiáridos (Bellard et al., 2014).

Uma das consequências das mudanças climáticas é o aumento de eventos climáticos extremos (Diffenbaugh et al. 2017). Um evento extremo é definido quando o valor de uma variável está acima ou abaixo de um limiar obtido pela aplicação de métodos estatísticos (IPCC 2021), um exemplo de evento climático extremo é o aumento dos dias consecutivos sem precipitação em uma determinada região, além disso, eventos extremos podem ser considerados em termos de sua frequência, intensidade, duração, dano causado (Seneviratne et al. 2012) e podem ser causados por processos naturais, antrópicos ou a combinação dos dois.

Segundo a Agência Nacional de Águas (ANA, 2021), as previsões atuais de modelagem climática não são otimistas, com previsões de aumento do estresse hídrico e conflito social devido a mudanças na disponibilidade de água, impactos sobre a agricultura e outros setores econômicos e o aumento na frequência de eventos extremos. Em suma, a mudança do clima abalará diversos sistemas naturais fortemente dependentes do clima – como oceanos, rios, florestas, campos e biodiversidade, além da agricultura e da pecuária (Margulis, 2017). Complementando, Cavalcante Junior et al. (2019) e Reboita et al. (2022) citam também o aumento da insegurança alimentar e a pobreza, afetando o bem-estar das sociedades.

A United Nations Framework Convention on Climate Change (Convenção das Nações Unidas sobre Mudanças Climáticas) (UNFCCC, 2012) sugeriu duas opções complementares para lidar com a mudança do clima: a mitigação e a adaptação. A mitigação visa prevenir novas mudanças climáticas, em um esforço global que exige mudanças amplas de comportamento e avanços tecnológicos e a adaptação implica reajustar a vida à realidade de que, independentemente dos esforços de mitigação, uma certa quantidade de mudanças climáticas inevitavelmente ocorrerá.

No Brasil, a Lei Federal nº 12.187/2009 instituiu a Política Nacional de Mudanças Climáticas (PNMC), iniciando as ações federais coordenadas de mitigação e adaptação às

mudanças climáticas no país (Brasil, 2009). Estados e Municípios também adotaram normas sobre o assunto, mostrando um aumento da importância do tema na agenda política nacional (Santos, 2021). Dessa forma, é imprescindível destacar a importância e como estão entrelaçados os âmbitos dos impactos causados pelas mudanças climáticas e a importância de conhecê-los, perpassando pelos diversos setores, sejam eles ambientais, sociais e/ou econômicos.

1.3.2. Semiárido Brasileiro

A região semiárida brasileira ocupa todos os estados da região Nordeste do Brasil, com uma área de 1.006.738 km², que cobre os limites territoriais de 1.171 municípios e uma população estimada de 26.378.043 habitantes (Medeiros, 2018; Silva et al., 2020). Essas regiões estão sob o domínio do Bioma Caatinga, bioma esse, exclusivamente brasileiro, com extensão de 982.563 km², ocupando o equivalente a 11% de todo território nacional, sendo evidenciado pelas secas, variabilidade climática, escassez de reservas hídricas e irregularidades sazonais e interanuais de precipitação (Brasil Neto et al., 2021). Além de forte insolação, altas taxas de evapotranspiração, baixa fertilidade e escassa cobertura vegetal no período de seco (Yang et al., 2019), juntamente com solos rasos, que resulta em rios intermitentes (De Nys et al., 2016) levando à baixa disponibilidade hídrica dos rios (ANA, 2015).

Segundo Dantas et al. (2020), para compreender a ocorrência desses fenômenos naturais na região semiárida, faz-se necessário entender a influência do mar do Oceano Pacífico nas anomalias de temperatura de superfície na região, atribuídas ao fenômeno conhecido como "El Niño". Este fenômeno impede a formação de nuvens e a ocorrência de precipitação durante a estação chuvosa, resultando em variabilidade hidroclimática (Moura et al. 2019).

Atualmente, os problemas decorrentes das secas e da escassez hídrica são cada vez mais recorrentes no cotidiano de grande parte da população residente no semiárido e afetam o desenvolvimento social e econômico da região (Brasil Neto et al., 2021). Os cenários futuros são ainda mais preocupantes por causa das estimativas de aumento de temperatura previstas pelas projeções climáticas, com a tendência no aumento e recorrência das secas e as mudanças de uso e ocupação da terra (IPCC, 2021), resultando em um aumento na desertificação devido a exploração da vegetação na região e a falta de práticas conservacionistas, que prejudicam a diversidade e os recursos (Fernandez et al. 2019).

O semiárido brasileiro apresenta uma cobertura vegetal altamente dinâmica, que exige um monitoramento constante das condições de mudança dos diferentes usos do solo (Vieira et al., 2020; Oliveira et al., 2021). Durante séculos, a vegetação natural dominante da região, conhecida como Caatinga, foi derrubada, principalmente para uso doméstico e para produção de carvão vegetal para usos como processamento de gesso (Vieira et al., 2020), estima-se que a perda contínua líquida de cobertura vegetal seja da ordem de 0,3% ano⁻¹ (Queiroz et al., 2020). Somando-se a isso, as áreas nativas ainda dividem espaço com cultivos agrícolas, pastagens e paisagens herbáceas que se alternam com o solo descoberto (Althoff et al., 2018).

Em estudos de avaliação dos impactos das mudanças climáticas sobre a estabilidade dos biomas predominantes no Brasil, desde o início dos anos 2000, Oyama e Nobre (2003), indicaram que o bioma Caatinga está entre os mais vulneráveis, num cenário de aumento das temperaturas globais, uma vez que a sua vulnerabilidade aos efeitos das mudanças climáticas representa um forte fator de pressão para a desertificação na região. Pinho et al. (2020), em pesquisa semelhante, sobre projeções de resiliência dos biomas brasileiros e riscos socioambientais às mudanças climáticas, concluíram que as projeções futuras para Caatinga mostram um estado característico de deserto, com altas temperaturas, níveis críticos de precipitação, sem biomassa, diluindo a resiliência da Caatinga. Somando-se a isso, Antongiovanni et al. (2020) discorre que estudos recentes indicam uma tendência de redução das áreas de vegetação nativa, resultando no aumento da degradação do solo, desencadeada pela substituição da cobertura natural do solo por pastagens e terras agrícolas.

Como observado, o semiárido brasileiro vem sofrendo com vários problemas ao longo das décadas, resultando em extensas áreas severamente degradadas (Antongiovanni et al., 2020). Para Strassburg et al. (2020), a conservação dos ecossistemas naturais remanescentes é o foco mais crítico para a preservação da biodiversidade diante dos efeitos da degradação e das mudanças climáticas. E a garantia da disponibilidade regular de recursos hídricos é um desafio abrangente para o semiárido brasileiro e outras regiões semiáridas do mundo, onde a escassez de água é uma realidade (Cavalcante Júnior et al., 2019).

1.3.3. Agropecuária e Pastagem

De acordo com Enahoro et al. (2018), a importância da agropecuária, como meio de subsistência, fornecimento de nutrientes e renda para populações vulneráveis e sob forte

influência das mudanças climáticas globais, são elementos importantes do discurso do desenvolvimento internacional, principalmente em regiões onde as atividades de produção pecuária são os pilares da economia.

Na região semiárida brasileira predomina a agropecuária de subsistência, dessa forma, o setor agropecuário ainda é a base da sociedade rural e a principal atividade econômica da maioria dos pequenos municípios da região (Vieira et al., 2020).

As principais atividades pecuárias no nordeste brasileiro são a ovinocaprinocultura, suinocultura, avicultura, apicultura e a bovinocultura de leite (Carneiro, 2019). De acordo com o Instituto Nacional do Semiárido (INSA, 2023), apesar da notoriedade dada à ovinocaprinocultura, em termos quantitativos, os bovinos são o principal rebanho da área do semiárido brasileiro e detém aproximadamente 58,1% desse rebanho bovino do Nordeste.

A bovinocultura de leite na região semiárida tem um importante papel na sobrevivência das propriedades agrícolas familiares, tanto no autoconsumo como na geração de renda (Silva Júnior et al., 2018), no entanto, é uma atividade desafiadora, devido aos custos de produção elevados, pois, de acordo com Campos et al. (2017), o sistema de produção de ruminantes mais econômico é o que utiliza pastagens como fonte principal de alimentação e em alguns sistemas, como por exemplo o de bovinocultura de corte, os gastos com alimentação podem chegar até a 80%, resultando em uma produção animal onerosa, o que acaba inviabilizando o investimento dos pequenos produtores.

As áreas de pastagens são a principal fonte de alimento para a pecuária comercial de grande porte (Silva et al., 2021). Na região semiárida a vegetação nativa da Caatinga, conhecida como pasto nativo, é a base de alimento para a criação pecuária, no entanto, apesar de abundante na época chuvosa, torna-se escassa no período seco, apresentando baixa capacidade de suporte, resultando na necessidade de estratégias de suplementação do rebanho, imprescindíveis para a melhoria dos índices produtivos (Alves et al., 2015). Ressalta-se também que, para além do fator da escassez no período seco, a degradação das pastagens nativas encontra-se presente em praticamente toda a região da Caatinga, de acordo com Araújo Filho (2013), a degradação se manifesta nas mudanças da composição florística da vegetação, observada pela dominância de espécies herbáceas anuais ou lenhosas arbustivas, todas de baixo ou nenhum valor forrageiro, resultante da exploração predatória dos recursos de solo e vegetação.

Entre as estratégias utilizadas para a suplementação alimentar da pecuária na região semiárida, cita-se a implantação de pastagens cultivadas. Araújo Filho (2013) cita dois modelos

de pastagens cultivadas, o cultivo de pasto para pastejo e o cultivo de forrageiras para corte. O cultivo para pastejo, no entanto, geralmente é exposto a intenso pisoteio animal, causando compactação do solo e acelerando a sua degradação (De Alcântara et al. 2021), já o cultivo para corte, constitui uma reserva estratégica de alimentos, seja para suplementação dos rebanhos nas épocas críticas ou para alimentação de animais confinados. Nesse modelo, destaca-se a utilização da palma forrageira, como uma alternativa viável para suprir a demanda alimentar e hídrica dos animais, alta palatabilidade e digestibilidade, bem como sua resistência a fatores bióticos e abióticos encontrados no semiárido brasileiro (Silva et al., 2021).

Entre as pastagens não nativas, com potencial para melhorar os aspectos socioeconômicos dessa região semiárida, Queiroz et al. (2020) citam gramíneas africanas como *Cenchrus ciliaris, Urochloa mosambicensis,* capim africano *Megathyrsus maximus,* cultivares de diferentes espécies de *Digitaria* spp. e palmas forrageiras *Opuntia* spp. e *Nopalea* spp., que também são recomendadas no plantio em áreas degradadas do bioma Caatinga, como alternativa para revitalização de áreas degradadas.

1.3.4. Sensoriamento Remoto e Geoprocessamento

O sensoriamento remoto pode ser definido, de uma maneira ampla, como sendo a forma de obter informações de um objeto ou alvo, sem que haja contato físico com ele (Rosa, 2005). Para Fernandes Neto e Madruga (2012), sensoriamento remoto é a utilização conjunta de modernos sensores com o objetivo de estudar o ambiente terrestre, através do registro e da análise de interações, entre a radiação eletromagnética e as substâncias componentes do planeta Terra, em suas mais diversas manifestações. Complementando, Rosa (2005) afirma que as informações são obtidas utilizando-se a radiação eletromagnética refletida e/ou emitida pelos alvos e geradas por fontes naturais como o Sol e a Terra, ou por fontes artificiais.

Nos últimos anos o sensoriamento remoto por satélite, vem proporcionando meios sofisticados para o estudo dos mais variados recursos da Terra, possibilitando o monitoramento de mudanças ambientais locais e regionais, e até mesmo globais (Yuan et al., 2020). Nos métodos convencionais, os estudos são realizados usando registros disponíveis, levantamentos de campo, que necessitam de equipamentos caros e de difícil obtenção utilizados em estudos *in situ*, e mapas, que são demorados e ficam obsoletos rapidamente (Jardim et al., 2022).

Somando-se a isso, de acordo com Silva et al. (2022), imagens de satélite combinadas com técnicas e ferramentas de geoprocessamento têm levado a avanços significativos nos mais variados estudos, como mapeamento e cobertura do solo e focos de incêndio (Oliveira-Júnior et al., 2022), aplicações climáticas e meteorológicas (Jardim et al., 2022) e respostas hidrológicas (Andrade et al., 2021). Corroborando, Anjos et al. (2019), discorrem que as informações geradas através de análise multitemporal usando imagens de satélite, auxiliam no monitoramento do terreno, da vegetação e de bacias hidrográficas, incluindo o planejamento de ações para recuperação de áreas degradadas.

Por fim, observa-se que ao longo das últimas décadas, as técnicas de sensoriamento remoto e geoprocessamento possibilitaram, com sucesso, o monitoramento dos mais variados parâmetros e em diferentes áreas, locais e biomas do mundo.

1.4. MATERIAL E MÉTODOS

1.4.1. Área de estudo

A área de estudo localiza-se entre os paralelos 08°18'04" S – 10°0' S e os meridianos 36°0' W e 38°0' W (Figura 1), com altitudes inferiores a 1.115 m e no Bioma Caatinga (MAPBIOMAS BRASIL, 2021). De acordo com a classificação climática proposta por Köppen-Geiger, o clima é predominantemente do tipo BSh e As, clima semiárido quente (Alvares et al., 2013; Beck et al., 2018), com temperatura máxima ocorrendo nos meses de novembro a janeiro (33 °C) e mínimas nos meses de maio a julho (19 °C) com temperaturas médias anuais superiores a 23°C, o período chuvoso está mais concentrado entre os meses de março a julho, com média anual inferior a 700 mm (INMET, 2021). A média anual da evapotranspiração potencial também é elevada, com índices que podem ser superiores a 1.600 mm (Montenegro; Ragab, 2010).



Figura 1. Localização espacial da área de estudo. (A) Delimitação do leito principal do Rio Ipanema e identificação do exutório; (B) Hipsometria com base no modelo de elevação digital (DEM) Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m; (C) Classificação climática de Köppen-Geiger, da BHRI, Pernambuco e Alagoas, Brasil.

As bacias leiteiras de Pernambuco e Alagoas estão inseridas na BHRI, com área de aproximadamente 7.850 km² (IBGE, 2021), localizada, em sua maior parte no Estado de Pernambuco, com sua porção sul no Estado de Alagoas (Figura 2) e está inserida, respectivamente, dentro de dois importantes níveis hidrográficos: a grande Bacia Hidrográfica do Rio São Francisco (macrorregião) e a Bacia Hidrográfica do Baixo São Francisco (mesorregião) (IBGE, 2021).



Figura 2. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na Bacia Hidrográfica do Rio Ipanema.

De acordo com o Censo Agro de 2017 (IBGE, 2021) Alagoas apresentava rebanho efetivo de 786.018 cabeças (17,6% - Bacia do Rio Ipanema), sendo 81.599 vacas de leite (41,8% - BHRI), que gerou produção de 188.628 (x1.000) kg de leite (51,3% - BHRI). Já Pernambuco, contava com 1.284.796 cabeças (22,5% - BHRI), sendo 222.344 vacas de leite (40,8% - BHRI) e produção de 520.990 (x1.000) kg de leite (56,1% - BHRI), distribuídos em 18 municípios pernambucanos (Águas Belas, Alagoinha, Arcoverde, Bom Conselho, Buíque, Caetés, Capoeiras, Garanhuns, Iati, Ibimirim, Itaíba, Manari, Paranatama, Pedra, Pesqueira, Saloá, Tupanatinga e Venturosa) e 16 municípios alagoanos (Batalha, Belo Monte, Cacimbinhas, Carneiros, Dois Riachos, Jacaré dos Homens, Jaramataia, Major Isidoro, Maravilha, Minador

do Negrão, Olho d'Água das Flores, Olivença, Ouro Branco, Poço das Trincheiras, Santana do Ipanema e Senador Rui Palmeira).

1.4.2. Caracterização temporal de Rebanho Efetivo, Vacas Ordenhadas e Produção de Leite por município

Foi realizado um levantamento para a quantificação do Rebanho Efetivo (RE), Vacas Ordenhadas (VO) e Produção de Leite (PL) em cada um dos 34 municípios estudados no período 2010-2020 utilizando o banco de dados da Pesquisa de Pecuária Municipal (PPM) da plataforma de Sistema de Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE) através do endereço eletrônico: <<u>https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2021</u>>.

Mapas temáticos foram criados para visualizar a espacialização temporal do número do RE, VO e PL dos municípios da bacia leiteira inseridos na BHRI nos anos 2010 e 2020, através da confecção de arquivos shapefile (.shp) e raster, com a união dos dados obtidos pela SIDRA e os dados geográficos do IBGE, utilizando o software QGIS 3.22.

1.4.3. Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI

O estudo foi desenvolvido a partir das imagens orbitais dos Satélites Landsat – 5 (sensor TM) e o Landsat – 8 (sensor OLI) (Tabela 1) referente a órbita/ponto 215/066, sendo disponibilizadas pelo Serviço Geológico dos Estados Unidos (USGS) via Administração Nacional da Aeronáutica e Espaço (NASA). Em média, um total anual de 10 imagens orbitais foram processadas, entre os anos de 2010 e 2020. Ressalta-se que para o ano de 2012, não foi possível a geração dos índices, devido à ausência de cobertura da série Landsat para o período.

Sanson Danda		Resolução	Resolução	Resolução
Sensor	Банаа	Espectral (µm)	Espacial (m)	Temporal
	r1: Azul	0,45 - 0,52	30	
	r2: Verde	0,52 - 0,60	30	
	r3: Vermelho	0,63 - 0,69	30	
TM	r4: Infravermelho Próximo	0,76 - 0,90	30	16 dias
	r5: Infravermelho Médio	1,55 - 1,75	30	
	r6: Infravermelho Termal	10,40 - 12,50	120	
	r7: Infravermelho Médio	2,08 - 2,35	30	
	r1: Costal (Aerosol)	0,43 - 0,45	30	
	r2: Azul	0,45 - 0,51	30	
	r3: Verde	0,53 - 0,59	30	
	r4: Vermelho	0,64 - 0,67	30	
	r5: Infravermelho Próximo	0,85 - 0,88	30	
OLI	r6: SWIR 1	1,57 - 1,65	30	16 dias
	r7: SWIR 2	2,11 - 2,29	30	
	r8: Pancromático	0,50 - 0,68	15	
	r9: Cirrus	1,36 - 1,38	30	
	r10: Infravermelho Termal 1	10,6 - 11,19	100	
	r11: Infravermelho Termal 2	11,50 - 12,51	100	

Tabela 1. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat 8 (OLI).

Fonte: Autores (2022) adaptado de USGS (2022).

Para o desenvolvimento de mapas temáticos de condições hidrológicas e cobertura vegetal a partir de parâmetros geoespaciais e biofísicos, o Índice de Diferença Normalizada da Água (NDWI) e o Índice de Vegetação de Diferença Normalizada (NDVI), foram desenvolvidos, gerenciados e processados automaticamente por meio da plataforma digital em nuvem, Google Earth Engine (GEE) (<u>https://earthengine.google.com/</u>), a partir da linguagem de programação em JavaScript. Essa plataforma inclui bibliotecas com múltiplas funções para análise matemática e modelagem, análises estatísticas e operações de aprendizado de máquina, baseadas em algoritmos específicos para o processamento digital de imagens de satélites (Silva et al., 2022; GEE, 2023).

O conjunto de imagens utilizadas foram oriundas das coleções ee.ImageCollection ("LANDSAT/LT05/C02/T1_L2") e ("LANDSAT/LC08/C02/T1_SR"), sendo adotado como período seco os meses de setembro, outubro, novembro, dezembro e janeiro, e chuvoso os

meses de março, abril, maio, junho e julho, de cada ano, com produtos de reflectância da superfície a partir de 01/01/2010 até 31/12/2020, estabelecendo o critério de nuvens inferior a 20%, no qual, para cada período foi estabelecido a média de todas as imagens dentro do critério de porcentagem de nuvens estabelecido, ressalta-se no entanto, que para o ano de 2011 o critério mínimo de nuvens para o período seco e chuvoso, foi de 30 e 55% respectivamente, pois foram as menores porcentagem de nuvens para que a obtenção de imagens da área. Mapas temáticos foram classificados e confeccionados no QGIS 3.22.

1.4.4. Dados de satélite orbital – TerraClimate

Para caracterizar os padrões e a variabilidade das chuvas, foram utilizados os dados do satélite TerraClimate, que possui resolução temporal mensal, do período de 01/01/2010 a 31/12/2020. O TerraClimate disponibiliza dados de balanço hídrico e climático, com resolução espacial de aproximadamente 4 km, com dados de 1958 até os dias atuais (Abatzoglou et al., 2018).

O conjunto de dados disponibilizados pelo TerraClimate é dividido em variáveis climáticas primárias e secundárias; as variáveis primárias correspondem as temperaturas máxima e mínima, a pressão de vapor, acúmulo de precipitação, radiação de ondas curtas na superfície, e velocidade dos ventos; as variáveis secundárias correspondem a evapotranspiração de referência, o escoamento superficial, a evapotranspiração real, o déficit hídrico climático, umidade do solo, água equivalente à neve, Índice de Severidade da Seca de Palmer (PDSI), e o déficit de pressão de vapor (Silva et al., 2022).

Para o presente estudo, a precipitação anual acumulada (mm) foi utilizada. Os dados foram obtidos na plataforma Climate Engine (Cloud Computing of Climate and Remote Sensing Data), plataforma de processamento das imagens provenientes do TerraClimate, disponibilizadas em: <u>https://app.climateengine.org/climateEngine</u>. Os arquivos raster obtidos para cada imagem foram transformados em arquivos vetoriais de pontos (*extension.shp*) e posteriormente interpolados pela técnica IDW (*Inverse Distance Weighted*), com uma resolução de 30m, que prediz um valor para algum local não medido utilizando-se os valores amostrados à sua volta, que terão um maior peso do que os valores mais distantes (Gomes et al., 2019). O processamento e os mapas temáticos foram realizados no QGIS 3.22.

1.4.5. Caracterização pluviométrica via estações meteorológicas do Instituto Nacional de Meteorologia (INMET)

A fim de caracterizar as componentes meteorológicas locais, foram utilizados dados de cinco estações meteorológicas do Instituto Nacional de Meteorologia (INMET) disponíveis, inseridas na área de estudo, localizadas nos municípios de Arcoverde, Garanhuns, Ibimirim e Pesqueira (Pernambuco) e Major Isidoro (Alagoas). Os dados foram extraídos para o período que compreende o estudo 2010-2020. Disponíveis no endereço eletrônico: <u>https://portal.inmet.gov.br/</u>.

1.4.6. Dinâmica da cobertura vegetal via MapBiomas Brasil

Para avaliação da cobertura vegetal, foram extraídos dados para região de estudo proveniente da plataforma MapBiomas (MapBiomas Brasil, 2021). Os dados de uso e cobertura do solo se encontram disponíveis no endereço eletrônico: <<u>https://plataforma.brasil.mapbiomas.org/></u>.

O MapBiomas trabalha com o conceito de coleção de dados e atualmente está na versão 7.0. A cada nova coleção todo conjunto de dados pretérito é reprocessado com base nos novos métodos e algoritmos (Silva et al., 2022; MapBiomas Brasil, 2021). Nesse estudo, foi utilizada a coleção de dados da versão 6.0, mais recente à data que o mesmo foi desenvolvido, utilizando um catálogo com 25 classes de legenda, próprio da plataforma, priorizando as classes majoritárias do Nível 1: Floresta (caatinga arbórea), Formação natural não florestal (caatinga arbustiva), Agricultura e Pecuária, Área não vegetada (Infraestrutura Urbana e Solo Exposto) e Corpos hídricos.

Os arquivos raster foram gerados para os anos de 2010 a 2020 para cada tipo de uso do solo e as classes majoritárias foram calculadas pelo plugin "r.report" do software GRASS 7, integrado ao QGIS 3.22.

1.4.7. Determinação e Classificação da Declividade da Terra

Para geração do mapa de declividade foi utilizado um mosaico de imagens digitais de dados altimétricos do projeto SRTM/NASA, dos quadrantes s10_w038; s10_w037; s09_w038

e s09_w037. Com auxílio da ferramenta de processamento "Análise Raster – Reclassificar por Tabela", disponível no QGIS 3.22, foi realizada a classificação de acordo com os limites das classes de declividade referentes ao risco de degradação da terra para a obtenção do Índice de Vulnerabilidade de Degradação (IVD) apresentados na Tabela 2 e a classificação da declividade de relevo da EMBRAPA (2006), Tabela 3.

Classes de Risco de Degradação	Limites de Classes	
Muito Baixa	0 a 3	
Baixa	3 a 6	
Média	6 a 12	
Alta	12 a 20	
Muito Alta	> 20	

Tabela 2. Classes de declividade referentes ao risco de degradação da terra.

Fonte: LOPES; CAMPOS (2019)

Tabela 3. Classes de declividade de acordo com a metodologia da EMBRAPA (2006).

Classes de Declividade	Limites de Classes (%)
Plano	0-3
Suave Ondulado	3 – 8
Ondulado	8 - 20
Forte Ondulado	20 - 45
Montanhoso	45 - 75
Escarpado	> 75

1.4.8. Índice de Diferença Normalizada da Água (NDWI)

O NDWI é calculado em função das bandas multiespectrais de reflectância de superfície e são indicadores sensíveis de mudanças na terra, na avaliação da disponibilidade de água e avaliação das condições de seca, e seus valores variam de -1 a 1 (Marengo et al., 2018; Silva et al., 2022). O NDWI foi calculado através das bandas reflexivas das imagens do satélite Landsat-5/TM e Landsat-8/OLI, pela diferença normalizada entre duas bandas da imagem, de acordo com a Eq. (1) (McFeeters, 1996; Xu, 2006).

$$NDWI = \frac{r_{b \text{ GREEN}} - r_{b \text{ SWIR}}}{r_{b \text{ GREEN}} + r_{b \text{ SWIR}}}$$
(1)

sendo, $r_{b \text{ GREEN}}$ - faixa refletiva do verde (banda 2 do sensor TM e banda 3 do sensor OLI); e r_{b} _{SWIR} - faixa refletiva do infravermelho médio (banda 5 do sensor TM e 6 do sensor OLI).

O NDWI também foi utilizado para a obtenção das imagens de detecção de mudanças para corpos hídricos e condição hídrica, considerando que valores entre 1 a 0 de NDWI são equivalentes a coberturas de corpos d´água e valores de -1 a 0 correspondem a umidade na vegetação e solo, vegetação e solo exposto.

A detecção de mudanças dos corpos hídricos representa a mudança ocorrida entre imagens ao longo de um determinado intervalo de tempo, na qual duas imagens são comparadas pixel a pixel, o produto dessa comparação é uma imagem que representa a diferença numérica entre os pixels pareados das duas imagens, conforme a Eq. (2).

$$\Delta ij = (Aij (t_i) - Aij (t_n))$$
⁽²⁾

sendo, Δij = valor da diferença dos pixels na linha i e coluna j; Aij (ti) = valor do pixel ij na data i; Aij (tn) = valor do pixel ij na data n.

As imagens foram classificadas pelo software QGIS 3.22 e os limites de cada classe, estabelecidos segundo a Tabela 4.

DMCH	Limites de Classe
Aumento hídrico	-1 a 0
Sem mudanças	0 a 0.1
Redução hídrica	0.1 a 1

Tabela 4. Classes e limites de Detecção de Mudanças para Corpos Hídricos (DMCH) de acordo com McFeeters (1996).

1.4.9. Índice de Vegetação de Diferença Normalizada (NDVI)

O NDVI é um indicador sensível da condição da cobertura vegetal, com valores variando entre -1 e 1, no qual, quanto mais próximo de 1, maior é a indicação da atividade vegetal fotossinteticamente ativa. Valores de zero e próximos de zero indicam áreas com pouca ou
nenhuma vegetação, e valores negativos são referentes a corpos hídricos (Santos et al., 2020). O NDVI foi determinado conforme a Eq. (1) (Rouse et al., 1974):

$$NDVI = \frac{r_{b \text{ NIR}} - r_{b \text{ RED}}}{r_{b \text{ NIR}} + r_{b \text{ RED}}}$$
(1)

Sendo, $r_{b \text{ NIR}} e r_{b \text{ RED}}$, correspondem às respectivas bandas refletivas 4 e 3 do Landsat-5 de sensor TM, e 5 e 4 do Landsat-8 de sensor OLI.

1.4.10. Índice de Biomassa da Vegetação Lenhosa (IBVL)

Através do NDVI foi realizada a reclassificação da vegetação da região de estudo, caracterizada pelo Índice de Biomassa da Vegetação Lenhosa (IBVL), método proposto por Chaves et al. (2008), desenvolvido para descrever e avaliar a vegetação da Caatinga em seus diferentes estágios de antropização. Com o objetivo de realizar o mapeamento do IBVL, por meio do NDVI, foram importadas as imagens de NDVI e realizada a classificação pelo QGIS 3.22, de acordo com a Tabela 5.

Tabela 5. Classes de vegetação e valores de refle	ectância baseados na metodologia de Chaves
et al. (2008).	

Classes de IBVL	Valores de NDVI		
Arbórea muito densa	>0,350		
Arbórea densa	0,320 a 0,350		
Subarbórea densa	0,300 a 0,320		
Subarbórea arbustiva densa	0,285 a 0,300		
Arbustiva subarbórea densa	0,265 a 0,285		
Arbustiva subarbórea aberta	0,250 a 0,265		
Arbustiva subarbustiva aberta	0,225 a 0,250		
Subarbustiva arbustiva rala	0,200 a 0,225		
Subarbustiva arbustiva muito rala	0,150 a 0,200		
Solo exposto	0,000 a 0,150		
Corpos d'água	-1,000 a 0,000		

Fonte: Francisco et al. (2013)

1.4.11. Índice de Vulnerabilidade da Vegetação (IVV)

A estimativa do Índice de Vulnerabilidade da Vegetação (IVV) desenvolvida por Chaves et al. (2008), foi determinado pela diferença entre o IBVL (Tabela 6), para uma condição hipotética de máxima preservação e a condição da vegetação que se quis avaliar, conforme a Eq. (2):

$$IVV = \left(\frac{1}{IBVL}\right)$$
(2)

Sendo 1, o valor do IBVL para condição de máxima preservação; e IBVL, o índice de biomassa para a condição de vegetação que se quer avaliar.

Classes de vecetação	Veget	ação	Vulnerabilidade		
Classes de Vegelação	IBVL	IVV	Classes		
Arbórea muito densa	1,00	1,00	Muito Roivo		
Arbórea densa	0,80 1,25 Muito I		Multo Dalxa		
Subarbórea densa	0,68	1,47	Daira		
Subarbórea arbustiva densa	0,60	1,67	Daixa		
Arbustiva subarbórea densa	0,48	2,08	Madaradaa		
Arbustiva subarbórea aberta	0,36	2,78	Wiouerauas		
Arbustiva subarbustiva aberta	0,24	4,17	Alto		
Subarbustiva arbustiva rala	0,14	7,14	Alla		
Subarbustiva arbustiva muito rala	0,07	14,29	Muito Alto		
Solo exposto	0,05	20,00	Multo Alta		

Tabela 6. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade da Vegetação.

Fonte: Adaptado de Francisco et al. (2013)

1.4.12. Índice de Vulnerabilidade das Terras (IVT)

O Índice de Vulnerabilidade da Terra (IVT) foi determinado pelo produto entre o índice de vulnerabilidade da vegetação (IVV) e o índice de vulnerabilidade de degradação (IVD), conforme a Eq. (3):

 $IVT = IVV \times IVD$

(3)

Para o mapeamento da vulnerabilidade da terra da bacia foi utilizado o cruzamento dos dados relativos aos parâmetros da vegetação e da declividade, conforme a Tabela 7.

Classes de vegetação	Vegetação		Declividade	Vulnerabilidade	
	IBVL*	IVV	IVD	IVT	Classes
Arbórea muito densa	1,00	1,00	0 a 3	0 . 6	Muito Baixa
Arbórea densa	0,80	1,25	0 a 5	0 a 0	
Subarbórea densa	0,68	1,47	3 0 6	6 . 12	Baixa
Subarbórea arbustiva densa	0,60	1,67	5 8 0	0 a 12	
Arbustiva subarbórea densa	0,48	2,08	6 . 12	12 0 24	Modoradas
Arbustiva subarbórea aberta	0,36	2,78	0 a 12	12 a 24	Moderadas
Arbustiva subarbustiva aberta	0,24	4,17	12 0 20	$24 \circ 40$	Alta
Subarbustiva arbustiva rala	0,14	7,14	12 a 20	24 a 40	
Subarbustiva arbustiva muito rala	0,07	14,29	> 20	> 40	Muito Alta
Solo exposto	0,05	20,00	>20	>40	

Tabela 7. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade das terras.

*IBVL, Índice de Biomassa da Vegetação Lenhosa; IVV, Índice de Vulnerabilidade pela Vegetação; IVD, Índice de Vulnerabilidade de Degradação; IVT, Índice de Vulnerabilidade das Terras.

Fonte: Adaptado de Francisco et al. (2013)

1.4.13. Dinâmica da cobertura de pastagem via Atlas da Pastagens (LAPIG/UFG)

Foram extraídos dados de pastagem para a região de estudo provenientes da plataforma Atlas de Pastagens. Os dados encontram-se disponíveis no seguinte endereço eletrônico: <u>https://atlasdaspastagens.ufg.br/map</u>.

O mapeamento de pastagens utilizado na plataforma é baseado em imagens da série de satélites Landsat, o classificador supervisionado Random Forest e robustas técnicas estatística de amostragem (para fins de calibração e validação dos modelos de classificação), com uma precisão geral de aproximadamente 91% (LAPIG/UFG, 2023).

Os arquivos shapefile foram gerados e transformados em raster para os anos de 2010 a 2020 e processados com o auxílio do QGIS 3.22.

1.4.14. Qualidade de pastagens via MapBiomas Pastagem

Os dados de qualidade de pastagem foram extraídos da plataforma MapBiomas Brasil, provenientes da coleção 6, que se encontram disponíveis no seguinte endereço eletrônico: <u>https://plataforma.brasil.mapbiomas.org/</u>.

De acordo com o MapBiomas (2023) o principal uso do solo brasileiro é a pastagem, o que ocupa uma área de 154 milhões de hectares, de norte a sul do Brasil, e está presente em todos os Biomas do Brasil. O bioma da Caatinga, em 2020, apresentou uma área de pastagem total de cerca de 20,2 milhões de hectares, em termos percentuais, é o 3º bioma mais ocupado por pastagens cultivadas com cerca de 23,1%, ficando atrás apenas da Mata Atlântica (25,7%) e do Cerrado (23,7%).

Os arquivos raster foram processados e classificados no QGIS 3.22 em três classes majoritárias: severamente degrada, moderadamente degradada e não degradada. Os mapas temáticos foram produzidos no mesmo software.

1.4.15. Análises estatísticas

As imagens de NDWI e NDVI foram submetidas a análise estatística descritiva no QGIS 3.22, para obtenção da média, mediana, desvio padrão, variância e coeficiente de variação (CV, %), sendo classificado como baixo quando o CV < 12%; médio quando estiver 12% < CV < 24%, e alto quando o CV > 24% (Warrick; Nielsen, 1980).

Para a validação dos dados de satélite do TerraClimate foram aplicadas correlações lineares de 2010 a 2020, a partir do coeficiente de determinação (R²) e RMSE (Root Mean Squared Error), a partir dos dados oriundos das estações meteorológicas do Instituto Nacional de Meteorologia – INMET (INMET, 2021). Cada estação foi devidamente identificada nas coordenadas do pixel analisado.

Realizou-se a análise por componentes principais (PCA) admitindo-se as variáveis IVT, Classes do MapBiomas (5 classes), número de Rebanho Efetivo e Pastagem no período seco e chuvoso, para a série de 2010 a 2020. Baseando-se nos componentes principais (PC) foi obtida a matriz de covariância para extração dos autovalores que originam os autovetores. Para identificação das variáveis que apresentaram correlação foi utilizado o critério de Kaiser, considerando os autovalores superiores a 1.0, que geram componentes com quantidade relevante de informação contida nos dados originais (Kaiser, 1958). Por fim, foi realizada a correlação de Pearson (r) para todas as variáveis, buscando correlacionar com a PCA, de forma a evidenciar as semelhanças entre as variáveis. O programa utilizado para a PCA e correlação foi o RStudio, versão 3.6.1 (R Core Team, 2019).

1.5. REFERÊNCIAS

ABATZOGLOU, J.T.; DOBROWSKI, S.Z.; PARKS, S.A.; et al.. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. Scientific Data. v.5, n.1, p. 1–12. 2018. Disponível em: https://doi.org/10.1038/sdata.2017.191>. Acesso em novembro de 2022.

ALTHOFF, T. D.; MENEZES, R. S. C.; PINTO, A. S.; et al.. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. **Agriculture, Ecosystems & Environment**. v. 254, p. 26–34. 2018. Disponível em: https://doi.org/10.1016/j.agee.2017.11.016>. Acesso em janeiro de 2023.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; et al.. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift.** v. 22, n. 6, p. 711–728. 2013. Disponível em: https://doi.org/10.1127/0941-2948/2013/0507>. Acesso em dezembro de 2021.

ALVES, A. A. A.; REIS, E. M.; SILVA NETO, M. F.; et al.. Forrageiras indicadas para a alimentação animal no Semiárido brasileiro. Petrolina: Embrapa Semiárido. 2015. 62 p. Disponível em: https://ainfo.cnptia.embrapa.br/digital/bitstream/item/141004/1/Cartilha-Andrea.pdf>. Acesso em janeiro de 2023.

ANA – Agência Nacional de Águas. Conjuntura dos Recursos Hídricos no Brasil 2021:
Relatório pleno. 2021. Disponível em: https://relatorio-conjuntura-ana-2021.webflow.io/.
Acesso em janeiro de 2023.

ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. A.; et al.. Climate change impact assessment on water resources underRCPscenarios: A case study in Mundaú River Basin, Northeastern Brazil. **International Journal of Climatology**. v. 41, n. S1. 2020. Disponível em: https://doi.org/10.1002/joc.6751. Acesso em janeiro de 2023.

ANJOS, D. M. D.; BAKKE, I. A.; SIMÕES, E. M.; et al. Spatial - Temporal Analysis of the Use and Land Cover in the Rio da Cruz Micro Basin of the Semi-arid Region of Paraíba, Using

Remote Sensing. Journal of Experimental Agriculture International. p. 1–13, 26. 2019. Disponível em: https://doi.org/10.9734/jeai/2019/v39i430341. Acesso em janeiro de 2023.

ANTONGIOVANNI, M.; VENTICINQUE, E. M.; MATSUMOTO, M.; et al. Chronic anthropogenic disturbance on Caatinga dry forest fragments. **Journal of Applied Ecology**. v. 57, n. 10, p. 2064–2074. 2020. Disponível em: https://doi.org/10.1111/1365-2664.13686>. Acesso em janeiro de 2023.

ARAÚJO FILHO, J. A.. **Manejo pastoril sustentável da Caatinga**. Projeto Dom Helder Câmara: Recife – PE. 2013. 200 p. ISBN: 978-85-64154-04-9. Disponível em: <https://repositorio.iica.int/bitstream/11324/4209/1/BVE17099221p.pdf>. Acesso em janeiro de 2023.

BECK, H. E.; ZIMMERMANN, N. E.; MCVICAR, T. R.; et al.. Present and future Köppen-Geiger climate classification maps at 1-km resolution. **Scientific Data**. v. 5, n. 1. 2018. Disponível em: < https://doi.org/10.1038/sdata.2018.214>. Acesso em janeiro de 2023.

BELLARD, C.; LECLERC, C; LEROY, B.; et al. Vulnerability of biodiversity hotspots to global change. **Global Ecology and Biogeography**. v. 23, n. 12, p. 1376–1386. 2014. Disponível em: https://doi.org/10.1111/geb.12228>. Acesso em janeiro de 2023.

BRASIL NETO, R. M.; SANTOS, C. A. G.; COSTA SILVA, J. F. C. B.; et al.. Evaluation of the TRMM product for monitoring drought over Paraíba State, northeastern Brazil: a trend analysis. **Scientific Reports**, v. 11, n. 1. 2021. Disponível em: https://doi.org/10.1038/s41598-020-80026-5>. Acesso em janeiro de 2023.

BRASIL. **Lei nº 12.187, de 29 de dezembro de 2009**. Política Nacional sobre Mudança do Clima – PNMC. Casa Civil, Brasília: DF. 2009. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/l12187.htm>. Acesso em janeiro de 2023.

BURNEY, J., CESANO, D., RUSSELL, J.; *et al.* Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. **Climatic Change.** v. 126, p. 45–59. 2014. Disponível em: https://doi.org/10.1007/s10584-014-1186-0>. Acesso em novembro de 2022.

CAMPOS, F. S.; GOIS, G. C.; VICENTE, S. L. A.; et al.. Alternativa de forragem para caprinos e ovinos criados no semiárido. **Nutritime Revista Eletrônica [on-line]**. v.14, n.2, p.5004 -5013. 2017. Disponível em: <https://www.nutritime.com.br/arquivos_internos/artigos/Artigo_416.pdf>. Acesso em janeiro de 2023.

CARNEIRO, W. M. A. Comportamento da Pecuária do Nordeste no Limiar do Século XXI. **Revista BNB Conjuntura Econômica.** Edição Especial 15 Anos. 2019. Disponível em: https://www.bnb.gov.br/etene/conjuntura-economica/edicao-especial-15-anos. Acesso em janeiro de 2023.

CAVALCANTE JÚNIOR, R.; FREITAS, M. A. V.; SILVA, N. F.; et al.. Sustainable Groundwater Exploitation Aiming at the Reduction of Water Vulnerability in the Brazilian Semi-Arid Region. **Energies**. v. 12, n. 5, p. 904. 2019. Disponível em: https://doi.org/10.3390/en12050904>. Acesso em janeiro de 2023.

CHAVES, I. B.; LOPES, V. L.; FFOLLIOTT, P. F.; SILVA, A. P. P.. Uma Classificação Morfo-Estrutural para Descrição e Avaliação da Biomassa da Vegetação da Caatinga. *Revista Caatinga*. v. 21, n. 2, 2008. Disponível em: <https://periodicos.ufersa.edu.br/index.php/caatinga/article/view/750/367>. Acesso em fevereiro de 2022.

COELHO, V. H. R.; MONTENEGRO, S. M. G. L.; ALMEIDA, C. N.; et al.. Dinâmica do Uso e Ocupação do Solo em uma Bacia Hidrográfica do Semiárido Brasileiro. **Revista Brasileira de Engenharia Agrícola e Ambiental.** v.18, nº 1, p. 64 – 72, 2013. Disponível em: http://www.scielo.br/pdf/rbeaa/v18n1/v18n1a09.pdf>. Acesso janeiro de 2023.

DANTAS, J. C.; DA SILVA, R. M.; SANTOS, C. A. G. Drought impacts, social organization, and public policies in northeastern Brazil: a case study of the upper Paraíba River basin. **Environmental Monitoring and Assessment**. v. 192, n. 5. 2020. Disponível em: https://doi.org/10.1007/s10661-020-8219-0>. Acesso em janeiro de 2023.

DE ALCÂNTARA, L. R. P.; COUTINHO, A. P.; SANTOS NETO, S. M.; et al.. Modeling of the Hydrological Processes in Caatinga and Pasture Areas in the Brazilian Semi-Arid. **Water**.

v. 13, n. 13, p. 1877. 2021. Disponível em: https://doi.org/10.3390/w13131877>. Acesso em janeiro de 2023.

DE NYS, E.; ENGLE, N.L.; MAGALHÃES, A.R. Secas no Brasil: Política e Gestão Proativas; Centro de Gestão e Estudos Estratégicos-CGEE: Brasília – DF. 2016. Disponível em: <https://www.cgee.org.br/documents/10195/734063/seca_brasil-web.pdf/793de1a2-157e-4098-b84a-9d2348266252?version=1.4>. Acesso em janeiro de 2023.

DIFFENBAUGH, N. S.; SINGH, D.; MANKIN, J. S.; et al.. Quantifying the influence of global warming on unprecedented extreme climate events. **Proceedings of the National Academy of Sciences**. v. 114, n. 19, p. 4881–4886. 2017. Disponível em: https://doi.org/10.1073/pnas.1618082114>. Acesso em janeiro de 2023.

EMBRAPA – Empresa Brasileira De Pesquisa Agropecuária. **Sistema Brasileiro de Classificação de Solos**. 2^a ed. Brasília – DF, 2006. 286p. Disponível em: <https://www.agrolink.com.br/downloads/sistema-brasileiro-de-classificacao-dossolos2006.pdf>. Acesso em novembro de 2022.

ENAHORO, D.; LANNERSTAD, M.; PFEIFER, C.; et al.. Contributions of livestock-derived foods to nutrient supply under changing demand in low- and middle-income countries. **Global Food Security**. v. 19, p. 1–10. 2018. Disponível em: https://doi.org/10.1016/j.gfs.2018.08.002>. Acesso em janeiro de 2023.

FERNANDES NETO, S.; MADRUGA, P. R. A. Geotecnologias. In: ROCHA, A. P. T. (Org.).
Manejo Ecológico Integrado de Bacias Hidrográficas no Semiárido Brasileiro. Vol. 2. 1^a
ed. Campina Grande – PB: Epgraf, 2012. p. 96 – 228.

FERNANDES, M. M.; FERNANDES, M. R. M.; GARCIA, J. R.; *et al.* Land use and land cover changes and carbon stock valuation in the São Francisco river basin, Brazil. **Environmental Challenges**. v. 5, article: 100247. 2021. Disponível em: https://doi.org/10.1016/j.envc.2021.100247>. Acesso em novembro de 2022.

FERNANDEZ, J. P. R.; FRANCHITO, S. H.; RAO, V. B. Future Changes in the Aridity of South America from Regional Climate Model Projections. **Pure and Applied Geophysics**. v.

176, n. 6, p. 2719–2728, 24. 2019. Disponível em: https://doi.org/10.1007/s00024-019-02108-4>. Acesso em janeiro 2023.

FRANCISCO, P. R. M.; CHAVES, I. B.; CHAVES, L. H. G.; et al.. Mapeamento da Vulnerabilidade das Terras da Bacia Hidrográfica do Rio Taperoá (Mapping the Vulnerability of the Land of River Basin Taperoá). **Revista Brasileira de Geografia Física**. v. 6, n. 2, p. 271–286. 2013. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe/article/view/232951/26920>. Acesso em janeiro de 2023.

GEE – Google Earth Engine. A planetary-scale platform for Earth science data & analysis.
2023. Disponível em: https://earthengine.google.com/. Acesso em janeiro de 2023.

GOMES, M. G.; VARGAS, T.; BELLADONA, R.; et al.. Aplicação do Interpolador IDW para elaboração de Mapas Hidrogeológicos Paramétricos na Região da Serra Gaúcha. **Scientia Cum Industria**. v.6, p. 38–43. 2018. Disponível em: http://dx.doi.org/10.18226/23185279.v6iss3p38>. Acesso em novembro de 2022.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo Agro 2017**. 2021. Disponível em: https://censos.ibge.gov.br/agro/2017/templates/censo_agro/resultadosagro/pecuaria.html?loc alidade=0&tema=75657>. Acesso em março de 2022.

INMET – Instituto Nacional de Meteorologia. **Dados Históricos Anuais**. 2021. Disponível em: https://portal.inmet.gov.br/dadoshistoricos. Acesso em novembro de 2022.

INSA – Instituto Nacional do Semiárido. **Semiárido Brasileiro.** 2023. Disponível em: https://www.gov.br/insa/pt-br/semiarido-brasileiro>. Acesso em janeiro de 2023.

IPCC. **The Intergovernmental Panel on Climate Change**. 2021. Disponível em: https://www.ipcc.ch/. Acesso em novembro de 2022.

JARDIM, A. M. R. F.; ARAÚJO JÚNIOR, G. N.; SILVA, M. V.; et al.. Using Remote Sensing to Quantify the Joint Effects of Climate and Land Use/Land Cover Changes on the Caatinga

Biome of Northeast Brazilian. **Remote Sensing**. v. 14, n. 8, p. 1911. 2022. Disponível em: https://doi.org/10.3390/rs14081911>. Acesso em janeiro de 2023.

KAISER, H. F. The varimax criterion for analytic rotation in factor analysis. **Psychometrika.** v. 23, n. 3, p. 187–200. 1958. Disponível em: https://doi.org/10.1007/BF02289233. Acesso em janeiro de 2022.

LAPIG/UFG. Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás. **Áreas de Pastagem.** 2023. Disponível em: <https://atlasdaspastagens.ufg.br/assets/hotsite/documents/metodos/pt/%C3%81rea%20de%2 0Pastagem.pdf>. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Pastagens Brasileiras Ocupam Área Equivalente a todo o Estado do Amazonas**. 2023. Disponível em: https://mapbiomas.org/pastagens-brasileiras-ocupam-area-equivalente-a-todo-o-estado-do-amazonas. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Plataforma de Mapas e Dados**. 2021. Disponível em: http://plataforma.mapbiomas.org/map>. Acesso em outubro de 2022.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; et al. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**. v. 90, n. 2 suppl 1, p. 1973–1985. 2018. Disponível em: https://doi.org/10.1590/0001-3765201720170206>. Acesso em novembro de 2022.

MARGULIS, S. **Guia de adaptação à mudança do clima para entes federativos.** WWF-Brasil: Brasília – DF. 2017. Disponível em: <https://d3nehc6yl9qzo4.cloudfront.net/downloads/guia_adaptacao_wwf_iclei_revfinal_01de z_2.pdf>. Acesso em janeiro de 2023.

MCFEETERS, S. K.. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**. v.17:7, p. 1425-1432. 1996. Disponível em: https://doi.org/10.1080/01431169608948714>. Acesso em novembro de 2022.

MEDEIROS, A. S.; MAIA, S. M. F.; SANTOS, T. C.; et al.. Soil carbon losses in conventional farming systems due to land-use change in the Brazilian semi-arid region. Agriculture, Ecosystems & Environment. v. 287, p. 106690. 2020. Disponível em: https://doi.org/10.1016/j.agee.2019.106690>. Acesso em janeiro de 2023.

MEDEIROS, S. S. Estabelecimentos Agropecuários do Semiárido Brasileiro. 1º. ed. Campina Grande: Instituto Nacional do Semiárido, 2018, 149 p.

MONTENEGRO, A. A.; RAGAB, R. Hydrological response of a Brazilian semi-arid catchment to different land use and climate change scenarios: a modelling study. Hydrological Processes. 2010. 24. 2705 - 2723. Disponível em: http://dx.doi.org/10.1002/hyp.7825. Acesso em fevereiro de 2023.

MOURA, M. M.; SANTOS, A. R.; PEZZOPANE, J. E. M.; et al. Relation of El Niño and La Niña phenomena to precipitation, evapotranspiration and temperature in the Amazon basin. **Science of The Total Environment**. v. 651, p. 1639–1651. 2019. Disponível em: https://doi.org/10.1016/j.scitotenv.2018.09.242>. Acesso em janeiro de 2023.

OLIVEIRA, M. L.; SANTOS, C. A. C.; OLIVEIRA, G.; et al.. Effects of human-induced land degradation on water and carbon fluxes in two different Brazilian dryland soil covers. **Science of The Total Environment**. v. 792, p. 148458. 2021. Disponível em: https://doi.org/10.1016/j.scitotenv.2021.148458>. Acesso em janeiro de 2023.

OLIVEIRA-JÚNIOR, J. F.; SHAH, M.; ABBAS, A.; et al.. Spatiotemporal Analysis of Fire Foci and Environmental Degradation in the Biomes of Northeastern Brazil. **Sustainability**. v. 14, n. 11, p. 6935. 2022. Disponível em: https://doi.org/10.3390/su14116935>. Acesso em janeiro de 2023.

OYAMA, M. D.; NOBRE, C. A. A new climate-vegetation equilibrium state for Tropical South America. **Geophysical Research Letters**. v. 30, n. 23. 2003. Disponível em: https://doi.org/10.1029/2003GL018600>. Acesso em janeiro de 2023.

PATEL, S. K.; VERMA, P.; SHANKAR SINGH, G. Agricultural growth and land use land cover change in peri-urban India. Environmental Monitoring and Assessment. v. 191, n. 9.

2019. Disponível em: <https://doi.org/10.1007/s10661-019-7736-1>. Acesso em janeiro de 2023.

PINHO, P. F.; ANJOS, L. J. S.; RODRIGUES-FILHO, S.; et al.. Projections of Brazilian biomes resilience and socio-environmental risks to climate change. Sustentabilidade em Debate. v. 11, n. 3, p. 225–259. 2020. Disponível em: https://doi.org/10.18472/SustDeb.v11n3.2020.33918>. Acesso em janeiro de 2023.

QUEIROZ, M. G.; SILVA, T. G. F.; ZOLNIER, S.; et al.. Spatial and temporal dynamics of soil moisture for surfaces with a change in land use in the semi-arid region of Brazil. **CATENA**. v. 188, p. 104457. 2020. Disponível em https://doi.org/10.1016/j.catena.2020.104457. Acesso em janeiro de 2023.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, 2021.

REBOITA, M. S.; KUKI, C. A. C.; MARRAFON, V. H.; et al.. South America climate change revealed through climate indices projected by GCMs and Eta-RCM ensembles. **Climate Dynamics**. v. 58, n. 1-2, p. 459–485. 2021. Disponível em: https://doi.org/10.1007/s00382-021-05918-2>. Acesso em janeiro de 2023.

ROSA, R. Geotecnologias na Geografia Aplicada. **Revista do Departamento de Geografia**. v. 16. p. 81–90. 2005. Disponível em: https://doi.org/10.7154/RDG.2005.0016.0009>. Acesso em janeiro de 2023.

ROUSE, R.; HAAS, J.; DEERING, D. Monitoring vegetation systems in the Great Plains with ERTS. **Goddard Space Flight Center 3d ERTS-1 Symp**. vol. 1, Sect A. 1974. Disponível em: https://ntrs.nasa.gov/api/citations/19740022614/downloads/19740022614.pdf>. Acesso em novembro de 2023.

SANTOS, A. C.. Política Nacional sobre Mudança do Clima no Brasil: uma avaliação de instrumentos e de efetividade. **Revista de Políticas Públicas da UFPE**. 6. 2021 Disponível em: http://hdl.handle.net/10451/47059. Acesso em janeiro de 2023.

SANTOS, A.; LOPES, P. M. O.; SILVA, M. V.; et al.. Causes and consequences of Seasonal changes in the water flow of the São Francisco river in the semiarid of Brazil. **Environmental and Sustainability Indicators**. v. 8, 1–15. 2020. Disponível em: https://doi.org/10.1016/j.indic.2020.100084>. Acesso em novembro de 2022.

SENEVIRATNE, S. I.; NICHOLLS, N.; EASTERLING, D.; et al.. Changes in Climate Extremes and their Impacts on the Natural Physical Environment. **Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation**. p. 109–230. 2012. Disponível em: https://doi.org/10.1017/CBO9781139177245.006>. Acesso em janeiro de 2023.

SILVA JÚNIOR, F. A. P.; SALLES, M. G. F.; PINTO, C. M.; et al.. A bovinocultura leiteira na agricultura familiar do município de Barreira, CE. **Enciclopédia Biosfera**. v.16, n.28, p.1-10. 2018. Disponível em: http://doi.org/10.18677/EnciBio_2018B1). Acesso em janeiro de 2023.

SILVA, J. L. B.; MOURA, G. B. A.; SILVA, M. V.; et al.. Environmental degradation of vegetation cover and water bodies in the semiarid region of the Brazilian Northeast via cloud geoprocessing techniques applied to orbital data. Journal of South American Earth Sciences.
v. 121, p. 104164. 2023. Disponível em: https://doi.org/10.1016/j.jsames.2022.104164>.
Acesso em janeiro de 2023.

SILVA, J. R. I.; MONTENEGRO, A. A. A.; FARIAS, C. W. L. A.; et al.. Morphometric characterization and land use of the Pajeú river basin in the Brazilian semi-arid region. Journal of South American Earth Sciences, v. 118, p. 103939. 2022. Disponível em: https://doi.org/10.1016/j.jsames.2022.103939. Acesso em janeiro de 2023.

SILVA, M. V.; PANDORFI, H.; ALMEIDA, G. L. P.; et al.. Spatio-temporal monitoring of soil and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semiarid region. **Journal of South American Earth Sciences**. v. 107, p. 103155. 2021. Disponível em: https://doi.org/10.1016/j.jsames.2021.103155. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; LOPES, P. M. O.; et al.. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid.

Remote Sensing Applications: Society and Environment. v. 19, p. 100353, 2020. Disponível em: https://doi.org/10.1016/j.rsase.2020.100353>. Acesso em novembro de 2022.

STRASSBURG, B. B. N.; IRIBARREM, A.; BEYER, H. L.; et al.. Global priority areas for ecosystem restoration. **Nature**. v. 586, n. 7831, p. 724–729. 2020. Disponível em: https://doi.org/10.1038/s41586-020-2784-9>. Acesso em janeiro de 2023.

UNFCCC – United Nations Framework Convention on Climate Change. National AdaptationPlans: Technical guidelines for the national adaptation plan process. ISBN: 92-9219-102-0.150pp.2012.Disponívelem:<https://unfccc.int/files/adaptation/cancun_adaptation_framework/application/pdf/naptechgui</td>delines_eng_high_res.pdf>. Acesso em janeiro de 2023.

United States Geological Survey/National USGS/NASA. Aeronautics and Space Administration. Landsat Satellite Missions. 2022. Disponível em: <https://www.usgs.gov/landsat-missions/landsat-satellite-missions>. Acesso em novembro de 2022.

VAGHEFI, S.A.; ABBASPOUR, N.; KAMALI, B.; et al.. A toolkit for climate change analysis and pattern recognition for extreme weather conditions e Case study: California-Baja California Peninsula. **Environmental Modelling & Software**. 96, 181-198. 2017. Disponível em: http://dx.doi.org/10.1016/j.envsoft.2017.06.033>. Acesso em janeiro de 2023.

VIEIRA, R. M. D. S. P.; TOMASELLA, J.; BARBOSA, A. A.; et al.. Desertification risk assessment in Northeast Brazil: Current trends and future scenarios. Land Degradation & Development. v. 32, n. 1, p. 224–240. 2020. Disponível em: https://doi.org/10.1002/ldr.3681>. Acesso em janeiro de 2023.

WARRICK, A. W.; NIELSEN, D. R.. Spatial variability of soil physical properties in the field. In: HILLEL, D. (Ed.). **Applications of Soil Physics**. New York: Academic. 2, 319-344, 1980.

XU, H.. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**. v. 27, p.

3025-3033. 2006. Disponível em: https://doi.org/10.1080/01431160600589179>. Acesso em novembro de 2022.

YANG, Z.; ZHANG, Q.; HAO, X.; et al.. Changes in Evapotranspiration Over Global Semiarid Regions 1984–2013. **Journal of Geophysical Research: Atmospheres**. v. 124, n. 6, p. 2946– 2963. 2019. Disponível em: https://doi.org/10.1029/2018JD029533>. Acesso em janeiro de 2023.

YUAN, Q.; SHEN, H.; LI, T.; et al. Deep learning in environmental remote sensing: Achievements and challenges. **Remote Sensing of Environment**. v. 241, p. 111716. 2020. Disponível em: https://doi.org/10.1016/j.rse.2020.111716>. Acesso em janeiro de 2023.

CAPÍTULO II

IMPACTO CAUSADO PELA CONDIÇÃO HÍDRICA E MUDANÇA DA COBERTURA VEGETAL NA BACIA HIDROGRÁFICA DO RIO IPANEMA, REGIÃO NORDESTE DO BRASIL

RESUMO: A escassez hídrica no semiárido brasileiro, associado a dinâmica e aplicabilidade de atividades de viés antrópico, implicam substancialmente na degradação nas Bacias Hidrográficas do Bioma Caatinga. O objetivo do estudo foi realizar a caracterização e detecção de mudança hídrica e cobertura vegetal nos municípios das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na Bacia Hidrográfica do Rio Ipanema, região Nordeste do Brasil. Mapas de padrões e variabilidade das chuvas, uso e cobertura da terra (LULC), Índice de Diferença Normalizada da Água (NDWI), Índice de Vegetação de Diferença Normalizada (NDVI), Índice de Biomassa da Vegetação Lenhosa (IBVL) e Índice de Vulnerabilidade da Vegetação (IVV) foram confeccionados no software QGIS 3.22. Para os padrões e variabilidade de chuvas, os valores dos pixels foram extraídos e submetidos ao método de interpolação Distância Inversa Ponderada (IDW). Verificou-se a relação inversa entre as classes de uso do solo Florestal, Agricultura e Pecuária, na qual, ao longo do período houve uma diminuição da área de floresta (Caatinga) em detrimento do aumento da área agropecuária. No período seco houve maior disponibilidade hídrica em 2010, 2017, 2018, 2019 e 2020, já os anos de 2013 a 2016 apresentaram as menores incidências de corpos d'água. No período chuvoso verificou-se que a alta incidência de nuvens na região afetou as análises por meio do NDWI. Quando comparado a diferença anual entre as imagens de 2010 a 2020, no período seco e chuvoso, prevaleceu a redução hídrica na maior parte da Bacia Hidrográfica. Para o NDVI foram encontrados valores que variaram de -0,52 a 0,80 no período seco e -0,56 a 0,99 para o período chuvoso, corroborando com os dados observados no LULC. O IBVL demonstrou a classe majoritária da área é composta por uma vegetação Subarbustiva seguida pela classe Arbustiva no período seco e Arbórea no período chuvoso. O IVV demonstrou que no período seco prevaleceu a classe de risco moderado e no período chuvoso a classe de risco muito baixo. Os resultados evidenciam que as secas no Nordeste Brasileiro (NEB) continuam presentes até os dias atuais, decorrentes das mudancas climáticas, ocasionando o aumento do déficit hídrico, associado à ação antrópica, que resulta em forte degradação ambiental em um dos ecossistemas mais ameaçados e de significativa extensão territorial.

PALAVRAS–CHAVE: caatinga, corpos de água, geoprocessamento, mudanças climáticas, uso e cobertura da terra.

IMPACT CAUSED BY WATER CONDITION AND CHANGE IN PLANT COVER IN THE IPANEMA RIVER RIVER BASIN, NORTHEAST REGION OF BRAZIL

ABSTRACT: Water restriction in the Brazilian semi-arid region, associated with the dynamics and applicability of activities with an anthropic bias, imply a reduction in degradation in the Caatinga Biome Watersheds. The objective of the study was to perform the characterization and detection of water change and vegetation cover in the municipalities of the dairy basins of the states of Alagoas and Pernambuco inserted in the Ipanema River Basin, Northeast region of Brazil. Maps of patterns and variability of rainfall, land use and land cover (LULC), Water Normalized Difference Index (NDWI), Normalized Difference Vegetation Index (NDVI), Woody Vegetation Biomass Index (IBVL) and Vulnerability Index of Vegetation (IVV) were made in QGIS 3.22 software. For rainfall patterns and variability, pixel values were extracted and confirmed to the Inverse Distance Weighted (IDW) interpolation method. There was an inverse relationship between the Forest, Agricultural and Livestock land use classes, in which, over the period there was a decrease in the forest area (Caatinga) to the detriment of the increase in the agricultural area. In the dry period there was greater water availability in 2010, 2017, 2018, 2019 and 2020, while the years 2013 to 2016 tolerate the lowest incidence of water bodies. In the rainy season, the high incidence of clouds in the region affected the analyzes using the NDWI. When comparing the annual difference between the images from 2010 to 2020, in the dry and rainy season, water reduction prevailed in most of the Hydrographic Basin. For the NDVI, values were found that varied from -0.52 to 0.80 in the dry period and -0.56 to 0.99 for the rainy period, corroborating the data observed in LULC. The IBVL demonstrated that the majority class of the area is composed of a Subshrub vegetation followed by the Shrub class in the dry season and Arboreal in the rainy season. The IVV showed that the moderate risk class prevailed in the dry season and the very low risk class in the rainy season. The results show that droughts in Northeast Brazil (NEB) are still present today, due to climate change, causing an increase in the water deficit, associated with anthropic action, which results in strong environmental degradation in one of the most threatened ecosystems and of significant territorial extension.

KEY WORDS: caatinga, water bodies, geoprocessing, climate change, land use and land cover.

2.1. INTRODUÇÃO

A água é um recurso natural essencial para a manutenção da vida (Perlin et al., 2019) por se tratar de um elemento representativo dos valores socioculturais e fator de produção de bens de consumo e produtos agrícolas, assim como na produção industrial e abastecimento humano (Anderson et al., 2019; Santiago et al., 2022).

Nas últimas décadas, tem sido dada atenção global a água e, portanto, desencadeando diversas discussões sobre o uso sustentável dos recursos hídricos (Di Baldassarre et al., 2019). Enfrentar a escassez e garantir água de qualidade, e em quantidade, para atender à crescente população mundial de forma sustentável, tem sido uma das grandes preocupações e prioridades (Boretti e Rosa, 2019) na tomada de decisão para o desenvolvimento de políticas de planejamento e gestão, dirigida a mitigação da escassez de água em escalas global, regional e local (Zhang et al., 2019; Viviroli, et al., 2020; Huang et al., 2021).

A escassez hídrica no semiárido brasileiro, associada às atividades antrópicas, interferem de forma substancial na degradação da Caatinga, que por sua vez é considerado um dos biomas mais sensíveis das Américas (Seddon et al., 2016; Salvatierra et al., 2017; Oliveira et al., 2021), ocupando uma área de cerca de 844.453 km², o equivalente a 11% do território nacional (IBGE, 2019). Diante disso, as investigações sobre os impactos no uso e cobertura do solo, refletem diretamente na degradação hídrica de rios e bacias hidrográficas (Brasil Neto et al, 2021), o que contribui com a expansão de núcleos de aridez no Nordeste do Brasil (NEB), ampliando os processos de desertificação neste bioma (Antongiovanni et al., 2020; Silva et al., 2021).

Segundo Burney et al. (2014) e Oliveira et al. (2021) modelos matemáticos, físicos e estatísticos demonstram o grande impacto das mudanças climáticas, principalmente na hidrologia das regiões semiáridas, que por sua vez afetam a vazão dos rios, o armazenamento de água e a produtividade agropecuária e, ainda indicam uma redução substancial da disponibilidade das águas superficiais. Ledru et al. (2020), Vieira et al. (2020) e Bhering et al. (2021) afirmam que as populações em áreas semiáridas são vulneráveis à variabilidade climática e disponibilidade de água e, portanto, potencialmente vulneráveis às condições de mudança climática, com anos hidrológicos de chuvas abaixo da média e secas severas frequentes.

Todas essas projeções são observadas quando se considera os extensos períodos anuais de seca no semiárido brasileiro, com destaque para a década de 2011 a 2020, considerada uma das mais graves, principalmente entre os anos de 2012 e 2016 de seca severa (Silva et al., 2020a; Costa et al., 2021b; Silva et al., 2023). Por isso, as regiões semiáridas do Brasil têm recebido atenção especial, períodos frequentes de seca aumentaram sua gravidade e extensão espacial (Ledru et al., 2020; Van Langen et al., 2021), com isso proporcionaram condições climáticas e hidrológicas extremas e altamente dinâmicas, com baixa precipitação e aumento da escassez de água (Correia Filho et al., 2019; Silva et al., 2020a).

Na região semiárida brasileira predomina a agropecuária de subsistência, na maioria das vezes prejudicada pelas estiagens, ou seja, o setor agropecuário ainda é a base da sociedade rural e a principal atividade econômica da maioria dos pequenos municípios da região (Martins et al., 2017; Silva et al., 2020b; Fernandes et al., 2021; Silva et al., 2023).

De acordo com Costa et al. (2021a) a maior parte da produção agropecuária da região provém da agricultura familiar, seja para subsistência ou para comercialização. Esses agricultores, em sua grande maioria, possuem pouca capacidade de investimento e baixa resiliência aos eventos de seca, levando a alta vulnerabilidade social e grande insegurança alimentar e econômica. Corroborando, Medeiros et al. (2020) e Vieira et al. (2020) ressaltam que o sistema agrícola predominante nessa região é a agricultura de sequeiro, geralmente em pequenas propriedades, que cultivam lavouras de subsistência com queima de vegetação nativa e preparo convencional do solo em paralelo à pecuária extensiva.

Dessa forma, a adaptação dos sistemas agropecuários às mudanças climáticas significa o uso de tecnologias e práticas que podem usar a biodiversidade, os serviços ecossistêmicos e os processos ecológicos do bioma para aumentar a capacidade adaptativa de culturas e pecuária às mudanças nas condições climáticas, trazendo benefícios financeiros para os produtores rurais e benefícios econômicos, sociais e ambientais para a sociedade (Marengo et al., 2021). Como exemplo podem ser citados os sistemas agroflorestais com animais, o manejo agroecológico de pastagens, agricultura de conservação e a integração lavoura-pecuária-floresta (Balbino et al., 2012).

A Bacia Hidrográfica do Rio Ipanema (BHRI), está inserida no bioma Caatinga com clima semiárido, sendo localizada em uma das principais bacias leiteiras dos Estados de Pernambuco e Alagoas, destaque para a pecuária leiteira, com dinâmica expansionista de áreas para produção de alimento e o fornecimento de forragem para o gado (Silva et al., 2020b;

Fernandes et al., 2021). A principal via de degradação do bioma nesta região, é decorrente das péssimas técnicas de manejo do uso e cobertura do solo, no qual, após a degradação de determinada área, é comum os produtores procurarem novas áreas, ao invés de aplicar técnicas de conservação do solo e da vegetação natural (Guerra et al., 2020; Silva et al., 2020a; Pereira et al., 2021), como o plantio de espécies nativas, manejo de pastagens e o manejo da água.

Diante desse cenário, as mudanças climáticas aumentarão o risco e a gravidade da seca (IPCC, 2021), com impacto significativo na agropecuária brasileira, seguido da recorrência de secas que afetam a produtividade das culturas, do rebanho e a segurança alimentar (Marengo et al., 2021), tal fato acarretará prejuízos sociais, afetando inclusive, os fluxos de migração ruralurbana e econômicos significativos nas escalas local (municípios e comunidades), regional e nacional no Brasil (Delazeri et al., 2021).

A vegetação é o principal componente dos ecossistemas terrestres na Terra e impacta no balanço hídrico regional e global, no valor do serviço ecossistêmico e na troca de energia de superfície (Yang et al., 2019). O Índice de Vegetação de Diferença Normalizada (NDVI) é sensível à fenologia e é frequentemente usado como o melhor indicador de crescimento da vegetação e mudança de cobertura (Huang et al., 2020), também tem sido amplamente utilizado no estudo de mudanças na vegetação em diferentes escalas. A dinâmica da vegetação e as respostas às mudanças climáticas têm sido reconhecidas como uma questão central da mudança global nos ecossistemas terrestres (Pan et al., 2018).

Dada a importância da gestão dos recursos hídricos, o sensoriamento remoto (SR) se destaca como técnica capaz de preencher lacunas temporais e espaciais que existem nos programas de monitoramento usuais (Teixeira et al., 2021). O uso de imagens de satélite para identificar dados hídricos tem sido realizada em diversas áreas de pesquisa, destaque para o Índice de Diferença Normalizada da Água (NDWI) proposta por McFeeters (1996) que destaca as características da água e minimiza outros alvos (Deng et al., 2020). O NDWI fornece informações sobre refletância de superfície e disponibilidade de água, com respostas importantes sobre as condições ambientais no semiárido, por exemplo, a detecção de secas, favorecendo as atividades agropecuárias, historicamente importantes para subsistência da população do semiárido nordestino (Silva et al., 2020).

O uso do geoprocessamento em conjunto com técnicas de sensoriamento remoto (SR) e imagens de satélite é alternativas para a realização do monitoramento da vulnerabilidade do solo, caracterização pluviométrica, bem como na detecção de mudanças nos corpos d'água, tornando-se fundamental e economicamente viável para a compreensão das dinâmicas espaçotemporais de mudanças na cobertura e uso da terra e especialmente em cursos de água (Marengo et al., 2018; Santos et al., 2020).

Assim, a utilização de imagens de satélite é capaz de fornecer padrões de mudanças, que pode ser usado para inferir variações da superfície, sendo uma ferramenta útil para os estudos de recursos hídricos, pois fornece informações atualizadas a custos baixos e auxilia no monitoramento das bacias hidrográficas (Washington et al., 2019; Kim et al., 2020).

Nesse contexto, objetivou-se com este estudo realizar a caracterização pluviométrica e a detecção de mudança hídrica e cobertura vegetal nos municípios das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na Bacia Hidrográfica do Rio Ipanema, região Nordeste do Brasil.

2.2. MATERIAL E MÉTODOS

2.2.1. Área de estudo

A área de estudo localiza-se entre os paralelos 08°18'04" S – 10°0' S e os meridianos 36°0' W e 38°0' W (Figura 3), com altitudes inferiores a 1.115 m e no Bioma Caatinga (MAPBIOMAS BRASIL, 2021). De acordo com a classificação climática proposta por Köppen-Geiger, o clima é predominantemente do tipo BSh e As, clima semiárido quente (Alvares et al., 2013; Beck et al., 2018), com temperatura máxima ocorrendo nos meses de novembro a janeiro (33 °C) e mínimas nos meses de maio a julho (19 °C) com temperaturas médias anuais superiores a 23°C, o período chuvoso está mais concentrado entre os meses de março a julho, com média anual inferior a 700 mm (INMET, 2021). A média anual da evapotranspiração potencial também é elevada, com índices que podem ser superiores a 1.600 mm (Montenegro; Ragab, 2010).



Figura 3. Localização espacial da área de estudo. (A) Delimitação do leito principal do Rio Ipanema e identificação do exutório; (B) Hipsometria com base no modelo de elevação digital (DEM) Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m; (C) Classificação climática de Köppen-Geiger, Bacia Hidrográfica do Rio Ipanema, Pernambuco e Alagoas, Brasil.

As bacias leiteiras de Pernambuco e Alagoas estão inseridas na Bacia Hidrográfica do Rio Ipanema (BHRI), com área de aproximadamente 7.850 km² (IBGE, 2021), localizada, em sua maior parte no Estado de Pernambuco, com sua porção sul no Estado de Alagoas (Figura 4) e está inserida, respectivamente, dentro de dois importantes níveis hidrográficos: a grande Bacia Hidrográfica do Rio São Francisco (macrorregião) e a Bacia Hidrográfica do Baixo São Francisco (mesorregião) (IBGE, 2021).



Figura 4. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na BHRI.

De acordo com o Censo Agro de 2017 (IBGE, 2021) Alagoas apresentava rebanho efetivo de 786.018 cabeças (17,6% - Bacia do Rio Ipanema), sendo 81.599 vacas de leite (41,8% - BHRI), que gerou produção de 188.628 (x1.000) kg de leite (51,3% - BHRI). Já Pernambuco, contava com 1.284.796 cabeças (22,5% - BHRI), sendo 222.344 vacas de leite (40,8% - BHRI) e produção de 520.990 (x1.000) kg de leite (56,1% - BHRI), distribuídos em 18 municípios pernambucanos (Águas Belas, Alagoinha, Arcoverde, Bom Conselho, Buíque, Caetés, Capoeiras, Garanhuns, Iati, Ibimirim, Itaíba, Manari, Paranatama, Pedra, Pesqueira, Saloá, Tupanatinga e Venturosa) e 16 municípios alagoanos (Batalha, Belo Monte, Cacimbinhas, Carneiros, Dois Riachos, Jacaré dos Homens, Jaramataia, Major Isidoro, Maravilha, Minador do Negrão, Olho d'Água das Flores, Olivença, Ouro Branco, Poço das Trincheiras, Santana do Ipanema e Senador Rui Palmeira), conforme a Tabela 8.

	Estado			
—	Alagoas	Pernambuco		
—	Total			
Bovinos	786.018	1.284.796		
Vacas Ordenhadas	81.599	222.344		
Produção de Leite (x1000)	188.628	520.990		
—	Bacia do Rio Ipanema			
Bovinos	138.325	288.580		
Vacas Ordenhadas	34.129	90.785		
Produção de Leite (x1000)	96.778	292.533		
	% Representativa	(Bacia/Total)		
Bovinos	17,6	22,5		
Vacas Ordenhadas	41,8	40,8		
Produção de Leite (x1000)	51,3	56,1		

Tabela 8. Comparação da pecuária leiteira entre o Total por Estado, na Bacia do Rio Ipanema e a porcentagem representativa entre eles.

Fonte: Autores (2022) adaptado de Censo Agro 2017 (IBGE, 2021).

2.2.2. Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI

O estudo foi desenvolvido a partir das imagens orbitais dos Satélites Landsat – 5 (sensor TM) e o Landsat – 8 (sensor OLI) (Tabela 9), referente a órbita/ponto 215/066, sendo disponibilizadas pelo Serviço Geológico dos Estados Unidos (USGS) via Administração Nacional da Aeronáutica e Espaço (NASA). Em média, um total anual de 10 imagens orbitais foram processadas, entre os anos de 2010 e 2020. Ressalta-se que para o ano de 2012, não foi possível a geração dos índices, devido à ausência de cobertura da série Landsat para o período.

Sensor Banda		Resolução	Resolução	Resolução
		Espectral (µm)	Espacial (m)	Temporal
	r1: Azul	0,45 - 0,52	30	
	r2: Verde	0,52 - 0,60	30	
	r3: Vermelho	0,63 - 0,69	,69 30	
TM	r4: Infravermelho Próximo	0,76 - 0,90	30	16 dias
	r5: Infravermelho Médio	1,55 - 1,75	30	
	r6: Infravermelho Termal	10,40 - 12,50	120	
	r7: Infravermelho Médio	2,08 - 2,35	30	
	r1: Costal (Aerosol)	0,43 - 0,45	30	
OLI	r2: Azul	0,45 - 0,51	30	
	r3: Verde	0,53 - 0,59	30	
	r4: Vermelho	0,64 - 0,67	30	
	r5: Infravermelho Próximo	0,85 - 0,88	30	
	r6: SWIR 1	1,57 - 1,65	30	16 dias
	r7: SWIR 2	2,11 - 2,29	30	
	r8: Pancromático	0,50 - 0,68	15	
	r9: Cirrus	1,36 - 1,38	30	
	r10: Infravermelho Termal 1	10,6 - 11,19	100	
	r11: Infravermelho Termal 2	11,50 - 12,51	100	

Tabela 9. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat 8 (OLI).

Fonte: Autores (2022) adaptado de USGS (2022).

Para o desenvolvimento de mapas temáticos de condições hidrológicas e cobertura vegetal a partir de parâmetros geoespaciais e biofísicos, o Índice de Diferença Normalizada da Água (NDWI) e o Índice de Vegetação de Diferença Normalizada (NDVI), foram desenvolvidos, gerenciados e processados automaticamente por meio da plataforma digital em nuvem, Google Earth Engine (GEE) (<u>https://earthengine.google.com/</u>), a partir da linguagem de programação em JavaScript. Essa plataforma inclui bibliotecas com múltiplas funções para análise matemática e modelagem, análises estatísticas e operações de aprendizado de máquina, baseadas em algoritmos específicos para o processamento digital de imagens de satélites (Silva et al., 2022; GEE, 2023).

O conjunto de imagens utilizadas foram oriundas das coleções ee.ImageCollection ("LANDSAT/LT05/C02/T1_L2") e ("LANDSAT/LC08/C02/T1_SR"), sendo adotado como período seco os meses de setembro, outubro, novembro, dezembro e janeiro, e chuvoso os

meses de março, abril, maio, junho e julho, de cada ano, com produtos de reflectância da superfície a partir de 01/01/2010 até 31/12/2020, estabelecendo o critério de nuvens inferior a 20%, no qual, para cada período foi estabelecido a média de todas as imagens dentro do critério de porcentagem de nuvens estabelecido, ressalta-se no entanto, que para o ano de 2011 o critério mínimo de nuvens para o período seco e chuvoso, foi de 30 e 55% respectivamente, pois foram as menores porcentagem de nuvens para que a obtenção de imagens da área. Mapas temáticos foram classificados e confeccionados no QGIS 3.22.

2.2.3. Dados de satélite orbital – TerraClimate

Para caracterizar os padrões e a variabilidade das chuvas, foram utilizados os dados do satélite TerraClimate, que possui resolução temporal mensal, do período de 01/01/2010 a 31/12/2020. O TerraClimate disponibiliza dados de balanço hídrico e climático, com resolução espacial de aproximadamente 4 km, com dados de 1958 até os dias atuais (Abatzoglou et al., 2018).

O conjunto de dados disponibilizados pelo TerraClimate é dividido em variáveis climáticas primárias e secundárias; as variáveis primárias correspondem as temperaturas máxima e mínima, a pressão de vapor, acúmulo de precipitação, radiação de ondas curtas na superfície, e velocidade dos ventos; as variáveis secundárias correspondem a evapotranspiração de referência, o escoamento superficial, a evapotranspiração real, o déficit hídrico climático, umidade do solo, água equivalente à neve, Índice de Severidade da Seca de Palmer (PDSI), e o déficit de pressão de vapor (Silva et al., 2022).

Para o presente estudo, a precipitação anual acumulada (mm) foi utilizada. Os dados foram obtidos na plataforma Climate Engine (Cloud Computing of Climate and Remote Sensing Data), plataforma de processamento das imagens provenientes do TerraClimate, disponibilizadas em: <u>https://app.climateengine.org/climateEngine</u>. Os arquivos raster obtidos para cada imagem foram transformados em arquivos vetoriais de pontos (*extension.shp*) e posteriormente interpolados pela técnica IDW (*Inverse Distance Weighted*), que prediz um valor para algum local não medido utilizando-se os valores amostrados à sua volta, que terão um maior peso do que os valores mais distantes (Gomes et al., 2019). O processamento e os mapas temáticos foram realizados no QGIS 3.22.

2.2.4. Caracterização pluviométrica via estações meteorológicas do Instituto Nacional de Meteorologia (INMET)

A fim de caracterizar as componentes meteorológicas locais, foram utilizados dados de cinco estações meteorológicas do Instituto Nacional de Meteorologia (INMET) disponíveis, inseridas na área de estudo, localizadas nos municípios de Arcoverde, Garanhuns, Ibimirim e Pesqueira (Pernambuco) e Major Isidoro (Alagoas). Os dados foram extraídos para o período que compreende o estudo 2010-2020. Disponíveis no endereço eletrônico: <u>https://portal.inmet.gov.br/</u>.

2.2.5. Dinâmica da cobertura vegetal via MapBiomas Brasil

Para avaliação da cobertura vegetal, foram extraídos dados para região de estudo proveniente da plataforma MapBiomas (MapBiomas Brasil, 2021). Os dados de uso e cobertura do solo se encontram disponíveis no endereço eletrônico: <<u>https://plataforma.brasil.mapbiomas.org/></u>.

O MapBiomas trabalha com o conceito de coleção de dados e atualmente está na versão 7.0. A cada nova coleção todo conjunto de dados pretérito é reprocessado com base nos novos métodos e algoritmos (Silva et al., 2022; MapBiomas Brasil, 2021). Nesse estudo, foi utilizada a coleção de dados da versão 6.0, mais recente à data que o mesmo foi desenvolvido, utilizando um catálogo com 25 classes de legenda, próprio da plataforma, priorizando as classes majoritárias do Nível 1: Floresta (caatinga arbórea), Formação natural não florestal (caatinga arbustiva), Agricultura e Pecuária, Área não vegetada (Infraestrutura Urbana e Solo Exposto) e Corpos hídricos.

Os arquivos raster foram gerados para os anos de 2010 a 2020 para cada tipo de uso do solo e as classes majoritárias foram calculadas pelo plugin "r.report" do software GRASS 7, integrado ao QGIS 3.22.

2.2.6. Índice de Diferença Normalizada da Água (NDWI)

O NDWI é calculado em função das bandas multiespectrais de reflectância de superfície e são indicadores sensíveis de mudanças na terra, na avaliação da disponibilidade de água e avaliação das condições de seca, e seus valores variam de -1 a 1 (Marengo et al., 2018; Silva et al., 2022). O NDWI foi calculado através das bandas reflexivas das imagens do satélite Landsat-5/TM e Landsat-8/OLI, pela diferença normalizada entre duas bandas da imagem, de acordo com a Eq. (1) (McFeeters, 1996; Xu, 2006).

$$NDWI = \frac{r_{b \text{ GREEN}} - r_{b \text{ SWIR}}}{r_{b \text{ GREEN}} + r_{b \text{ SWIR}}}$$
(1)

sendo, $r_{b \text{ GREEN}}$ - faixa refletiva do verde (banda 2 do sensor TM e banda 3 do sensor OLI); e r_{b} _{SWIR} - faixa refletiva do infravermelho médio (banda 5 do sensor TM e 6 do sensor OLI).

O NDWI também foi utilizado para a obtenção das imagens de detecção de mudanças para corpos hídricos e condição hídrica, considerando que valores entre 1 a 0 de NDWI são equivalentes a coberturas de corpos d´água e valores de -1 a 0 correspondem a umidade na vegetação e solo, vegetação e solo exposto.

A detecção de mudanças dos corpos hídricos representa a mudança ocorrida entre imagens ao longo de um determinado intervalo de tempo, na qual duas imagens são comparadas pixel a pixel, o produto dessa comparação é uma imagem que representa a diferença numérica entre os pixels pareados das duas imagens, conforme a Eq. (2).

$$\Delta ij = (Aij (t_i) - Aij (t_n))$$
⁽²⁾

sendo, Δij = valor da diferença dos pixels na linha i e coluna j; Aij (ti) = valor do pixel ij na data i; Aij (tn) = valor do pixel ij na data n.

As imagens foram classificadas pelo software QGIS 3.22 e os limites de cada classe, estabelecidos segundo a Tabela 10.

Tabela 10. Classes e limites de Detecção de Mudanças para Corpos Hídricos (DMCH) de acordo com McFeeters (1996).

Limites de Classe		
-1 a 0		
0 a 0,1		
0,1 a 1		

2.2.7. Índice de Vegetação de Diferença Normalizada (NDVI)

O NDVI é um indicador sensível da condição da cobertura vegetal, com valores variando entre -1 e 1, no qual, quanto mais próximo de 1, maior é a indicação da atividade vegetal fotossinteticamente ativa. Valores de zero e próximos de zero indicam áreas com pouca ou nenhuma vegetação, e valores negativos são referentes a corpos hídricos (Santos et al., 2020). O NDVI foi determinado conforme a Eq. (1) (Rouse et al., 1974):

$$NDVI = \frac{r_{b \text{ NIR}} - r_{b \text{ RED}}}{r_{b \text{ NIR}} + r_{b \text{ RED}}}$$
(1)

Sendo, $r_{b \text{ NIR}} e r_{b \text{ RED}}$, correspondem às respectivas bandas refletivas 4 e 3 do Landsat-5 de sensor TM, e 5 e 4 do Landsat-8 de sensor OLI.

2.2.8. Índice de Biomassa da Vegetação Lenhosa (IBVL)

Através do NDVI foi realizada a reclassificação da vegetação da região de estudo, caracterizada pelo Índice de Biomassa da Vegetação Lenhosa (IBVL), método proposto por Chaves et al. (2008), desenvolvido para descrever e avaliar a vegetação da Caatinga em seus diferentes estágios de antropização. Com o objetivo de realizar o mapeamento do IBVL, por meio do NDVI, foram importadas as imagens de NDVI e realizada a classificação pelo QGIS 3.22, de acordo com a Tabela 11.

Classes de IBVL	Valores de NDVI
Arbórea muito densa	>0,350
Arbórea densa	0,320 a 0,350
Subarbórea densa	0,300 a 0,320
Subarbórea arbustiva densa	0,285 a 0,300
Arbustiva subarbórea densa	0,265 a 0,285
Arbustiva subarbórea aberta	0,250 a 0,265
Arbustiva subarbustiva aberta	0,225 a 0,250
Subarbustiva arbustiva rala	0,200 a 0,225
Subarbustiva arbustiva muito rala	0,150 a 0,200
Solo exposto	0,000 a 0,150
Corpos d'água	-1,000 a 0,000

Tabela 11. Classes de vegetação e valores de reflectância baseados na metodologia de Chaves et al. (2008).

Fonte: Francisco et al. (2013)

2.2.9. Índice de Vulnerabilidade da Vegetação (IVV)

A estimativa do Índice de Vulnerabilidade da Vegetação (IVV) desenvolvida por Chaves et al. (2008), foi determinado pela diferença entre o IBVL (Tabela 12), para uma condição hipotética de máxima preservação e a condição da vegetação que se quis avaliar, conforme a Eq. (2):

$$IVV = \left(\frac{1}{IBVL}\right)$$
(2)

Sendo 1, o valor do IBVL para condição de máxima preservação; e IBVL, o índice de biomassa para a condição de vegetação que se quer avaliar.

Classes de vegetação	Veget	ação	Vulnerabilidade	
Classes de Vegelação	IBVL	IVV	Classes	
Arbórea muito densa	1,00	1,00	Muito Poivo	
Arbórea densa	0,80	1,25	winto Baixa	
Subarbórea densa	0,68	1,47	Baixa	
Subarbórea arbustiva densa	0,60	1,67		
Arbustiva subarbórea densa	0,48	2,08	Modoradaa	
Arbustiva subarbórea aberta	0,36	2,78	wioueradas	
Arbustiva subarbustiva aberta	0,24	4,17	A 1to	
Subarbustiva arbustiva rala	0,14	7,14	Alla	
Subarbustiva arbustiva muito rala	0,07	14,29	Muito Alto	
Solo exposto	0,05	20,00	Multo Alta	

Tabela 12. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade da Vegetação.

Fonte: Adaptado de Francisco et al. (2013)

2.2.10. Análises estatísticas

As imagens de NDVI, NDWI e Precipitação foram submetidas a análise estatística descritiva no QGIS 3.22, para obtenção de máximo, mínimo, média, desvio padrão, variância e coeficiente de variação (CV, %), sendo classificado como baixo quando o CV < 12%; médio quando estiver 12% < CV < 24%, e alto quando o CV > 24% (Warrick e Nielsen, 1980).

Para a validação dos dados de satélite do TerraClimate foram aplicadas correlações lineares de 2010 a 2020, a partir do coeficiente de determinação (R²) e RMSE (Root Mean Squared Error), a partir dos dados oriundos das estações meteorológicas do INMET (INMET, 2021). Cada estação foi devidamente identificada nas coordenadas do pixel analisado.

2.3. RESULTADOS E DISCUSSÃO

2.3.1. Análise e caracterização de precipitação (chuva) via TerraClimate

No período seco (Figura 5) a precipitação variou entre 25 a 289 mm, já para o período chuvoso (Figura 6), percebe-se uma variação entre 97 e 1018 mm. Os maiores valores de precipitações ocorreram nas regiões que apresentam maiores altitudes (Figura 3 (B)),

corroborando Brito et al., (2019), que no seu estudo sobre monitoramento da seca meteorológica estimada por satélite em bacia hidrográfica no Estado da Paraíba (NEB), discorre que os efeitos da elevação contribuem para uma maior condensação da massa de ar, com a elevação orográfica a originar climas mais úmidos nos topos das colinas e encostas de barlavento.



Figura 5. Dinâmica espacial das chuvas, via TerraClimate, para o período seco de 2010-2020 na BHRI.

Para o período seco (Figura 5) é possível observar que os anos de 2011, 2012, 2016 e 2019 apresentaram chuvas abaixo de 138 mm, com destaque para o ano de 2016, que apresentou o ano mais crítico do período seco, com chuvas abaixo dos 64 mm. Os resultados demonstram a baixa incidência de chuvas no período seco, com valores abaixo de 289 mm em toda região da BHRI, tal fato justifica-se pela incidência de secas enfrentadas no NEB durante os anos de 2012-2017. (Cunha et al., 2018; Barbosa et al., 2019; Silva et al., 2022; Silva et al.; 2023).

Avaliando o período chuvoso (Figura 6), observa-se que nos anos de 2012, 2013, 2016, 2018 e 2019 apresentaram uma precipitação abaixo de 492 mm, destaca-se ainda que os anos

de 2012 e 2016 foram os anos mais críticos do período chuvoso, com precipitação abaixo de 101mm para os meses que, historicamente, apresentam maior volume de chuvas na região.



Figura 6. Dinâmica espacial das chuvas, via TerraClimate, para o período chuvoso de 2010-2020 na BHRI.

A caracterização pluviométrica da região foi apresentada via estatística descritiva dos períodos seco e chuvoso (2010-2020), de acordo com Tabela 13. Nos períodos secos e chuvosos de 2010 a 2020 verifica-se uma precipitação média de 116,61 e 380,43 mm, respectivamente. Conforme os valores médios reais da precipitação no período seco, foi observado uma baixa pluviosidade com destaque para o ano de 2012 e 2016, que apresentaram as precipitações médias mais baixas dos dois períodos, resultado semelhante pode ser encontrado em Brito et al. (2019) e justificados novamente pelas secas enfrentadas no NEB no período de 2012-2017. (Cunha et al., 2018; Barbosa et al., 2019; Silva et al., 2022; Silva et al.; 2023).

Precipitação (mm)							
Período	Ano	Min	Máx	μ	σ	σ^2	CV (%)
	2010	128,00	289,00	189,41	27,39	750,35	14,46
	2011	79,00	141,00	100,57	10,34	106,98	10,28
	2012	44,00	89,00	58,12	7,22	52,14	12,42
	2013	123,00	231,00	179,95	16,38	268,24	9,10
	2014	103,00	232,00	161,35	23,31	543,49	14,45
Seco	2015	101,00	199,00	137,23	14,61	213,32	10,64
	2016	25,00	67,00	36,00	4,77	22,74	13,25
	2017	82,00	207,00	121,15	15,26	232,96	12,60
	2018	65,00	146,00	105,16	15,41	237,43	14,65
	2019	50,00	126,00	70,31	11,35	128,81	16,14
	2020	69,00	181,00	123,46	18,26	333,53	14,79
	2010	249,01	531,98	394,14	55,38	3067,31	14,05
	2011	293,01	601,99	422,66	48,58	2360,45	11,49
	2012	97,00	223,00	155,83	24,44	597,55	15,69
	2013	182,01	407,00	286,71	41,41	1714,79	14,44
	2014	333,00	680,00	476,46	55,33	3061,57	11,61
Chuvoso	2015	249,01	505,00	377,05	48,89	2390,53	12,97
	2016	146,00	308,00	212,54	25,11	630,63	11,82
	2017	346,01	747,97	532,59	73,90	5461,95	13,88
	2018	218,01	407,99	303,80	28,64	820,03	9,43
	2019	196,00	478,99	319,42	45,84	2101,35	14,35
	2020	483,02	1017,99	703,55	85,23	7264,14	12,11

Tabela 13. Estatística descritiva para os mapas de precipitação (chuvas) via TerraClimate para os períodos seco e chuvoso de 2010-2020 com valores de mínimo, máximo, média, desvio padrão, variância e coeficiente de variação (CV, %).

Min = Mínimo; Máx = Máximo; μ = Média; σ = Desvio Padrão; σ^2 = Variância; CV = Coeficiente de Variação

De acordo com a classificação proposta por Warrick e Nielsen (1980), os valores de CV apresentados na Tabela 13, no período seco, os anos de 2011, 2013 e 2015 apresentaram variabilidade baixa (<12%), e os demais anos apresentaram variabilidade média (12-24%). Já no período chuvoso, os anos de 2011, 2014, 2016 e 2018 apresentaram variabilidade baixa, enquanto os demais anos exibiram variabilidade média. Valores de CV variando de médio a alto são comumente observados em dados de chuva.

A validação dos dados mensais de precipitação obtidos pelo TerraClimate para a região de estudo, se deu a partir dos dados mensais obtidos do INMET nas estações localizadas nos




Figura 7. Dados observados pelo INMET nas estações meteorológicas dos municípios e dados observados do TerraClimate para os anos de 2010 a 2020.



Figura 8. Validação dos dados observados pela estação meteorológica do INMET com os dados observados do TerraClimate para os anos de 2010 a 2020.

O coeficiente R² foi satisfatório, com valor de 0,81, descrevendo boa concordância entre os dados, seguido do coeficiente de Pearson r = 0,89, considerado muito alto de acordo com a classificação de Hopkins (2009) (Tabela 14), apresentando ajuste adequado, ou seja, representa a proximidade existente entre as duas variáveis (dados observados e estimados) de uma relação linear entre si, variando de -1 a 1. Andrade et al. (2022) encontrou valor semelhante de r = 0,86para o TerraClimate, em seu estudo sobre produtos de precipitação no nordeste brasileiro, o que valida os dados desse estudo, estimados pelo TerraClimate com os observados pelas estações meteorológicas do INMET.

Coeficiente de correlação de Pearson (r)	Classificação
0-0,1	Muito Baixo
0, 1 - 0, 3	Baixo
0,3 - 0,5	Moderado
0,5 - 0,7	Alto
0,7 - 0,9	Muito Alto
0,9 - 1,0	Quase Perfeito

Tabela 14. Coeficiente de correlação de Pearson (r) e suas classificações de acordo com Hopkins (2009).

O valor de RMSE encontrado foi de 39,18mm, representando a distância média entre as previsões e a linha de regressão do modelo. O RMSE fornece informações sobre a estimativa de erro e a magnitude média das estimativas de erro [mm.mês⁻¹], de acordo com Oliveira-Júnior et al. (2021), os valores de RMSE são importantes para validar os dados observados (estações) com dados estimados (satélite), em seu estudo os autores validaram os conjuntos de dados CHIRPS para os estados de Mato Grosso e Mato Grosso do Sul, região Centro-Oeste do Brasil, onde obtiveram valores de RMSE acima de 40mm. Silva et al. (2022) em seu estudo, no Vale do Ipojuca, Pernambuco, Brasil, encontraram um RMSE de 26,86mm, analisando dados estimados de 2014 – 2021 do TerraClimate, com dados observados de uma estação meteorológica. Andrade et al. (2022) avaliaram produtos de precipitação realizando análises temporais e espaciais sobre biomas no NEB comparando cinco produtos de precipitação, TRMM, IMERG, CHIRPS, TerraClimate e ERA5-Land, no período de 2001 a 2019, encontrando valores de RMSE para o TerraClimate foi satisfatório e consistente com os dados encontrados em estudos semelhantes (Figura 8).

2.3.2. Classes de cobertura vegetal via MapBiomas Brasil

Observa-se na Figura 9 as classes de uso e ocupação do solo (LULC) e na Figura 10 a quantificação da área em hectares (ha) para o intervalo de tempo de 2010 a 2020. Verificou-se relação inversa entre as classes Floresta e Agricultura e Pecuária, na qual ao longo do período houve diminuição da área de Floresta (Caatinga) em detrimento do aumento da área Agropecuária.



Figura 9. Dinâmica espaço-temporal anual do LULC dos anos de 2010 a 2020 na BHRI.

Os anos de 2016 e 2017 apresentaram área florestal de 305.047 ha e 287.852 ha, respectivamente, enquanto a área de agropecuária, para os mesmos anos, saltou de 460.547 ha para 483.125 ha, um desmatamento de 13.696 ha de formação florestal e um acréscimo de 22.578 ha da classe agropecuária (Figura 10). Para o mesmo período de tempo observa-se também a diminuição da área natural não florestal de 3.270 ha, corroborando resultados encontrados por Silva et al. (2022) que avaliaram o processo de degradação na região semiárida do Vale do Ipojuca, Melo et al. (2022), caracterizaram e avaliaram o processo de uso e cobertura do solo no agreste de Pernambuco e Silva et al. (2023) que avaliaram a degradação ambiental da cobertura vegetal e corpos d'água no semiárido do NEB.

		0	100000	Área (h 200000 300000	a)) 400000	500000 600000
as		Floresta				
For For	nação Natural Nã	io Florestal 🛉				
ajori	Agricultura	e Pecuária 📃				_
s Mi	Área Nã	o Vegetada 📄				
asse	Cor	pos d'Água				
D	Não	Observado				
	Não Observado	Corpos d'Água	Área Não Vegetada	Agricultura e Pecuária	Formação Natura Não Florestal	il Floresta
2010	136,45	1.384,15	8.836,28	413.033,22	993,53	360.616,37
2011	136,44	1.265,38	11.497,14	436.723,22	780,63	334.597,19
■2012	136,44	768,57	14.924,90	458.079,69	1.376,08	309.714,32
2013	136,45	414,20	20.910,08	451.156,99	1.927,93	310.454,35
2014	136,46	276,90	20.574,68	444.011,72	5.521,80	314.478,44
2015	136,43	217,78	18.661,47	446.850,32	7.170,70	311.963,30
2016	136,44	229,57	14.953,44	460.547,07	4.085,88	305.047,60
2017	136,42	459,23	12.610,96	483.125,65	815,73	287.852,01
2018	136,45	544,67	12.633,91	463.211,66	1.115,31	307.358,00
2019	136,45	507,09	11.884,66	449.270,09	1.722,03	321.479,68
2020	136,44	846,92	11.318,72	467.226,63	2.394,79	303.076,50

Figura 10. Quantificação de áreas (ha) de uso e cobertura da terra para os anos de 2010 a 2020 na BHRI.

Diante dos dados observados, ressalta-se também algumas análises relacionadas a acurácia geral da classificação do MapBiomas para a Coleção 6 (Figura 11), que para o período e área de estudo variou entre 80 e 84% para valores máximo e mínimo, respectivamente, e a média de 82,2% (MapBiomas, 2023).



Figura 11. Precisão do Nível 1 da Coleção 6 do MapBiomas 6 para os anos de 2010 a 2020 dos municípios produtores das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na BHRI.

De acordo com o ATBD (Algorithm Theoretical Basis Document – Documento de Base Teórica do Algoritmo), que descreve todo o processo de desenvolvimento e produção dos mapas e os algoritmos utilizados, a classificação digital dos mosaicos Landsat no Bioma Caatinga para as classes Agricultura ou Pastagem, ocorre como a integração das duas, não sendo possível distinguir entre elas, e a classificação de Áreas Não Vegetadas, inclui Área Urbana e Solo Exposto. Tal fato pode justificar um possível erro na interpretação dos valores da classe Agricultura e Pecuária para o ano de 2017, que apresentou o maior número de área com 483.125 ha, muito acima de todos os outros anos, que variaram entre 460.000 e 463.000 (2016 e 2018, respectivamente), em detrimento da menor área de Floresta (287.852 ha) de toda a série (2010-2020) e uma das menores áreas para a classe de Formação Natural Não Florestal (815,73 ha), ressalta-se que esse ano também apresentou a segunda menor porcentagem de acurácia geral (80,9%) e a segunda maior discordância de área (-0,055).

Outros valores que chamaram a atenção foram os valores da classe de Área Não Vegetada (Infraestrutura Urbana e Solo Exposto), que no ano de 2012 apresentou uma área de 14.920 ha e nos anos de 2013 (20.910 ha) e 2014 (20.574 ha) tendo um acréscimo de 5.990 ha e novamente uma diminuição em 2015 (18.661 ha) de 335,40 ha, como há uma associação de

feições nessa classe, supõem-se que essa variação ocorre na feição que corresponde as áreas de Solo Exposto.

2.3.3. Análise dos índices para detecção de mudanças hídricas

No período seco (Figura 12), houve maior disponibilidade hídrica nos anos de 2010, 2017, 2018, 2019 e 2020, destacando-se a maior incidência de corpos d'água, com valores de NDWI que variaram de 0,36 a -0,94, o que pode ser observado na área ocupada pelos corpos d'água nos respectivos anos, de acordo com o LULC (Figura 10).

Os anos de 2013, 2014, 2015 e 2016 apresentaram as menores incidências de corpos d'água, tal fato justifica-se pela incidência de secas severas durante o período (Cunha et al., 2018; Barbosa et al., 2019; Silva et al., 2022; Silva et al., 2023), que pode ser observado também no LULC (Figura 10), em que ocorreu uma redução na área de corpos d'água passando de 768,57 ha em 2012 para 229,57 ha em 2016, ou seja, uma redução de 539 ha de área nos corpos d'água durante os anos, fato também observado por Bezerra et al. (2022) que analisou parâmetros biofísicos no semiárido pernambucano, verificando reduções acentuadas no NDWI entre os anos de 2012 a 2017 para todo o Estado de Pernambuco, Silva et al. (2022) para os anos de 2015 e 2016 na região semiárida do Vale do Ipojuca e por Silva et al. (2023) para os anos de 2014, 2015 e 2016 no semiárido no NEB.

O ano de 2011 apresentou forte influência das nuvens nos valores de NDWI, que, devido a sua alta sensibilidade para corpos d'água, acabaram ocasionando uma alta variabilidade no índice. Considerando que as nuvens são elementos não controlados nos estudos que envolvem o processamento de imagens de satélites orbitais, não foi possível mascarar sua influência, o que também pode ser observado no estudo de Washington et al. (2019), que utilizou o Espectroradiômetro de Imagem de Resolução Moderada (MODIS) e Silva et al. (2022) que utilizou o Landsat-8 (OLI).



Figura 12. Dinâmica espaço-temporal do Índice de Diferença Normalizada da Água (NDWI), para o período seco dos anos de 2010 a 2020 na BHRI.

No período chuvoso (Figura 13), verificou-se que a alta incidência de nuvens na região afetou as análises do NDWI, com índices que variam de -0,99 a 0,51, e os maiores valores positivos correspondem as áreas com maior incidência de nuvens, fato também relatado por Souza et al. (2022) no estudo sobre análise das influências ambientais e atmosféricas no monitoramento operacional do nível de água de um reservatório no NEB, em que 71% das imagens dos satélites Landsat-8 e Sentinel-2 não puderam ser utilizadas devido a efeitos atmosféricos e más condições climáticas.



Figura 13. Dinâmica espaço-temporal do Índice de Diferença Normalizada da Água (NDWI), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Para o período chuvoso, utilizando o baixo CV (Tabela 15) como parâmetro de análise, foram avaliadas as imagens dos anos de 2013, 2017 e 2019. A imagem do ano de 2013 apresentou a menor incidência de corpos d'água, fato também observado para o período seco e validado pela extensão da área ocupada por corpos hídricos do LULC (MapBiomas, 2021). Os anos que apresentaram maior disponibilidade hídrica foram 2017 e 2019, corroborando os dados observados no período seco (Figuras 5 e 12 e Tabela 13), bem como pela extensão da área ocupada por recursos hídricos. Resultado semelhante foi encontrado por Santiago et al. (2019), em estudo de modelagem matemática e uso de produtos orbitais na degradação ambiental da Floresta do Araripe no NEB, onde o NDWI para o mês de julho (chuvoso) foi de -1,00 (mín) e 0,77 (máx).

De acordo com a classificação proposta por Warrick e Nielsen (1980), para o período seco, os anos de 2013, 2015 e 2017 apresentaram um CV considerado baixo, os anos de 2010,

2014, 2016, 2018, 2019 e 2020 apresentaram um CV médio e o ano de 2011, o ano que apresentou maior presença de nuvens, alterou o CV significativamente, classificando-o como um CV alto (Tabela 15), corroborando com os resultados obtidos por Bezerra et al. (2022) e Silva et al. (2022), que apontaram que o CV alto no NDWI está diretamente ligado à influência de nuvens.

O período chuvoso, em que há maior presença de nuvens, os coeficientes de variação foram maiores que os apresentados no período seco. O ano de 2013 foi o único que apresentou um CV baixo, os anos de 2017 e 2019 apresentaram um CV médio e os anos de 2010, 2011, 2014, 2015, 2016, 2018 e 2020 apresentaram alto valor de CV, desses, o ano de 2011 foi o ano que apresentou maior presença de nuvens, elevando ainda mais o valor do CV (Tabela 15).

NDWI											
Período	Ano	Min	Máx	μ	σ	σ^2	CV (%)				
	2010	-0,75	0,24	0,27	0,04	0,00	15,87				
	2011	-0,71	0,36	0,20	0,09	0,01	46,94				
	2013	-0,45	0,22	0,30	0,04	0,00	11,84				
	2014	-0,57	0,19	0,29	0,05	0,00	15,86				
Saga	2015	-0,44	0,23	0,31	0,03	0,00	10,14				
Seco	2016	-0,94	0,21	0,30	0,05	0,00	15,97				
	2017	-0,53	0,27	0,29	0,03	0,00	11,93				
	2018	-0,48	0,19	0,30	0,05	0,00	15,77				
	2019	-0,47	0,23	0,30	0,05	0,00	15,24				
	2020	-0,59	0,33	0,31	0,04	0,00	12,26				
	2010	-0,72	0,42	0,21	0,06	0,00	27,94				
	2011	-0,38	0,51	0,07	0,12	0,01	169,05				
	2013	-0,67	0,32	0,30	0,04	0,00	11,76				
	2014	-0,99	0,27	0,21	0,09	0,01	42,52				
Chuyaga	2015	-0,63	0,29	0,27	0,07	0,00	25,60				
Chuvoso	2016	-1,00	0,41	0,22	0,09	0,01	43,55				
	2017	-0,92	0,37	0,23	0,05	0,00	23,24				
	2018	-1,00	0,48	0,20	0,11	0,01	54,97				
	2019	-0,60	0,34	0,25	0,05	0,00	18,50				
	2020	-0,93	0,37	0,19	0,05	0,00	28,45				

Tabela 15. Estatística descritiva para o NDWI no período seco e chuvoso de 2010 a 2020.

Min = Mínimo; Máx = Máximo; μ = Média; σ = Desvio Padrão; σ^2 = Variância; CV = Coeficiente de Variação

Quando se compara a diferença anual entre as imagens de 2010 a 2020 do período seco (Figura 14), observa-se prevalência da redução de cobertura hídrica na maior parte do território, com destaque para a porção oeste e sul da BHRI, localizada próximo ao exutório.



Figura 14. Detecção de mudanças para corpos hídricos utilizando o Índice de Diferença Normalizada da Água (NDWI), para o período seco dos anos de 2010 a 2020 na BHRI.

No período seco houve déficit hídrico entre os anos 2010-2020. O ano que apresentou maior mudança na disponibilidade hídrica corresponde ao ano de 2011, e as maiores reduções hídricas podem ser observadas em todos os anos, na região oeste da Bacia, principalmente nos anos de 2014 a 2018 (Figura 14), corroborando o estudo de Bezerra et al. (2022), que verificou os menores índices em relação ao período seco de 2012 e 2017, onde a disponibilidade hídrica de reservatórios, lagos e rios diminuíram drasticamente e a perda efetiva da cobertura vegetal verde causou aumento na condição de déficit hídrico no Estado de Pernambuco.

Martins et al. (2019) no estudo sobre implicações na mudança da água superficial e na variabilidade da turbidez do reservatório de Sobradinho (NEB), concluiu que mudanças críticas

de água no reservatório de Sobradinho foram observada entre 2013 e 2017, com uma redução de 62,77% da área total do reservatório em 2017, bem como Ribeiro Neto et al. (2022), que realizaram uma análise do ciclo da seca para avaliar a influência de uma densa rede de pequenos reservatórios na evolução da seca na bacia hidrográfica do Riacho do Sangue, NEB, Ceará, que apontou o período de 2012 a 2018 como anos secos.

Como esperado e de acordo com os coeficientes de variação das imagens para o período chuvoso, devido à forte influência das nuvens no NDWI, é possível observar um "aumento hídrico" fortemente representado pela presença de nuvens na maioria dos anos (Figura 15), de acordo com Pereira et al. (2018), em sua análise comparativa entre os métodos de índice de água por diferença normalizada (NDWI) em área úmida continental, o NDWI de McFeeters (1996) registrou confusão espectral em muitas situações, não sendo possível diferir o alvo por meio do valor do número digital, ou seja, alvos como solo seco, úmido, ou com cobertura de vegetação rasteira apresentaram-se dentro do mesmo intervalo de resposta espectral, o que pode justificar a resposta espectral das nuvens nas imagens do período chuvoso, que apresentaram-se dentro do mesmo intervalo supersí superstimando seu aumento real.



Figura 15. Detecção de mudanças para corpos hídricos utilizando o Índice de Diferença Normalizada da Água (NDWI), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Corroborando, Ogilvie et al. (2018) em seu estudo de monitoramento de águas superficiais em pequenos corpos d'água: potencial e limites da série temporal Landsat multissensor, constatou que as nuvens levaram essencialmente a erros de comissão (falsos positivos) e superestimação. Resultado semelhante foi descrito por Cardoso et al. (2020) na detecção e delimitação de pequenos reservatórios na bacia hidrográfica do Rio Cachoeira, Bahia, no qual foram analisadas imagens entre o período seco e chuvoso entre os anos de 2015 a 2019, destacando que a presença de nuvens foi fator limitante na seleção das imagens e apenas duas cenas apresentaram condições satisfatórias para o cálculo dos índices normalizados de água.

Quando se observa as classificações de mudanças hídricas, nos dois períodos, é possível observar que as imagens que apresentam nuvens foram classificadas como corpos hídricos, pois apresentam valores de NDWI menores que 0, iguais aos de corpos hídricos, que variam de -1 a

0. Já a presença de sombras das nuvens apresenta valores positivos, e confundem-se com valores de solo e vegetação 0 a 1.

Outro fator em destaque é que, para além dos corpos hídricos, o NDWI foi capaz de detectar as mudanças de umidade e fisiológicas da vegetação na área, corroborando Silva Júnior et al. (2018) no estudo da Análise do NDVI e NDWI e umidade local no munícipio de Água Branca – AL, onde evidenciaram que no mês com menor incidência pluviométrica os pixels com valores negativos de NDWI representam pixels com características de áreas de baixa umidade e com poucas presenças de corpos hídricos.

2.3.4. Análise dos índices para detecção de cobertura vegetal

A análise do NDVI para o período seco pode ser observada nos mapas da Figura 16. Os valores de NDVI variaram de -0,52 a 0,80, sendo possível observar que houve diminuição gradativa entre os valores positivos do índice para o período, os menores valores observados foram para os anos de 2015 e 2016, corroborando com os dados observados no LULC (Figura 10), nos quais os anos de 2012 a 2018 apresentaram a maior diminuição das áreas da classe floresta (Caatinga) da série, fato também observado por Bezerra et al. (2022) principalmente no ano de 2015, Silva et al. (2022) para os anos de 2015 e 2016, Silva et al. (2023) para os anos de 2015 e 2016 e Rebello et al. (2020) para os anos de 2012 a 2018.

Os anos de 2019 e 2020 expressaram a recuperação da vegetação, demonstrada pelo aumento da área com tons de verde. De acordo com a média da precipitação para o período (Figura 5), os menores valores precipitados ocorreram nos anos de 2012 e 2016, com 58,12 e 36 mm respectivamente, no entanto, para todo o período, a precipitação máxima não passou dos 289 mm no ano de 2010 (Tabela 13), que consequentemente foi o ano que apresentou a maior área com tons de verde, corroborando os resultados de Mutti et al. (2019), que afirmam que a vegetação da região é fortemente influenciada pela chuva e durante os períodos mais secos as espécies do bioma perdem suas folhas, a fim de reduzir a atividade metabólica durante condições de estresse hídrico e Tomasella et al. (2018) que em seu estudo sobre as tendências da desertificação no NEB, mostram que os valores de NDVI são menores na estação seca, principalmente nas áreas dominadas pela vegetação de Caatinga, uma vez que esse tipo de vegetação perde suas folhas no início do período seco.



Figura 16. Dinâmica espaço-temporal do Índice de Vegetação de Diferença Normalizada (NDVI), para o período seco dos anos de 2010 a 2020 na BHRI.

O NDVI para o período chuvoso (Figura 17), assim como NDWI, foi fortemente influenciado pela incidência de nuvens, e apresentaram valores que variam de -0,56 a 0,99. Os anos de 2013 e 2015 foram os anos que apresentaram menor área de vegetação, corroborando os dados de precipitação (Figura 6) para o ano de 2013, que apresentou um dos menores índices de precipitação média do período, 286,71 mm, ficando atrás apenas dos anos de 2012 e 2016 com 155,83mm e 212,54mm, respectivamente (Tabela 13).

O bioma Caatinga apresenta rápida resposta da vegetação em períodos de maior pluviosidade (Silva et al., 2020b), dessa forma, o período de chuva teve influência direta na resiliência da vegetação, refletindo nos maiores valores de NDVI nos anos de 2014, 2017 e 2020, que apresentaram as maiores médias de precipitação para o período, com 476,46, 532,59 e 703,55 mm respectivamente (Tabela 13), resultado semelhante obtido por Dutta et al. (2021) que analisaram a variação sazonal na cobertura vegetal usando NDVI e chuva na região de

floresta decídua seca do leste da Índia, concluíram que há variabilidade significativa entre a precipitação e o estado da vegetação, indicando a influência da precipitação na vegetação.



Figura 17. Dinâmica espaço-temporal do Índice de Vegetação de Diferença Normalizada (NDVI), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Observando as análises do NDVI, conclui-se que mesmo diante das condições de disponibilidade hídrica observadas na análise de precipitação (Figuras 5 e 6) e no LULC (Figura 9), a vegetação apresentou menor resiliência, possivelmente ocasionada pelo desmatamento da cobertura vegetal natural (Caatinga), em detrimento da substituição por áreas de agricultura e pastagem (Figura 10), resultados semelhantes foram encontrados por Silva et al. (2023).

A análise estatística descritiva das imagens de NDVI pode ser vista na Tabela 16. De acordo com a classificação proposta por Warrick e Nielsen (1980), diferente da análise estatística da precipitação e do NDWI, o NDVI para o período seco apresentou CV alto (CV> 24%) em todos os anos, exceto o ano de 2015, que apresentou CV médio (23,98 %). O Ano de

2011 apresentou o maior CV (47,98 %), fato justificado, pois também foi o ano que apresentou maior incidência de nuvens. O período chuvoso apresentou o mesmo padrão de CV, variando de médio a alto, encontrado no NDWI do período. Assim como no período seco, o ano de 2011 apresentou o maior CV (76,51%) e também a maior incidência de nuvens da série.

NDVI											
Período	Ano	Min	Máx	μ	σ	σ^2	CV (%)				
	2010	-0,32	0,54	0,22	0,07	0,00	29,53				
	2011	-0,52	0,53	0,20	0,09	0,01	47,98				
	2013	-0,14	0,56	0,18	0,05	0,00	27,40				
	2014	-0,17	0,57	0,21	0,06	0,00	27,51				
Saaa	2015	-0,09	0,56	0,15	0,04	0,00	23,98				
Seco	2016	-0,10	0,80	0,14	0,04	0,00	26,44				
	2017	-0,14	0,54	0,19	0,05	0,00	25,00				
	2018	-0,16	0,52	0,16	0,05	0,00	27,99				
	2019	-0,14	0,55	0,17	0,05	0,00	27,08				
	2020	-0,20	0,59	0,19	0,05	0,00	26,71				
	2010	-0,56	0,58	0,26	0,08	0,01	29,84				
	2011	-0,54	0,59	0,18	0,14	0,02	76,51				
	2013	-0,12	0,55	0,15	0,04	0,00	28,55				
	2014	-0,20	0,98	0,28	0,11	0,01	39,16				
Chuyaga	2015	-0,13	0,55	0,21	0,07	0,00	31,94				
CIIUVOSO	2016	-0,20	0,99	0,24	0,10	0,01	44,27				
	2017	-0,25	0,96	0,33	0,09	0,01	28,59				
	2018	-0,20	0,99	0,26	0,12	0,01	44,70				
	2019	-0,21	0,64	0,25	0,07	0,00	27,36				
	2020	-0,22	0,83	0,38	0,09	0,01	23,93				

Tabela 16. Estatística descritiva para o NDVI no período seco e chuvoso de 2010 a 2020.

Min = Mínimo; Máx = Máximo; μ = Média; σ = Desvio Padrão; σ^2 = Variância; CV = Coeficiente de Variação

Através da reclassificação dos valores de NDVI dos períodos seco e chuvoso, a vegetação foi avaliada via IBVL, contemplando seus diferentes estágios de sucessão e antropização. Para o período seco, foi possível observar concordância entre as imagens do NDVI (Figura 16) e do IBVL, constatando que o IBVL conseguiu acentuar e distinguir as informações sobre a condição da cobertura vegetal. Destaca-se, no entanto, que a presença de nuvens afetou a análise e quantificação dos corpos d'água, principalmente no ano de 2011,

superestimando os valores de área ocupada pela classe (1.625 ha), que apresentou uma média de 192 ha entre os demais anos. (Figuras 18 e 19).



Figura 18. Dinâmica espaço-temporal do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período seco dos anos de 2010 a 2020 na BHRI.

De acordo com a avaliação da área ocupada pelas classes (Figura 19), observa-se que a classe majoritária da área é composta por uma vegetação Subarbustiva (arbustiva muito rala e arbustiva rala) com valor máximo de 491.501 ha (2017) e mínimo de 200.495 ha (2011), seguida da classe Arbustiva (subarbustiva aberta, subarbórea aberta e subarbórea densa), com valor máximo de 206.094 ha (2014) e mínimo de 22.185 ha (2016). Francisco et al. (2020) em seu livro sobre modelo de mapeamento da degradação do Bioma Caatinga, descreve o estudo realizado na bacia hidrográfica do rio Taperoá, no Estado da Paraíba, identificando que as áreas abertas utilizadas como pastagem e culturas irrigadas se confundem com as leituras das classes de vegetação Subarbustiva (muito rala e rala) e a leitura da classe Arbustiva (subarbórea aberta) foram identificadas áreas de plantio de milho e bosques de algaroba.

O solo exposto também apresentou valores elevados durante toda série, com área máxima de 530.482 ha em 2016 e mínima de 93.283 ha em 2010. As classes Subarbórea (arbustiva densa e densa), Arbórea (densa e muito densa) e Corpos d'água, foram as classes com menor área, com valores máximos de 82.535 ha (2010), 97.379 ha (2011), 1.625 ha (2011) e mínimos de 3.110 ha (2016), 3.110 (2016), 41 ha (2016), respectivamente, ressalta-se também que as classes Subarbórea e Arbórea estão localizadas nas áreas de maior altitude da BHRI (Figura 3 (B)), fato também observado por Francisco et al. (2020).

O ano de 2016 foi o ano que se destacou entre todas as varáveis analisadas, condições pluviométricas (chuvas), disponibilidade de recursos hídricos e de cobertura vegetal (Figuras 5, 6, 14 e 16), como um dos anos com menores índices em cada variável, inclusive no LULC via MapBiomas (Figura 10).

Classa	Área (ha) do Período Seco											
Classe	2010	2011	2013	2014	2015	2016	2017	2018	2019	2020		
Corpos d'água	370	1.625	62	64	52	41	158	202	98	677		
Solo exposto	93.283	285.737	246.996	120.592	476.429	530.482	138.204	365.759	301.024	157.969		
Subarbustiva arbustiva muito rala	247.320	142.435	307.247	247.799	248.443	200.405	384.712	286.305	325.707	369.468		
Subarbustiva arbustiva rala	97.359	58.060	100.032	129.052	31.694	27.478	106.788	58.140	73.665	98.631		
Arbustiva subarbustiva aberta	83.333	51.964	60.059	103.767	13.761	13.453	66.287	33.770	38.862	59.948		
Arbustiva subarbórea aberta	46.490	30.907	22.605	50.285	4.618	4.742	25.435	13.232	14.024	24.960		
Arbustiva subarbórea densa	57.555	42.162	20.024	52.041	4.043	3.991	23.208	12.173	12.370	24.740		
Subarbórea arbustiva densa	38.825	32.474	9.673	27.842	1.990	1.767	12.239	5.795	6.209	13.826		
Subarbórea densa	43.710	42.257	8.249	24.732	1.793	1.343	11.725	4.813	5.510	13.879		
Arbórea densa	47.260	51.661	6.284	18.567	1.422	897	10.376	3.410	4.644	13.035		
Arbórea muito densa	29.495	45.718	3.769	10.259	756	403	5.865	1.402	2.886	7.866		

Figura 19. Quantificação de áreas (ha) das classes do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período seco dos anos de 2010 a 2020 na BHRI.

No período chuvoso também foi observada a concordância entre as imagens do NDVI (Figura 17) e do IBVL para o período, ressalta-se também, que, como todos os outros índices, o IBVL foi fortemente influenciado pela incidência de nuvens, afetando as análises e quantificação dos corpos d'água, o que fica evidente principalmente nos anos de 2011, 2014, 2016 e 2018 (Figura 20).



Figura 20. Dinâmica espaço-temporal do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

O quantitativo da área das classes para o período (Figura 21), demonstra que a classe que apresentou os maiores valores, diferente do período seco, foi a classe Arbórea (densa e muito densa), com valor máximo de 633.487 ha (2020) e mínimo de 5.855 ha (2013), tais valores podem ser justificados se considerarmos que o ano de 2020 apresentou a maior média de precipitação para o período e o ano de 2013 apresentou uma das menores médias (Tabela 13), no entanto, a classe Floresta do LULC via MapBiomas (Figura 10), para o ano de 2020, foi a segunda menor em área para a série 2010-2020, outro fator a ser considerado nessa avaliação foi descrito por Francisco et al. (2020), no qual os mesmos discorrem que muitas das áreas com vegetação aberta com valores de IBVL variando de 0,200 a 0,400 (classes Subarbustiva a Arbórea) (Tabela 11), apresentam valores de índices de vegetação iguais aos das maiores áreas com vegetação de porte maior e mais densa, confirmando que, na Caatinga, a recomposição da vegetação é intensa com a chegada das primeiras chuvas.

A classe Subarbustiva (arbustiva muito rala e arbustiva rala) foi a segunda classe com as maiores áreas, com valor máximo de 337.761 ha (2015) e mínimo de 26.103 ha (2020), seguida da classe Solo exposto, valor máximo 466.875 ha (2013) e mínimo 20.782 ha (2020), o valor máximo para o ano de 2013 relaciona-se com o fato que esse foi um dos anos com as menores médias de precipitação somado ao fato de que o ano de 2012 apresentou a menor média de precipitação da série 2010-2020 com uma precipitação média de 155,83mm (Tabela 13). Outra observação importante a cerca dessas informações, é que, ainda de acordo com Francisco et al. (2020), os baixos valores das leituras dos índices de vegetação para o período chuvoso, em torno de 0,200 (classes Solo exposto a Subarbustiva) (Tabela 11), devem representar áreas degradadas, ou seja, essas classes representaram altos valores em área e, apesar da época chuvosa, representam áreas com perda da capacidade de restabelecimento da cobertura vegetal natural.

As classes Arbustiva (subarbustiva aberta, subarbórea aberta e subarbórea densa), Subarbórea (arbustiva densa e densa) e Corpos d'água, com valores máximos de 246.001 ha (2019), 117.879 ha (2019), 23.148 ha (2011) e mínimos de 38.440 ha (2013), 6.372 ha (2013), 43 ha (2015), respectivamente, destaca-se que o ano de 2015 também foi o menor ano com área de corpos d'água no LULC via MapBiomas (Figura 10).

	Área (ha) do Período Chuvoso											
Classe	2010	2011	2013	2014	2015	2016	2017	2018	2019	2020		
Corpos d'água	1.299	23.148	125	57	43	725	233	2.434	117	770		
Solo exposto Subarbustiva	43.088	340.469	466.875	96.948	142.786	170.828	23.117	145.959	48.795	20.782		
arbustiva muito rala	118.730	100.168	223.702	81.818	225.780	123.765	39.441	80.646	131.660	22.724		
Subarbustiva arbustiva rala	94.497	48.001	43.631	58.436	111.981	70.523	42.366	54.162	93.895	3.380		
Arbustiva subarbustiva aberta	98.711	40.581	23.480	63.144	93.425	69.685	53.360	55.775	102.817	19.100		
Arbustiva subarbórea aberta	57.150	21.254	8.129	38.637	45.941	39.752	36.777	33.401	62.954	13.724		
Arbustiva subarbórea densa	72.344	25.834	6.831	50.991	50.328	49.839	54.509	44.640	80.230	21.611		
Subarbórea arbustiva densa	49.995	18.106	3.343	37.116	30.410	34.537	44.502	33.625	54.686	19.019		
Subarbórea densa	59.915	23.197	3.028	47.552	31.830	41.833	63.193	45.057	63.193	30.405		
Arbórea densa	72.411	33.708	2.764	67.083	31.384	54.889	97.626	68.449	71.852	60.451		
Arbórea muito densa	116.860	110.536	3.092	243.217	21.093	128.625	329.877	220.853	74.802	573.036		

Figura 21. Quantificação de áreas (ha) das classes do Índice de Biomassa de Vegetação Lenhosa (IBVL), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

A porcentagem de perdas e ganhos para as classes (Figura 22), observa-se que os anos de 2011 e 2013 tiveram perdas em quase todas as classes, quando comparadas entre o período seco e chuvoso. A classe Arbórea (densa e muito densa) foi a classe que apresentou os maiores ganhos de área, quando comparada entre os períodos, exceto no ano de 2013, que foi um dos anos com menor incidência de chuvas nos dois períodos.

	% Perda ou Ganho											
Classe	2010	2011	2013	2014	2015	2016	2017	2018	2019	2020		
Corpos d'água	71.50	92.98	50.72	-10.89	-17.07	94.39	32.23	91.71	16.00	12.03		
Solo exposto	-53.81	16.08	47.10	-19.61	-70.03	-67.80	-83.27	-60.09	-83.79	-86.84		
Subarbustiva arbustiva muito rala	-51.99	-29.68	-27.19	-66.98	-9.12	-38.24	-89.75	-71.83	-59.58	-93.85		
Subarbustiva arbustiva rala	-2.94	-17.33	-56.38	-54.72	71.70	61.04	-60.33	-6.84	21.55	-96.57		
Arbustiva subarbustiva aberta	15.58	-21.91	-60.90	-39.15	85.27	80.70	-19.50	39.45	62.20	-68.14		
Arbustiva subarbórea aberta	18.65	-31.23	-64.04	-23.16	89.95	88.07	30.84	60.38	77.72	-45.01		
Arbustiva subarbórea densa	20.44	-38.73	-65.89	-2.02	91.97	91.99	57.42	72.73	84.58	-12.65		
Subarbórea arbustiva densa	22.34	-44.24	-65.44	24.99	93.46	94.88	72.50	82.77	88.65	27.30		
Subarbórea densa	27.05	-45.10	-63.29	47.99	94.37	96.79	81.45	89.32	91.28	54.35		
Arbórea densa	34.73	-34.75	-56.02	72.32	95.47	98.37	89.37	95.02	93.54	78.44		
Arbórea muito densa	74.76	58.64	-17.98	95.78	96.41	99.69	98.22	99.37	96.14	98.63		

Figura 22. Porcentagem de perdas ou ganhos das classes do Índice de Biomassa de Vegetação Lenhosa (IBVL), entre os períodos seco e chuvoso dos anos de 2010 a 2020 na BHRI.

Os resultados encontrados para o Índice de Vulnerabilidade da Vegetação (IVV), do período seco, demonstram que as áreas que apresentaram vulnerabilidade muito baixa e baixa correspondem as classes Arbórea (muito densa e densa) e Subarbórea (densa e arbustiva densa), respectivamente, como pode ser observado na Figura 23.



Figura 23. Dinâmica espaço-temporal do Índice de Vulnerabilidade da Vegetação (IVV), para o período seco dos anos de 2010 a 2020 na BHRI.

Os resultados (Figura 23) corroboram o IBVL do período seco que demonstrou que essas são as classes que apresentaram menor área de ocupação na BHRI, com áreas máximas de 82.535 ha (2010), 97.379 ha (2011) e mínimas de 3.110 ha (2016), 3.110 (2016), respectivamente (Figuras 18 e 19). Observa-se também, a incidência de nuvens, principalmente na imagem de 2011, computando a sua influência como vulnerabilidade muito alta.

A classe para vulnerabilidade moderada no IVV corresponde as áreas das classes Solo exposto e Subarbustiva (arbustiva muito rala e arbustiva rala) no IBVL, a classe Subarbustiva foi a classe que apresentou a maior área do período seco, com valor máximo de 491.501 ha (2017) e mínimo de 200.495 ha (2011) e o Solo exposto também apresentou valores elevados, com área máxima de 530.482 ha em 2016 e mínima de 93.283 ha em 2010 (Figuras 18 e 19), ou seja, as informações são compatíveis para o IVV, visto que esse índice tem relação direta com os resultados do IBVL, o que foi observado.

Para o período chuvoso, os resultados do IVV podem ser observados na Figura 24. Ressalta-se novamente as conclusões de Francisco et al. (2020), para estudos de vegetação na caatinga durante o período chuvoso, no qual discorrem que muitas das áreas com vegetação aberta com valores de IBVL variando de classes Subarbustiva a Arbórea, apresentam valores de índices de vegetação iguais aos das maiores áreas com vegetação de porte maior e mais densa.



Figura 24. Dinâmica espaço-temporal do Índice de Vulnerabilidade da Vegetação (IVV), para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Observa-se também que, assim como no período seco, a classe para vulnerabilidade moderada no IVV corresponde as áreas das classes Solo exposto e Subarbustiva (arbustiva muito rala e arbustiva rala) no IBVL do período chuvoso. Mais uma vez foi constatado que as informações são compatíveis para o IVV em relação ao IBVL. Dessa forma conclui-se que o Índice de Vulnerabilidade da Vegetação apresentou resultados satisfatórios e condizentes com os demais índices calculados.

2.4. CONCLUSÃO

A metodologia utilizada neste trabalho, embora tenha suas limitações (incidência de nuvens nas imagens de satélite), permitiu coletar informações importantes para o diagnóstico da bacia hidrográfica e estimar dados quantitativos e qualitativos sobre as mudanças hídricas e a cobertura vegetal da área.

O estudo identificou mudanças nas condições de uso do solo na Caatinga, levando à perda da cobertura vegetal e dos corpos d'água, apresentando resultados consistentes com estudos relacionados com a temática.

A variabilidade das chuvas, devido a baixos totais anuais, impacta diretamente na dinâmica e resiliência da vegetação, dos corpos hídricos e na disponibilidade hídrica da bacia, afetando o microclima local e intensificando o déficit hídrico no semiárido do nordeste brasileiro.

O NDWI foi eficiente em detectar a condição hídrica anual na bacia hidrográfica, mas mostrou-se menos eficaz durante períodos chuvosos devido à alta presença de nuvens.

A condição hídrica evidenciou os efeitos severos da estiagem, refletindo a variabilidade pluviométrica e destacando a redução crítica dos corpos d'água e aumento de áreas não vegetadas, o que favorece a vulnerabilidade a processos de degradação ambiental e pressões antrópicas.

O NDVI, o IBVL e o IVV foram eficientes em detectar a condição da cobertura vegetal, sendo validados pelo LULC via MapBiomas.

A divisão do estudo entre período seco e chuvoso apresentou limitações em relação a incidência de nuvens nas imagens de satélite.

O sensoriamento remoto é eficiente na identificação da variabilidade dos parâmetros físico-hídricos, que se mostraram indicadores sensíveis do déficit hídrico e da degradação da vegetação.

2.5. REFERÊNCIAS

ABATZOGLOU, J.T.; DOBROWSKI, S.Z.; PARKS, S.A.; et al.. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. Scientific Data. v.5, n.1, p. 1–12. 2018. Disponível em: https://doi.org/10.1038/sdata.2017.191>. Acesso em novembro de 2022.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**. v. 22, n. 6, p. 711–728. 2013. Disponível em: https://doi.org/10.1127/0941-2948/2013/0507>. Acesso em dezembro de 2021.

ANDERSON, E. P.; SUE JACKSON, R. E.; THARME, M. D.; et al.. Understanding Rivers and Their Social Relations: A Critical Step to Advance Environmental Water Management. **WIREs Water.** v.6, n.6. 2019. Disponível em: https://doi.org/10.1002/wat2.1381. Acesso em novembro de 2022.

ANDRADE, J. M; RIBEIRO-NETO, A.; BEZERRA, U. A.; et al.. A comprehensive assessment of precipitation products: Temporal and spatial analyses over terrestrial biomes in Northeastern Brazil. **Remote Sensing Applications: Society and Environment**. v. 28, p. 100842. 2022. Disponível em: https://doi.org/10.1016/j.rsase.2022.100842>. Acesso em janeiro de 2023.

ANTONGIOVANNI, M., VENTICINQUE, E. M.; MATSUMOTO, M.; et al.. Chronic Anthropogenic Disturbance on Caatinga Dry Forest Fragments. Edited by Shekhar Biswas. Journal of Applied Ecology. 57 (10): 2064–74. 2020. Disponível em: https://doi.org/10.1111/1365-2664.13686>. Acesso em janeiro de 2023.

BALBINO, L. C.; CORDEIRO, L. A. M.; OLIVEIRA, P. D.; et al.. Agricultura sustentável por meio da integração lavoura-pecuária-floresta (iLPF). International Plant Nutrition Institute.
n. 138 (06). 2012. Disponível em: https://www.alice.cnptia.embrapa.br/bitstream/doc/1111127/1/BalbinoAgriculturasustentave BARBOSA, H. A.; LAKSHMI KUMAR, T. V.; PAREDES, F.; et al.. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008–2016). **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 148, p. 235–252. 2019. Disponível em: https://doi.org/10.1016/j.isprsjprs.2018.12.014>. Acesso em janeiro de 2023.

BECK, H. E.; ZIMMERMANN, N. E.; MCVICAR, T. R.; *et al.* Present and future Köppen-Geiger climate classification maps at 1-km resolution. **Scientific Data**. v. 5, n. 1. 2018. Disponível em: https://doi.org/10.1038/sdata.2018.214>. Acesso em novembro de 2022.

BEZERRA, A. C.; SILVA, J. L. B.; MOURA, G. B. A.; et al.. Dynamics of Land Cover and Land Use in Pernambuco (Brazil): Spatio-Temporal Variability and Temporal Trends of Biophysical Parameters. **Remote Sensing Applications: Society and Environment**. v.25, article: 100677. 2022. Disponível em: https://doi.org/10.1016/j.rsase.2021.100677. Acesso em novembro de 2022.

BHERING, A. P.; ANTUNES, I. M. H. R.; MARQUES, E. A. G.; *et al.* Geological and hydrogeological review of a semi-arid region with conflicts to water availability (southeastern Brazil). **Environmental Research**. v. 202, article: 111756. 2021. Disponível em: https://doi.org/10.1016/j.envres.2021.111756>. Acesso em novembro de 2022.

BORETTI, AL.; ROSA, L.. Reassessing the Projections of the World Water Development Report. **Npj Clean Water.** 2 (1). 2019. Disponível em: https://doi.org/10.1038/s41545-019-0039-9>. Acesso em janeiro de 2023.

BRASIL NETO, R. M.; SANTOS, C. A. G.; SILVA, J. F. C. B. C.; et al.. Evaluation of the TRMM Product for Monitoring Drought over Paraíba State, Northeastern Brazil: A Trend Analysis. **Scientific Reports**. 11 (1). 2021. Disponível em: https://doi.org/10.1038/s41598-020-80026-5. Acesso em janeiro de 2023.

BRITO, C. S.; SILVA, R. M.; SANTOS, C. A. G.; et al.. Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: A case study of the Piranhas River basin, northeastern Brazil. Atmospheric Research, v. 250, p. 105380. 2021. Disponível em: https://doi.org/10.1016/j.atmosres.2020.105380>. Acesso em janeiro de 2023. BURNEY, J., CESANO, D., RUSSELL, J.; *et al.* Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. **Climatic Change.** v. 126, p. 45–59. 2014. Disponível em: https://doi.org/10.1007/s10584-014-1186-0>. Acesso em novembro de 2022.

CARDOSO, S. B.; CUNHA, C. F.; ENGELBRECHT, B. Z.; et al.. Detecção e delimitação de pequenos reservatórios na bacia hidrográfica do rio cachoeira, Bahia, utilizando imagens multiespectrais. **Holos Environment.** v. 20, p. 458-475. 2020. Disponível em: https://doi.org/10.14295/holos.v20i4.12391. Acesso em janeiro de 2023.

CHAVES, I. B.; LOPES, V. L.; FFOLLIOTT, P. F.; et al.. Uma Classificação Morfo-Estrutural Para Descrição e Avaliação da Biomassa da Vegetação da Caatinga. **Revista Caatinga** [online]. v. 21(2), 204-213. 2008. Disponível em: <https://www.redalyc.org/pdf/2371/237117611026.pdf>. Acesso em janeiro de 2023.

CORREIA FILHO, W. L. F.; OLIVEIRA-JÚNIOR, J. F.; SANTIAGO, D. B.; et al.. Rainfall variability in the Brazilian northeast biomes and their interactions with meteorological systems and ENSO via CHELSA product. **Big Earth Data**. v. 3:4, p. 315-337. 2019. Disponível em: https://doi.org/10.1080/20964471.2019.1692298>. Acesso em janeiro de 2023.

COSTA, L.; SANT'ANNA, A. A.; YOUNG, C. E. F. Barren lives: drought shocks and agricultural vulnerability in the Brazilian Semi-Arid. **Environment and Development Economics**. p. 1–21. 2021a. Disponível em: https://doi.org/10.1017/S1355770X21000176>. Acesso em janeiro de 2023.

COSTA, M. S., OLIVEIRA-JÚNIOR, J. F.; SANTOS, P. J.; et al.. Rainfall Extremes and Drought in Northeast Brazil and Its Relationship with El Niño–Southern Oscillation. **International Journal of Climatology.** 41 (S1). 2021b. Disponível em: https://doi.org/10.1002/joc.6835. Acesso em janeiro de 2023.

CUNHA, A. P. M. A.; TOMASELLA, J.; RIBEIRO-NETO, G. G.; et al.. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. **Atmospheric Science Letters**. v. 19, n. 10, p. e855. 2018. Disponível em: https://doi.org/10.1002/asl.855>. Acesso em janeiro de 2023.

DELAZERI, L. M. M.; CUNHA, D. A.; OLIVEIRA, L. R. Climate change and rural–urban migration in the Brazilian Northeast region. **GeoJournal**. v. 87, n. 3, p. 2159–2179. 2021. Disponível em: https://doi.org/10.1007/s10708-020-10349-3. Acesso em janeiro de 2023.

DENG, X.; SONG, C.; LIU, K.; et al.. Remote sensing estimation of catchment-scale reservoir water impoundment in the upper Yellow River and implications for river discharge alteration. **Journal of Hydrology**. v. 585, article: 124791. 2020. Disponível em: https://doi.org/10.1016/j.jhydrol.2020.124791. Acesso em novembro de 2022.

DI BALDASSARRE, G.; SIVAPALAN, M.; RUSCA, M.; et al.. Sociohydrology: Scientific Challenges in Addressing the Sustainable Development Goals. **Water Resources Research**. 55 (8): 6327–55. 2019. Disponível em: https://doi.org/10.1029/2018wr023901. Acesso em janeiro de 2023.

DUTTA, S.; REHMAN, S.; CHATTERJEE, S.; et al.. Analyzing seasonal variation in the vegetation cover using NDVI and rainfall in the dry deciduous forest region of Eastern India. **Forest Resources Resilience and Conflicts**. p. 33–48, 2021. Disponível em: https://doi.org/10.1016/B978-0-12-822931-6.00003-4>. Acesso em janeiro de 2023.

FERNANDES, M. M.; FERNANDES, M. R. M.; GARCIA, J. R.; *et al.* Land use and land cover changes and carbon stock valuation in the São Francisco river basin, Brazil. **Environmental Challenges**. v. 5, article: 100247. 2021. Disponível em: https://doi.org/10.1016/j.envc.2021.100247>. Acesso em novembro de 2022.

FRANCISCO, P. R. M.; CHAVES, I. B.; CHAVES, L. H. G.. **Bioma Caatinga e Degradação: Modelo de Mapeamento**. Campina Grande – PB: EPGRAF. 1ª Edição. 2020. 80 f. ISBN: 978-65-86474-01-5. Disponível em: <https://www.researchgate.net/publication/339988707_Bioma_Caatinga_e_Degradacao_Mod elo_de_Mapeamento>. Acesso em janeiro de 2023.

FRANCISCO, P. R. M.; CHAVES, I. B.; CHAVES, L. H. G.; et al.. Mapeamento daVulnerabilidade das Terras da Bacia Hidrográfica do Rio Taperoá (Mapping the Vulnerabilityof the Land of River Basin Taperoá). Revista Brasileira de Geografia Física. v. 6, n. 2, p.271–286.2013.Disponívelem:

<https://periodicos.ufpe.br/revistas/rbgfe/article/view/232951/26920>. Acesso em janeiro de 2023.

GEE – Google Earth Engine. A planetary-scale platform for Earth science data & analysis. 2023. Disponível em: https://earthengine.google.com/. Acesso em janeiro de 2023.

GOMES, M. G.; VARGAS, T.; BELLADONA, R.; et al.. Aplicação do Interpolador IDW para elaboração de Mapas Hidrogeológicos Paramétricos na Região da Serra Gaúcha. **Scientia Cum Industria**. v.6, p. 38–43. 2018. Disponível em: http://dx.doi.org/10.18226/23185279.v6iss3p38. Acesso em novembro de 2022.

GUERRA, A.; REIS, L. K.; BORGES, F. L. G.; *et al.* Ecological restoration in Brazilian biomes: Identifying advances and gaps. **Forest Ecology and Management**. v. 458, p. 117802. 2020. Disponível em: https://doi.org/10.1016/j.foreco.2019.117802>. Acesso em novembro de 2022.

HOPKINS, W.G. A new view of statistics: Correlation coefficient. 2009. Disponível em: http://www.sportsci.org/resource/stats/correl.html. Acesso em novembro de 2022.

HUANG, S.; TANG, L.; HUPY, J. P.; et al.. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. **Journal of Forestry Research**. v. 32, n. 1, p. 1–6. 2020. Disponível em: https://doi.org/10.1007/s11676-020-01155-1>. Acesso em janeiro de 2023.

HUANG, Z.; LIU, X.; SUN, S.; *et al.* Global assessment of future sectoral water scarcity under adaptive inner-basin water allocation measures. **Science of The Total Environment**. v. 783, article: 146973. 2021. Disponível em: https://doi.org/10.1016/j.scitotenv.2021.146973. Acesso em novembro de 2022.

IBGE – Instituto Brasileiro de Geografia e Estatística. Biomas e sistema costeiro-marinho do Brasil: compatível com a escala 1:250.000. 2019. Rio de Janeiro, Coordenação de Recursos Naturais e Estudos Ambientais. 168 p. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101676.pdf>. Acesso em fevereiro de 2023. IBGE – Instituto Brasileiro de Geografia e Estatística. **Censo Agro 2017**. 2021. Disponível em: https://censos.ibge.gov.br/agro/2017/templates/censo_agro/resultadosagro/pecuaria.html?loc alidade=0&tema=75657>. Acesso em novembro de 2022.

INMET – Instituto Nacional de Meteorologia. **Dados Históricos Anuais**. 2021. Disponível em: https://portal.inmet.gov.br/dadoshistoricos. Acesso em novembro de 2022.

INMET – Instituto Nacional de Meteorologia. **Normais Climatológicas Do Brasil**. 2010. Disponível em: https://portal.inmet.gov.br/normais>. Acesso em novembro de 2022.

IPCC. **The Intergovernmental Panel on Climate Change**. 2021. Disponível em: https://www.ipcc.ch/. Acesso em novembro de 2022.

KIM, D.; LEE, H.; JUNG, H. C.; et al.. Monitoring river basin development and variation in water resources in transboundary Imjin River in North and South Korea using remote sensing. **Remote** Sensing. v.12, article: 195. 2020. Disponível em: https://doi.org/10.3390/rs12010195>. Acesso em novembro de 2022.

LEDRU, M. P.; JESKE-PIERUSCHKA, V.; BREMOND, L.; et al.. When Archives Are Missing, Deciphering the Effects of Public Policies and Climate Variability on the Brazilian Semi-Arid Region Using Sediment Core Studies. **Science of the Total Environment**. 723 (June): 137989. 2020. Disponível em: https://doi.org/10.1016/j.scitotenv.2020.137989. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. Análise de Acurácia. 2023. Disponível em: https://mapbiomas.org/analise-de-acuracia. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Plataforma de Mapas e Dados**. 2021. Disponível em: http://plataforma.mapbiomas.org/map>. Acesso em novembro de 2022.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; *et al.* Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**. v. 90, n. 2 suppl 1, p. 1973–1985. 2018. Disponível em: https://doi.org/10.1590/0001-3765201720170206>. Acesso em novembro de 2022.

104

MARENGO, J. A.; GALDOS, M. V.; CHALLINOR, A.; *et al.* Drought in Northeast Brazil: A review of agricultural and policy adaptation options for food security. **Climate Resilience and Sustainability.** v. 1, n. 1. 2021. Disponível em: https://doi.org/10.1002/cli2.17>. Acesso em: novembro de 2022.

MARTINS, M.A.; HOCHRAINER-STIGLER, S.; PFLUG, G.. Vulnerability of agricultural production in the Brazilian semi-arid: an empirical approach including risk. **IDRiM**. 7(1), 2185–8322. 2017. Disponível em: https://doi.org/10.5595/idrim.2017.0174>. Acesso em janeiro de 2023.

MARTINS, V. S.; KALEITA, A.; BARBOSA, C. C. F.; et al.. Remote sensing of large reservoir in the drought years: Implications on surface water change and turbidity variability of Sobradinho reservoir (Northeast Brazil). **Remote Sensing Applications: Society and Environment**, v. 13, p. 275–288. 2019. Disponível em: <https://doi.org/10.1016/j.rsase.2018.11.006>. Acesso em janeiro de 2023.

MCFEETERS, S. K.. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**. v.17:7, p. 1425-1432. 1996. Disponível em: https://doi.org/10.1080/01431169608948714>. Acesso em novembro de 2022.

MEDEIROS, A. S.; MAIA, S. M. F.; SANTOS, T. C.; et al.. Soil carbon losses in conventional farming systems due to land-use change in the Brazilian semi-arid region. Agriculture, Ecosystems & Environment. v. 287, p. 106690. 2020. Disponível em: https://doi.org/10.1016/j.agee.2019.106690>. Acesso em janeiro de 2023.

MELO, M. V. N.; OLIVEIRA, M. E. G.; ALMEIDA, G. L. P.; et al.. Spatiotemporal characterization of land cover and degradation in the agreste region of Pernambuco, Brazil, using cloud geoprocessing on Google Earth Engine. **Remote Sensing Applications: Society and Environment**. v. 26, p. 100756. 2022. Disponível em: https://doi.org/10.1016/j.rsase.2022.100756>. Acesso em janeiro de 2023.

MUTTI, P. R.; SILVA, L. L.; MEDEIROS, S. S.; et al.. Basin scale rainfall-evapotranspiration dynamics in a tropical semiarid environment during dry and wet years. **International Journal**

of Applied Earth Observation and Geoinformation. v. 75, p. 29–43. 2019. Disponível em: https://doi.org/10.1016/j.jag.2018.10.007>. Acesso em janeiro de 2023.

OGILVIE, A.; BELAUD, G.; MASSUEL, S.; et al.. Surface water monitoring in small water bodies: potential and limits of multi-sensor Landsat time series. **Hydrology and Earth System Sciences**, v. 22, n. 8, p. 4349–4380. 2018. Disponível em: https://doi.org/10.5194/hess-22-4349-2018>. Acesso em janeiro de 2023.

OLIVEIRA, M. L.; SANTOS, C. A. C.; OLIVEIRA, G.; et al.. Effects of human-induced land degradation on water and carbon fluxes in two different Brazilian dryland soil covers. **Science of The Total Environment**. v. 792, p. 148458. 2021. Disponível em: https://doi.org/10.1016/j.scitotenv.2021.148458>. Acesso em janeiro de 2023.

OLIVEIRA-JÚNIOR, J. F.; SILVA JUNIOR, C. A.; TEODORO, P. E.; et al.. Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. **International Journal of Climatology**. v. 41 (9), p. 4478–4493. 2021. Disponível em: https://doi.org/10.1002/joc.7080. Acesso em novembro de 2022.

PAN, N.; FENG, X.; FU, B.; et al.. Increasing global vegetation browning hidden in overall vegetation greening: Insights from time-varying trends. **Remote Sensing of Environment**, v. 214, p. 59–72. 2018. Disponível em: https://doi.org/10.1016/j.rse.2018.05.018>. Acesso em janeiro de 2023.

PEREIRA, A. P.; LIMA, L. A. L.; BEZERRA, W. M.; *et al.* Grazing exclusion regulates bacterial community in highly degraded semiarid soils from the Brazilian Caatinga biome. **Land Degradation & Development**. v. 32, n. 6, p. 2210–2225. 2021. Disponível em: https://doi.org/10.1002/ldr.3893. Acesso em novembro de 2022.

PEREIRA, L. E.; AMORIM, G.; GRIGIO, A. M.; et al.. Análise Comparativa entre Métodos de Índice de Água por Diferença Normalizada (NDWI) em Área Úmida Continental. Anuário do Instituto de Geociências, v. 41, n. 2, p. 654–662, 2018. Disponível em: http://dx.doi.org/10.11137/2018_2_654_662>. Acesso em janeiro de 2023.

PERLIN, J. L.; SILVIERA, D. P.; KOEFENDER, J.. The Analysis of Water Availability as an Important Factor for Farmers' Permanence in the Field: A Study in Southern Brazilian Countryside. **International Journal for Innovation Education and Research.** v. 7, p. 296-306. 2019. Disponível em: https://doi.org/10.31686/ijier.Vol7.Iss10.1774>. Acesso em janeiro de 2023.

REBELLO, V. P. A.; GETIRANA, A.; ROTUNNO FILHO, O. C.; et al.. Spatiotemporal vegetation response to extreme droughts in eastern Brazil. **Remote Sensing Applications: Society and Environment**. v. 18, p. 100294. 2020. Disponível em: https://doi.org/10.1016/j.rsase.2020.100294>. Acesso em janeiro de 2023.

RIBEIRO NETO, G. G.; MELSEN, L. A.; MARTINS, E. S. P. R.; et al.. Drought Cycle Analysis to Evaluate the Influence of a Dense Network of Small Reservoirs on Drought Evolution. **Water Resources Research**, v. 58, n. 1, jan. 2022. Disponível em: https://doi.org/10.1029/2021WR030799>. Acesso em janeiro de 2023.

SALVATIERRA, L. H. A.; LADLE, R. J.; BARBOSA, H.; *et al.* Protected areas buffer the Brazilian semi-arid biome from climate change. **Biotropica**. v. 49, n. 5, p. 753–760. 2017. Disponível em: https://doi.org/10.1111/btp.12459>. Acesso em novembro de 2022.

SANTIAGO, D. B., BARBOSA, H. A.; CORREIA FILHO, W. L. F.; et al. Interactions of Environmental Variables and Water Use Efficiency in the Matopiba Region via Multivariate Analysis. **Sustainability**. 14 (14): 8758. 2022. Disponível em: https://doi.org/10.3390/su14148758>. Acesso em janeiro de 2023.

SANTIAGO, D. B.; CORREIA FILHO, W. L. F.; OLIVEIRA-JÚNIOR, J. F.; et al.. Mathematical modeling and use of orbital products in the environmental degradation of the Araripe Forest in the Brazilian Northeast. **Modeling Earth Systems and Environment**. v. 5, n. 4, p. 1429–1441. 2019. Disponível em: https://doi.org/10.1007/s40808-019-00614-x. Acesso em janeiro de 2023.

SANTOS, A.; LOPES, P. M. O.; SILVA, M. V.; et al.. Causes and consequences of Seasonal changes in the water flow of the São Francisco river in the semiarid of Brazil. Environmental

and Sustainability Indicators. v. 8, 1–15. 2020. Disponível em: https://doi.org/10.1016/j.indic.2020.100084>. Acesso em novembro de 2022.

SEDDON, A. W. R.; MACIAS-FAURIA, M.; LONG, P. R.; et al.. Sensitivity of global terrestrial ecosystems to climate variability. **Nature**. v. 531, n. 7593, p. 229–232. 2016. Disponível em: https://doi:10.1038/nature16986>. Acesso em novembro de 2022.

SILVA JÚNIOR, J. A.; MORAES, V. S.; CANDEIAS, A. L. B.; et al.. Análise do NDVI e NDWI e umidade local no Munícipio de Água Branca – AL. Congresso Técnico Científico da Engenharia e da Agronomia. 2018. Disponível em: <https://www.confea.org.br/sites/default/files/antigos/contecc2018/agrimensura/1_adneneuln md%C3%A1ba.pdf>. Acesso em janeiro de 2023.

SILVA, J. L. B.; MOURA, G. B. A.; SILVA, M. V.; et al.. Environmental degradation of vegetation cover and water bodies in the semiarid region of the Brazilian Northeast via cloud geoprocessing techniques applied to orbital data. **Journal of South American Earth Sciences**, v. 121, p. 104164. 2023. Disponível em: https://doi.org/10.1016/j.jsames.2022.104164>. Acesso em janeiro de 2023.

SILVA, J. L. B.; MOURA, G. B. A.; SILVA, M. V.; et al.. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**. v. 20, article: 100372. 2020a. Disponível em: https://doi.org/10.1016/j.rsase.2020.100372>. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; ALMEIDA, G. L. P.; et al.. Spatio-temporal monitoring of soil and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semiarid region. Journal of South American Earth Sciences. v. 107, article: 103155. 2021. Disponível em: https://doi.org/10.1016/j.jsames.2021.103155. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; LOPES, P. M. O.; et al.. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid.
Remote Sensing Applications: Society and Environment. v. 19, article: 100353, 2020b. Disponível em: https://doi.org/10.1016/j.rsase.2020.100353>. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; OLIVEIRA-JÚNIOR, J. F.; et al.. Remote Sensing Techniques via Google Earth Engine for Land Degradation Assessment in the Brazilian Semiarid Region, Brazil. Journal of South American Earth Sciences. v.120, article: 104061. 2022. Disponível em: https://doi.org/10.1016/j.jsames.2022.104061. Acesso em novembro de 2022.

SOUZA, W. O.; REIS, L. G. M.; RUIZ-ARMENTEROS, A. M.; et al.. Analysis of Environmental and Atmospheric Influences in the Use of SAR and Optical Imagery from Sentinel-1, Landsat-8, and Sentinel-2 in the Operational Monitoring of Reservoir Water Level. **Remote Sensing**. v. 14, n. 9, p. 2218. 2022. Disponível em: https://doi.org/10.3390/rs14092218>. Acesso em janeiro de 2023.

TEIXEIRA, D. B.; VELOSO, M. F.; FERREIRA, F. L. V.; et al.. Spectro-temporal analysis of the Paraopeba River water after the tailings dam burst of the Córrego do Feijão mine, in Brumadinho, Brazil. **Environmental Monitoring and Assessment**. v.193, p. 435. 2021. Disponível em: https://doi.org/10.1007/s10661-021-09218-4. Acesso em novembro de 2022.

TOMASELLA, J.; VIEIRA, R. M. S. P.; BARBOSA, A. A.; et al. Desertification trends in the Northeast of Brazil over the period 2000–2016. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 197–206. 2018. Disponível em: https://doi.org/10.1016/j.jag.2018.06.012>. Acesso em janeiro de 2023.

USGS/NASA. United States Geological Survey/National Aeronautics and Space Satellite Missions. 2022. Disponível Administration. Landsat em: https://www.usgs.gov/landsat-missions/landsat-satellite-missions. Acesso em novembro de 2022.

VAN LANGEN, S. C. H.; COSTA, A. C.; RIBEIRO NETO, G. G.; et al.. Effect of a reservoir network on drought propagation in a semi-arid catchment in Brazil. Hydrological Sciences Journal. v. 66:10, p. 1567-1583. 2021. Disponível em: https://doi.org/10.1080/02626667.2021.1955891>. Acesso em janeiro de 2023.

VIEIRA, R. M. D. S. P.; TOMASELLA, J.; BARBOSA, A. A.; et al.. Desertification risk assessment in Northeast Brazil: Current trends and future scenarios. Land Degradation & Development. v. 32, n. 1, p. 224–240. 2020. Disponível em: https://doi.org/10.1002/ldr.3681 Acesso em janeiro de 2023.

VIVIROLI, D.; KUMMU, M.; MEYBECK, M.; et al.. Increasing Dependence of Lowland Populations on Mountain Water Resources. **Nature Sustainability**. 3 (11): 917–28. 2020. Disponível em: https://doi.org/10.1038/s41893-020-0559-9>. Acesso em janeiro de 2023.

WARRICK, A. W.; NIELSEN, D. R.. Spatial variability of soil physical properties in the field. In: HILLEL, D. (Ed.). **Applications of Soil Physics**. New York: Academic, v.2, p. 319-344. 1980.

WASHINGTON, B.; SEYMOUR, L.; MOTE, T.; et al.. Identifying and extracting a seasonal streamflow signal from remotely sensed snow cover in the Columbia River Basin. **Remote Sensing Applications: Society and Environment**. v. 14, p. 207–223. 2019. Disponível em: https://doi.org/10.1016/j.rsase.2018.03.003>. Acesso em novembro de 2022.

XU, H.. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**. v. 27, p. 3025-3033. 2006. Disponível em: https://doi.org/10.1080/01431160600589179>. Acesso em novembro de 2022.

YANG, Y.; WANG, S.; BAI, X.; et al.. Factors Affecting Long-Term Trends in Global NDVI. **Forests**. v. 10, n. 5, p. 372. 2019. Disponível em: https://doi.org/10.3390/f10050372. Acesso em janeiro de 2023.

ZHANG, P.; ZHANG, L.; CHANG, Y.; et al.. Food-Energy-Water (FEW) Nexus for Urban Sustainability: A Comprehensive Review. **Resources, Conservation and Recycling.** 142 (March), p. 215–24. 2019. Disponível em: https://doi.org/10.1016/j.resconrec.2018.11.018>. Acesso em janeiro de 2023.

CAPÍTULO III

MODELAGEM ESPAÇO-TEMPORAL DA VULNERABILIDADE DA TERRA E PASTAGEM EM BACIAS LEITEIRAS NA REGIÃO NORDESTE DO BRASIL

RESUMO: No semiárido brasileiro predomina a agropecuária de subsistência e as pastagens são a forma mais prática e econômica de alimentação dos bovinos, garantindo baixos custos de produção. No entanto, o manejo inadequado e o uso de altas taxas de lotação contribuem para sua degradação e estigmatização da pecuária. Objetiva-se com esse estudo, avaliar a dinâmica espaço-temporal da vulnerabilidade da terra e as áreas de pastagens nas bacias leiteiras dos Estados de Pernambuco e Alagoas, inseridas na Bacia Hidrográfica do Rio Ipanema (BHRI), Região Nordeste do Brasil. Mapas de Uso e Cobertura da Terra (LULC), Determinação e Índice de Vulnerabilidade de Degradação (IVD), Índice de Vulnerabilidade da Terra (IVT), Série Temporal de Rebanho Efetivo (RE), Vacas Ordenhadas (VO) e Produção de Leite (PL), e Cobertura e Qualidade de Pastagens foram confeccionados no software QGIS 3.22. Verificouse a relação inversa entre as classes de uso do solo Florestal, Agricultura e Pecuária, na qual, ao longo do período houve uma diminuição da área de floresta (Caatinga) em detrimento do aumento da área agropecuária. A área da BHRI apresenta um relevo predominantemente plano com um risco de degradação muito alto durante o período analisado. O número de RE em todos os munícipios manteve-se estável, com pouca variação, na análise de VO, observou-se uma concordância com as informações contidas na análise de RE, bem como na PL. O município de Itaíba (Pernambuco – PE) figurou entre os municípios com maior quantitativo de RE, VO, PL, seguido pelos municípios de Bom Conselho (PE), Buíque (PE) e Pedra (PE). Observou-se uma correlação entre os valores de maiores áreas de pastagem com os parâmetros de RE, VO e PL, onde o município que apresentou maior área de pastagem foi Itaíba (PE), seguido por Buíque (PE), Águas Belas (PE), Tupanatinga (PE) e Pedra (PE). Na avaliação da qualidade das pastagens, observou-se que as áreas com Degradação Severa apresentaram valores crescentes entre 2010-2014, a partir do ano de 2015 houve uma diminuição gradativa na classe, voltando a crescer em 2020, a classe de Degradação Moderada manteve valores médios elevados e as áreas de pastagens Não Degradadas foi a menor de todas entre 2012-2020. A análise por componentes principais (PCA) admitindo-se as variáveis IVT, Classes do MapBiomas (5 classes), número de Rebanho Efetivo e Pastagem no período seco e chuvoso, para a série de 2010 a 2020, demonstrou que a variância total aponta representatividade e significância dos dados em 77,3% para o período seco e 77,2% para o período chuvoso no acumulado em PC2 indicando a significância das correlações entre as variáveis analisadas. Por fim, observou-se que ao longo dos 10 anos que compreendem o período de estudo (2010-2020), as bacias leiteiras de Pernambuco e Alagoas, inseridas na BHRI, apresentaram forte processo de degradação, com perda de aproximadamente 16% da vegetação nativa do Bioma Caatinga, aumento das áreas de pastagem e da vulnerabilidade da terra.

PALAVRAS-CHAVE: caatinga, geoprocessamento, pecuária bovina, semiárido, sensoriamento remoto.

SPACE-TEMPORAL MODELING OF LAND VULNERABILITY AND PASTURE IN DAIRY BASINS IN THE NORTHEAST REGION OF BRAZIL

ABSTRACT: In the Brazilian semi-arid region subsistence farming predominates and pastures are the most practical and economical way of feeding cattle, ensuring low production costs. However, inadequate management and the use of high stocking rates contribute to its degradation and stigmatization of livestock. The objective of this study is to evaluate the spacetime dynamics of land vulnerability and pasture areas in the dairy basins of the states of Pernambuco and Alagoas, inserted in the Ipanema River Basin (BHRI), Northeast Region of Brazil. Land Use and Cover Maps (LULC), Determination and Degradation Vulnerability Index (IVD), Land Vulnerability Index (IVT), Effective Herd Time Series (RE), Milked Cows (VO) and Milk Production (PL), and Pasture Coverage and Quality were created using QGIS 3.22 software. There was an inverse relationship between the Forest, Agriculture and Livestock land use classes, in which, over the period there was a decrease in the forest area (Caatinga) to the detriment of the increase in the agricultural area. The BHRI area features a predominantly flat relief with a very high risk of degradation during the analyzed period. The number of RE in all municipalities remained stable, with little variation, in the VO analysis, agreement was observed with the information contained in the RE analysis, as well as in the PL. The municipality of Itaíba (Pernambuco - PE) was among the municipalities with the highest number of RE, VO, PL, followed by the municipalities of Bom Conselho (PE), Buíque (PE) and Pedra (PE). A correlation was observed between the values of the largest pasture areas with the RE, VO and PL parameters, where the municipality that had the largest pasture area was Itaíba (PE), followed by Buíque (PE), Águas Belas (PE), Tupanatinga (PE) and Pedra (PE). In evaluating the quality of the pastures, it was observed that the areas with Severe Degradation showed increasing values between 2010-2014, from the year 2015 there was a gradual decrease in the class, growing again in 2020, the Moderate Degradation class maintained values high averages and areas of Non-Degraded pastures was the lowest of all between 2012-2020. The principal component analysis (PCA) assuming the variables IVT, MapBiomas Classes (5 classes), number of Effective Herd and Pasture in the dry and rainy season, for the series from 2010 to 2020, demonstrated that the total variance indicates representativeness and data significance of 77.3% for the dry period and 77.2% for the rainy period in the accumulated in PC2 indicating the significance of the correlations between the analyzed variables. Finally, it was observed that over the 10 years that comprise the study period (2010-2020), the dairy basins of Pernambuco and Alagoas, inserted in the BHRI, showed a strong degradation process, with loss of approximately 16% of the vegetation native to the Caatinga Biome, increased pasture areas and land vulnerability.

KEY WORDS: caatinga, geoprocessing, cattle raising, semi-arid, remote sensing.

3.1. INTRODUÇÃO

As mudanças climáticas e seus impactos estão entre as ameaças mais desafiadoras que o mundo enfrenta atualmente (IPCC, 2021), de acordo com as projeções climáticas futuras deste relatório, o aumento esperado na duração e intensidade das ondas de calor extremo e mudanças na distribuição de precipitação, disponibilidade de água e seca podem reduzir a produtividade agropecuária e aumentar o risco de insegurança alimentar.

A tendência de mudanças climáticas e aquecimento global de longo prazo é particularmente acentuada nas regiões semiáridas (Huang et al., 2015). Essas regiões são caracterizadas por baixa precipitação e altas temperaturas, e já enfrentam desafios significativos para garantir a segurança alimentar e o desenvolvimento econômico (Stavi et al., 2021), somando-se a isso, as mudanças climáticas estão causando ainda mais escassez de água e aumentando a frequência e intensidade de eventos climáticos extremos, como secas e ondas de calor (Burney et al., 2014; Oliveira et al., 2021).

De acordo com Andrade et al. (2020) e Maranhão et al. (2022), as regiões semiáridas correspondem a aproximadamente 40% da superfície da Terra e cerca de 50% da população que vive nestas regiões obtêm suas necessidades básicas (água, alimentos, fibras, energia, etc.) dos bens e serviços gerados nesses ecossistemas.

A região semiárida brasileira ocupa todos os estados da região Nordeste do Brasil, com uma área de 1.006.738 km², que cobre os limites territoriais de 1.171 municípios e uma população estimada de 26.378.043 habitantes (Medeiros, 2018; Silva et al., 2020b). Essas regiões estão sob o domínio do Bioma Caatinga, bioma esse, exclusivamente brasileiro, com extensão de 982.563 km², ocupando o equivalente a 11% de todo território nacional, que sofre o reflexo da elevada variabilidade das chuvas, com pouca distribuição espacial e concentradas ao longo do tempo (Silva et al., 2020b). Nesse sentido, apresenta uma cobertura vegetal altamente dinâmica, que exige um monitoramento constante das condições de mudança dos diferentes usos do solo (Vieira et al., 2020; Oliveira et al., 2021). Estima-se que a perda contínua líquida de cobertura vegetal seja da ordem de 0,3% ano⁻¹ (Queiroz et al., 2020). Somando-se a isso, as áreas nativas ainda dividem espaço com cultivos agrícolas, pastagens e paisagens herbáceas que se alternam com o solo descoberto (Althoff et al., 2018).

Na região semiárida brasileira, predomina a agropecuária de subsistência, sendo a base da sociedade rural e a principal atividade econômica da maioria dos pequenos municípios da região (Silva et al., 2020b; Fernandes et al., 2021; Silva et al., 2023). De acordo com Medeiros et al. (2020) e Vieira et al. (2020), o sistema agrícola predominante nessa região é a agricultura de sequeiro, geralmente em pequenas propriedades, que cultivam lavouras de subsistência com queima de vegetação nativa e preparo convencional do solo em paralelo à pecuária extensiva.

Entre os anos de 2013 a 2015, a região Nordeste apresentou um crescimento anual do setor agropecuário de aproximadamente 3.374 ha, seguido da redução da mata nativa do bioma Caatinga (Silva et al., 2020b, Barreto-Garcia et al., 2021), que é considerado um dos mais ameaçados pela degradação ambiental, devido à predominância do clima semiárido (Vieira et al., 2020).

A produção agropecuária pode resultar em degradação dos ecossistemas, contaminação de alimentos, solos e água, elevação do custo de captação da água para abastecimento humano e aumento das emissões de gases do efeito estufa por meio do desmatamento (Campos et al., 2015). Esse cenário leva a comunidade científica a adotar abordagens mais integrativas para o enfrentamento do problema, considerando tanto as mudanças climáticas quanto o desenvolvimento sustentável, com especial atenção para as áreas áridas e semiáridas, que normalmente apresentam baixa fertilidade e cobertura vegetal esparsa, caracterizando um ecossistema frágil (Mariano et al., 2018), com maior aptidão a desertificação, marcado por condições climáticas adversas e vulnerabilidade social. A desertificação é um problema global, afetando cerca de um terço da superfície terrestre do planeta, especialmente em regiões áridas e semiáridas e é caracterizada pela erosão do solo, redução na qualidade da água e perda de biodiversidade, prejudicando a agricultura, a pecuária e a subsistência das populações locais (Naorem et al., 2023).

As pastagens são a maneira mais prática e econômica para a alimentação de bovinos, garantindo baixos custos de produção, no entanto, o manejo inadequado e a utilização de taxas de lotação elevadas, que ultrapassam a capacidade de suporte do pasto (Campos et al. 2015), contribuem para sua degradação e a estigmatização da pecuária extensiva, como atividade improdutiva e essencialmente danosa ao meio ambiente (Dias Filho, 2014). De acordo com Silva et al. (2021) as áreas de pastagem, compreendem o principal uso do solo no território brasileiro, ocupando aproximadamente 20% das terras nacionais, sendo a principal fonte de alimento para a pecuária comercial. Segundo o último censo do Instituto Brasileiro de Geografia e Estatística (IBGE), 47% das unidades produtivas do setor agropecuário são compostas por pastagens, seja na forma natural e/ou plantada (IBGE, 2021) e sua degradação é um agravante

no cenário agrícola brasileiro, afetando diretamente a produção de carne e leite (Batista et al., 2020).

Estima-se que 75% da superfície terrestre esteja sob algum grau de degradação do solo, que deverá aumentar para 90% até 2050 (Pereira; Bogunovic, 2019), no entanto, segundo os autores, as estimativas de degradação da terra não são conclusivas e apresentam grandes discrepâncias. As inconsistências entre os estudos são atribuídas aos métodos aplicados, que capturam diferentes aspectos da degradação, mas negligenciam o quadro completo, entre os métodos mais usados estão: a opinião de especialistas, imagens de satélite, modelos biofísicos e terras agrícolas abandonadas (Gibbs e Salmon, 2015). De todos os métodos, talvez o mais preciso é o baseado em imagens de satélite, pois mostram a degradação real do solo e não são limitados a certos tipos de uso da terra (Zhou et al., 2021).

O uso do geoprocessamento em conjunto com técnicas de sensoriamento remoto e imagens de satélite são alternativas para a realização do monitoramento da vulnerabilidade da terra, tornando-se fundamental, e economicamente viável, para a compreensão das dinâmicas espaço-temporais de mudanças na cobertura e uso da terra (Marengo et al., 2018; Santos et al., 2020), de modo que se possa estabelecer técnicas de manejo conservacionistas (sistemas agroflorestais com animais, o manejo agroecológico de pastagens, agricultura de conservação e a integração lavoura-pecuária-floresta), proporcionando cenários futuros menos pessimistas, embasando o suporte de tomada de decisão e planejamento para o uso sustentável da atividade agropecuária (Silva et al., 2022; Melo et al., 2022).

A Bacia Hidrográfica do Rio Ipanema (BHRI), está inserida no bioma Caatinga e no clima semiárido, compreendendo duas das principais bacias leiteiras dos Estados de Pernambuco e Alagoas, com dinâmica expansionista de áreas (Silva et al., 2020b; Fernandes et al., 2021). Nesse contexto, esse estudo objetivou avaliar a dinâmica espaço-temporal da vulnerabilidade da terra e as áreas de pastagens nas bacias leiteiras dos Estados de Pernambuco e Alagoas, inseridas na Bacia Hidrográfica do Rio Ipanema, Região Nordeste do Brasil.

3.2. MATERIAL E MÉTODOS

3.2.1. Área de estudo

A área de estudo localiza-se entre os paralelos 08°18'04" S – 10°0' S e os meridianos 36°0' W e 38°0' W (Figura 3), com altitudes inferiores a 1.115 m e no Bioma Caatinga (MAPBIOMAS BRASIL, 2021). De acordo com a classificação climática proposta por Köppen-Geiger, o clima é predominantemente do tipo BSh e As, clima semiárido quente (Alvares et al., 2013; Beck et al., 2018), com temperatura máxima ocorrendo nos meses de novembro a janeiro (33 °C) e mínimas nos meses de maio a julho (19 °C) com temperaturas médias anuais superiores a 23°C, o período chuvoso está mais concentrado entre os meses de março a julho, com média anual inferior a 700 mm (INMET, 2021). A média anual da evapotranspiração potencial também é elevada, com índices que podem ser superiores a 1.600 mm (Montenegro; Ragab, 2010).



Figura 25. Localização espacial da área de estudo. (A) Delimitação do leito principal do Rio Ipanema e identificação do exutório; (B) Hipsometria com base no modelo de elevação digital (DEM) Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m; (C) Classificação climática de Köppen-Geiger, da BHRI, Pernambuco e Alagoas, Brasil.

As bacias leiteiras de Pernambuco e Alagoas estão inseridas na BHRI, com área de aproximadamente 7.850 km² (IBGE, 2021), localizada, em sua maior parte no Estado de Pernambuco, com sua porção sul no Estado de Alagoas (Figura 26) e está inserida, respectivamente, dentro de dois importantes níveis hidrográficos: a grande Bacia Hidrográfica do Rio São Francisco (macrorregião) e a Bacia Hidrográfica do Baixo São Francisco (mesorregião) (IBGE, 2021).



Figura 26. Municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na BHRI.

De acordo com o Censo Agro de 2017 (IBGE, 2021) Alagoas apresentava rebanho efetivo de 786.018 cabeças (17,6% - Bacia do Rio Ipanema), sendo 81.599 vacas de leite (41,8% - BHRI), que gerou produção de 188.628 (x1.000) kg de leite (51,3% - BHRI). Já Pernambuco, contava com 1.284.796 cabeças (22,5% - BHRI), sendo 222.344 vacas de leite (40,8% - BHRI) e produção de 520.990 (x1.000) kg de leite (56,1% - BHRI), distribuídos em 18 municípios pernambucanos (Águas Belas, Alagoinha, Arcoverde, Bom Conselho, Buíque, Caetés, Capoeiras, Garanhuns, Iati, Ibimirim, Itaíba, Manari, Paranatama, Pedra, Pesqueira, Saloá, Tupanatinga e Venturosa) e 16 municípios alagoanos (Batalha, Belo Monte, Cacimbinhas, Carneiros, Dois Riachos, Jacaré dos Homens, Jaramataia, Major Isidoro, Maravilha, Minador do Negrão, Olho d'Água das Flores, Olivença, Ouro Branco, Poço das Trincheiras, Santana do Ipanema e Senador Rui Palmeira), conforme Tabela 17.

Tabela 17. Comparação da pecuária leiteira entre o Total por Estado, na BHRI e a porcentagem representativa entre eles.

	Estad	0
—	Alagoas	Pernambuco
_	Total	1
Bovinos	786.018	1.284.796
Vacas Ordenhadas	81.599	222.344
Produção de Leite (x1000)	188.628	520.990
—	Bacia do Rio	Ipanema
Bovinos	138.325	288.580
Vacas Ordenhadas	34.129	90.785
Produção de Leite (x1000)	96.778	292.533
_	% Representativa	(Bacia/Total)
Bovinos	17,6	22,5
Vacas Ordenhadas	41,8	40,8
Produção de Leite (x1000)	51,3	56,1

Fonte: Autores (2022) adaptado de Censo Agro 2017 (IBGE, 2021).

3.2.2. Dinâmica da cobertura vegetal via MapBiomas Brasil

Para avaliação da cobertura vegetal, foram extraídos dados para região de estudo proveniente da plataforma MapBiomas (MapBiomas Brasil, 2021). Os dados de uso e cobertura do solo se encontram disponíveis no endereço eletrônico: <u>https://plataforma.brasil.mapbiomas.org/</u>.

O MapBiomas trabalha com o conceito de coleção de dados e atualmente está na versão 7.0. A cada nova coleção todo conjunto de dados pretérito é reprocessado com base nos novos métodos e algoritmos (Silva et al., 2022; MapBiomas Brasil, 2021). Nesse estudo, foi utilizada a coleção de dados da versão 6.0, mais recente à data que o mesmo foi desenvolvido, utilizando um catálogo com 25 classes de legenda, próprio da plataforma, priorizando as classes majoritárias do Nível 1: Floresta (caatinga arbórea), Formação natural não florestal (caatinga arbustiva), Agricultura e Pecuária, Área não vegetada (Infraestrutura Urbana e Solo Exposto) e Corpos hídricos.

Os arquivos raster foram gerados para os anos de 2010 a 2020 para cada tipo de uso do solo e as classes majoritárias foram calculadas pelo plugin "r.report" do *software* GRASS 7, integrado ao QGIS 3.22.

3.2.3. Dados de satélite orbital – Landsat 5/TM e Landsat 8/OLI

O presente estudo foi desenvolvido a partir de imagens orbitais dos Satélites Landsat – 5, com sensor TM e o Landsat – 8 com sensor OLI (Tabela 18), referente a órbita/ponto 215/066, sendo disponibilizadas pelo Serviço Geológico dos Estados Unidos (USGS) via Administração Nacional da Aeronáutica e Espaço (NASA). Em média, um total anual de 10 imagens orbitais foram processadas, entre anos de 2010 e 2020. Ressalta-se que para o ano de 2012, não foi possível a geração dos índices, devido à ausência de cobertura da série Landsat para o período.

Sensor	Banda	Resolução Espectral (µm)	Resolução Espacial (m)	Resolução Temporal
	r1: Azul	0,45 - 0,52	30	
	r2: Verde	0,52 - 0,60	30	
ТМ	r3: Vermelho	0,63 - 0,69	30	
	r4: Infravermelho Próximo	0,76 - 0,90	30	16 dias
	r5: Infravermelho Médio	1,55 - 1,75	30	
	r6: Infravermelho Termal	10,40 - 12,50	120	
	r7: Infravermelho Médio	2,08 - 2,35	30	
	r1: Costal (Aerosol)	0,43 - 0,45	30	16 dias
ULI	r2: Azul	0,45 - 0,51	30	10 dias

Tabela 18. Características das bandas multiespectrais dos Satélites Landsat 5 (TM) e Landsat 8 (OLI).

r3: Verde	0,53 - 0,59	30
r4: Vermelho	0,64 - 0,67	30
r5: Infravermelho Próximo	0,85 - 0,88	30
r6: SWIR 1	1,57 - 1,65	30
r7: SWIR 2	2,11 - 2,29	30
r8: Pancromático	0,50 - 0,68	15
r9: Cirrus	1,36 - 1,38	30
r10: Infravermelho Termal 1	10,6 - 11,19	100
r11: Infravermelho Termal 2	11,50 - 12,51	100

Fonte: Autores (2022) adaptado de USGS (2022)

Para o desenvolvimento de mapas temáticos de vulnerabilidade da terra, a partir de parâmetros geoespaciais e biofísicos, foi determinado o Índice de Vegetação por Diferença Normalizada (NDVI), desenvolvido, gerenciado e processado automaticamente por meio da plataforma digital em nuvem, Google Earth Engine (GEE) - (<u>https://earthengine.google.com/</u>), a partir da linguagem de programação em JavaScript. Essa plataforma inclui bibliotecas com múltiplas funções para análise matemática e modelagem, análises estatísticas e operações de aprendizado de máquina, baseadas em algoritmos específicos para o processamento digital de imagens de satélites (Silva et al., 2022; GEE, 2023).

O conjunto de imagens utilizadas foram oriundas das coleções ee.ImageCollection ("LANDSAT/LT05/C02/T1_L2") e ("LANDSAT/LC08/C02/T1_SR"), sendo adotado como período seco os meses de setembro, outubro, novembro, dezembro e janeiro, e chuvoso os meses de março, abril, maio, junho e julho, de cada ano, com produtos de reflectância da superfície a partir de 01/01/2010 até 31/12/2020, estabelecendo o critério de nuvens inferior a 20%, no qual, para cada período foi estabelecido a média de todas as imagens dentro do critério de porcentagem de nuvens estabelecido, ressalta-se no entanto, que para o ano de 2011 o critério mínimo de nuvens para o período seco e chuvoso, foi de 30 e 55% respectivamente, pois foram as menores porcentagem de nuvens para que a obtenção de imagens da área. Mapas temáticos foram classificados e confeccionados no QGIS 3.22.

3.2.4. Determinação e Classificação da Declividade da Terra

Para geração do mapa de declividade foi utilizado um mosaico de imagens digitais de dados altimétricos do projeto SRTM/NASA, dos quadrantes s10_w038; s10_w037; s09_w038 e s09_w037. Com auxílio da ferramenta de processamento "Análise Raster – Reclassificar por Tabela", disponível no QGIS 3.22, foi realizada a classificação de acordo com os limites das classes de declividade referentes ao risco de degradação da terra para a obtenção do Índice de Vulnerabilidade de Degradação (IVD) apresentados na Tabela 19 e a classificação da declividade de relevo da EMBRAPA (2006), Tabela 20.

Classes de Risco de DegradaçãoLimites de ClassesMuito Baixa0 a 3Baixa3 a 6Média6 a 12Alta12 a 20Muito Alta> 20

Tabela 19. Classes de declividade referentes ao risco de degradação da terra.

Fonte: LOPES; CAMPOS (2019)

Classes de Declividade	Limites de Classes (%)
Plano	0-3
Suave Ondulado	3 - 8
Ondulado	8 - 20
Forte Ondulado	20 - 45
Montanhoso	45 - 75
Escarpado	> 75

Tabela 20. Classes de declividade de acordo com a metodologia da EMBRAPA (2006).

Fonte: EMBRAPA (2006)

3.2.5. Índice de Vulnerabilidade das Terras (IVT)

O cálculo de IVT foi realizado através do processamento das imagens no QGIS 3.22, de acordo com a Figura 27.



Figura 27. Fluxograma do processamento de imagens para o cálculo do Índice de Vulnerabilidade das Terras (IVT).

O NDVI é um indicador sensível da condição da cobertura vegetal, com valores variando entre -1 e 1, no qual, quanto mais próximo de 1, maior é a indicação da atividade vegetal fotossinteticamente ativa. Valores de zero e próximos de zero indicam áreas com pouca ou nenhuma vegetação, e valores negativos são referentes a corpos hídricos (SANTOS et al., 2020). O NDVI foi determinado conforme a Eq. (1) (ROUSE et al., 1974; ALLEN et al., 2002):

$$NDVI = \frac{r_{b \text{ NIR}} - r_{b \text{ RED}}}{r_{b \text{ NIR}} + r_{b \text{ RED}}}$$
(1)

Sendo, $r_{b \text{ NIR}} e r_{b \text{ RED}}$, correspondem às respectivas bandas refletivas 4 e 3 do Landsat-5 de sensor TM, e 5 e 4 do Landsat-8 de sensor OLI.

Através do NDVI foi realizada a reclassificação da vegetação (Tabela 21), caracterizada pelo Índice de Biomassa da Vegetação Lenhosa (IBVL), método proposto por Chaves et al. (2008), desenvolvido para descrever e avaliar a vegetação da Caatinga em seus diferentes estágios de antropização.

A estimativa do Índice de Vulnerabilidade da Vegetação (IVV) desenvolvida por Chaves et al. (2008), foi determinado pela diferença entre o índice de biomassa da vegetação lenhosa (IBVL), para uma condição hipotética de máxima preservação e a condição da vegetação que se quis avaliar, conforme a Eq. (2):

$$IVV = \left(\frac{1}{IBVL}\right)$$
(2)

Considerando, "1", o valor do índice de biomassa da vegetação lenhosa (IBVL) para condição de máxima preservação; e o IBVL, o índice de biomassa para a condição da vegetação avaliada.

O Índice de Vulnerabilidade da Terra (IVT) foi determinado pelo produto entre o índice de vulnerabilidade da vegetação (IVV) e o índice de vulnerabilidade de degradação (IVD), conforme a Eq. (3):

$$IVT = IVV \times IVD$$
 (3)

Para o mapeamento da vulnerabilidade da terra da bacia foi utilizado o cruzamento dos dados relativos aos parâmetros da vegetação e da declividade, conforme a Tabela 21.

Tabela 21. Classes e índices de vegetação e de declividade para estimativa da vulnerabilidade das terras.

Classes de vegetação	Vegetação		Declividade	Declividade Vulnerabilidad		
	IBVL*	IVV	IVD	IVT	Classes	
Arbórea muito densa	1,00	1,00	0 a 3	0.2.6	Muito Baiya	
Arbórea densa	0,80	1,25	0 4 5	0 0 0	With Daixa	
Subarbórea densa	0,68	1,47	3 0 6	6 0 12	Poivo	
Subarbórea arbustiva densa	0,60	1,67	5 a 0	0 a 12	Daixa	
Arbustiva subarbórea densa	0,48	2,08	6 2 1 2	12 2 24	Moderadas	
Arbustiva subarbórea aberta	0,36	2,78	0 a 12	12 a 24	Wouerauas	
Arbustiva subarbustiva aberta	0,24	4,17	12 2 20	24 + 40	Alta	
Subarbustiva arbustiva rala	0,14	7,14	12 a 20	24 a 40	Alla	
Subarbustiva arbustiva muito rala	0,07	14,29	>20	>40	Muito Alta	
Solo exposto	0,05	20,00	>20	> 4 0	Multo Alta	

*IBVL, Índice de Biomassa da Vegetação Lenhosa; IVV, Índice de Vulnerabilidade pela Vegetação; IVD, Índice de Vulnerabilidade de Degradação; IVT, Índice de Vulnerabilidade das Terras.

Fonte: Adaptado de Francisco et al. (2013)

3.2.6. Caracterização da série temporal de Efetivo Bovino, Vacas Ordenhadas e Produção de Leite por município

Foi realizado um levantamento para a quantificação do Rebanho Efetivo (RE), Vacas Ordenhadas (VO) e Produção de Leite (PL) em cada um dos 34 municípios estudados no período 2010-2020 utilizando o banco de dados da Pesquisa de Pecuária Municipal (PPM) da plataforma de Sistema de Recuperação Automática (SIDRA) do Instituto Brasileiro de Geografia e Estatística (IBGE) através do endereço eletrônico: <<u>https://sidra.ibge.gov.br/pesquisa/ppm/quadros/brasil/2021</u>>.

Mapas temáticos foram criados para visualizar a espacialização temporal do número do RE, VO e PL dos municípios da bacia leiteira inseridos na BHRI nos anos 2010 e 2020, através da confecção de arquivos shapefile (.shp) e raster, com a união dos dados obtidos pela SIDRA e os dados geográficos do IBGE, utilizando o QGIS 3.22.

3.2.7. Dinâmica da cobertura de pastagem via Atlas da Pastagens (LAPIG/UFG)

Foram extraídos dados de pastagem para a região de estudo provenientes da plataforma Atlas de Pastagens. Os dados encontram-se disponíveis no seguinte endereço eletrônico: <u>https://atlasdaspastagens.ufg.br/map</u>.

O mapeamento de pastagens utilizado na plataforma é baseado em imagens da série de satélites Landsat e o classificador supervisionado Random Forest e robustas técnicas estatística de amostragem (para fins de calibração e validação dos modelos de classificação), com uma precisão geral de aproximadamente 91% (LAPIG/UFG, 2023).

Os arquivos shapefile foram gerados e transformados em raster para os anos de 2010 a 2020 e processados com o auxílio do QGIS 3.22.

3.2.8. Qualidade de pastagens via MapBiomas Pastagem

Os dados de qualidade de pastagem foram extraídos da plataforma MapBiomas Brasil, provenientes da coleção 6, que se encontram disponíveis no seguinte endereço eletrônico: <u>https://plataforma.brasil.mapbiomas.org/</u>.

De acordo com o MapBiomas (2023) o principal uso do solo brasileiro é a pastagem, o que ocupa uma área de 154 milhões de hectares, de norte a sul do Brasil, e está presente em todos os Biomas do Brasil. O bioma da Caatinga, em 2020, apresentou uma área de pastagem total de cerca de 20,2 milhões de hectares, em termos percentuais, é o 3º bioma mais ocupado por pastagens cultivadas com cerca de 23,1%, ficando atrás apenas da Mata Atlântica (25,7%) e do Cerrado (23,7%).

Os arquivos raster foram processados no QGIS 3.22, e os mapas temáticos produzidos e classificados em três classes majoritárias: severamente degrada, moderadamente degrada e não degradada.

3.2.9. Análises estatísticas

Realizou-se a análise por componentes principais (PCA) admitindo-se as variáveis IVT, Classes do MapBiomas (5 classes), número de Rebanho Efetivo e Pastagem no período seco e chuvoso, para a série de 2010 a 2020. Baseando-se nos componentes principais (PC) foi obtida a matriz de covariância para extração dos autovalores que originam os autovetores. Para identificação das variáveis que apresentaram correlação foi utilizado o critério de Kaiser, considerando os autovalores superiores a 1.0, que geram componentes com quantidade relevante de informação contida nos dados originais (Kaiser, 1958).

Por fim, foi realizada a correlação de Pearson (r) para todas as variáveis, buscando correlacionar com a PCA, de forma a evidenciar as semelhanças entre as variáveis. O programa utilizado para a PCA e correlação de Pearson foi o RStudio, versão 3.6.1 (R Core Team, 2019).

3.3. RESULTADOS E DISCUSSÃO

3.3.1. Classes de cobertura vegetal via MapBiomas Brasil

Observa-se na Figura 28 as classes de uso e ocupação do solo (LULC) e na Figura 29 a quantificação da área em hectares (ha) para o intervalo de tempo de 2010 a 2020. Verificou-se a relação inversa entre as classes Floresta e Agricultura e Pecuária, na qual ao longo do período houve diminuição da área de floresta (Caatinga) em detrimento do aumento da área agropecuária.



Figura 28. Dinâmica espaço-temporal anual do LULC dos anos de 2010 a 2020 na BHRI.

Os anos de 2016 e 2017 apresentaram área florestal de 305.047 ha e 287.852 ha, respectivamente, enquanto a área de agropecuária, para os mesmos anos, saltou de 460.547 ha para 483.125 ha, um desmatamento de 13.696 ha de formação florestal e um acréscimo de 22.578 ha na classe agropecuária (Figura 29). Para o mesmo período de tempo observa-se também uma diminuição da área natural não florestal de 3.270 ha, corroborando os resultados encontrados por Silva et al. (2022) que avaliou o processo de degradação na região semiárida do Vale do Ipojuca, Melo et al. (2022), que caracterizou e avaliou o processo de uso e cobertura do solo no agreste de Pernambuco, Silva et al. (2023) que avaliou a degradação ambiental da cobertura vegetal e corpos d'água no semiárido do NEB.

		0	100000	Área (h 200000 300000	a)) 400000	500000 600000
as		Floresta		_		
ji Forı	nação Natural Nâ	io Florestal				
ajor	Agricultura	e Pecuária				_
S M	Área Nã	o Vegetada 🛉				
asse	Cor	pos d'Água				
Ð	Não	Observado				
	Não Observado	Corpos d'Água	Área Não Vegetada	Agricultura e Pecuária	Formação Natura Não Florestal	l Floresta
2010	136,45	1.384,15	8.836,28	413.033,22	993,53	360.616,37
2011	136,44	1.265,38	11.497,14	436.723,22	780,63	334.597,19
■2012	136,44	768,57	14.924,90	458.079,69	1.376,08	309.714,32
2013	136,45	414,20	20.910,08	451.156,99	1.927,93	310.454,35
2014	136,46	276,90	20.574,68	444.011,72	5.521,80	314.478,44
2015	136,43	217,78	18.661,47	446.850,32	7.170,70	311.963,30
2016	136,44	229,57	14.953,44	460.547,07	4.085,88	305.047,60
2017	136,42	459,23	12.610,96	483.125,65	815,73	287.852,01
2018	136,45	544,67	12.633,91	463.211,66	1.115,31	307.358,00
2019	136,45	507,09	11.884,66	449.270,09	1.722,03	321.479,68
2020	136,44	846,92	11.318,72	467.226,63	2.394,79	303.076,50

Figura 29. Quantificação de áreas (ha) de uso e cobertura da terra para os anos de 2010 a 2020 na BHRI.

Diante dos dados observados, ressalta-se também algumas análises relacionadas a acurácia geral da classificação do MapBiomas para a Coleção 6 (Figura 30), que para o período e área de estudo variou entre 80 e 84% para valores máximo e mínimo, respectivamente, e a média de 82,2% (MapBiomas, 2023).



Figura 30. Precisão do Nível 1 da Coleção 6 do MapBiomas 6 para os anos de 2010 a 2020 dos municípios produtores das bacias leiteiras dos estados de Alagoas e Pernambuco inseridos na BHRI.

De acordo com o ATBD (Algorithm Theoretical Basis Document – Documento de Base Teórica do Algoritmo), que descreve todo o processo de desenvolvimento e produção dos mapas e os algoritmos utilizados, a classificação digital dos mosaicos Landsat no Bioma Caatinga para as classes Agricultura ou Pastagem, ocorre como a integração das duas, Agricultura e Pastagem, não sendo possível distinguir entre elas, e a classificação de Áreas Não Vegetadas, inclui Área Urbana e Solo Exposto. Tal fato pode justificar um possível erro na interpretação dos valores da classe Agricultura e Pecuária para o ano de 2017, que apresentou o maior número de área com 483.125 ha, muito acima de todos os outros anos, que variaram entre 460.000 e 463.000 (2016 e 2018, respectivamente), em detrimento da menor área de Floresta (287.852 ha) de toda a série (2010-2020) e uma das menores áreas para a classe de Formação Natural Não Florestal (815,73 ha), ressalta-se que esse ano também apresentou a segunda menor porcentagem de acurácia geral (80,9%) e a segunda maior discordância de área (-0,055). Outros valores que chamaram a atenção foram os valores da classe de Área Não Vegetada (Infraestrutura Urbana e Solo Exposto), que no ano de 2012 apresentou uma área de 14.920 ha e nos anos de 2013 (20.910 ha) e 2014 (20.574 ha) tendo um acréscimo de 5.990 ha e novamente uma diminuição em 2015 (18.661 ha) de 335,40 ha, como há uma associação de feições nessa classe, supõem-se que essa variação ocorre na feição que corresponde as áreas de Solo Exposto.

3.3.2. Análise de Declividade e Índice de Vulnerabilidade de Degradação (IVD)

Os mapas para determinação da declividade e Índice de Vulnerabilidade de Degradação (IVD) apontam que a área da BHRI apresenta um relevo predominantemente plano com um risco de degradação muito alto. O relevo ondulado e forte ondulado faz correspondência com o risco de degradação baixo e muito baixo (Figura 31).



Figura 31. Classificação da Declividade de acordo com a Metodologia Embrapa (A) e o risco de degradação (B) da área dos municípios das bacias leiteiras dos Estados de Alagoas e Pernambuco, inseridos na BHRI.

Observou-se que o os riscos de degradação Baixo e Muito Baixo também estão diretamente relacionados com as altitudes mais elevadas da área (Figura 25 (B)), nas quais o efeito da declividade, em geral, é minimizado pelos maiores índices de cobertura vegetal, fator que está relacionado com áreas de difícil acesso, solos rasos e inclinados e impróprios para a agricultura (So et al., 2018). Somando-se a isso, Tolche et al. (2021) no estudo de modelagem e acesso à vulnerabilidade da degradação da terra usando técnicas de sensoriamento remoto, discorrem que a inclinação foi encontrada como o principal fator que determina a degradação da terra e Hossain et al. (2020) no estudo da degradação de terras agrícolas: processos e problemas que prejudicam a segurança alimentar futura, afirmam que além da flutuação nas práticas de uso da terra e desmatamento, a topografia e o declive de uma dada paisagem exercem influência na erosão e degradação do solo, ressaltando que, mesmo declives menores podem resultar em erosão devido ao posicionamento topográfico e à exposição a ações antrópicas.

3.3.3. Análise do Índice de Vulnerabilidade das Terras (IVT)

Os resultados obtidos pelo IVT corroboram com os resultados obtidos pelo IVD, apontando que a área da BHRI apresenta um risco de vulnerabilidade de terra considerado alto e que as áreas com maior vulnerabilidade são as áreas com relevo plano e suave ondulado.

Para o período seco (Figura 32), observa-se que o índice permaneceu alto e constante durante toda a série (2010-2020)



Figura 32. Dinâmica espaço-temporal do Índice de Vulnerabilidade das Terras (IVT) para o período seco dos anos de 2010 a 2020 na BHRI.

Na comparação com os mapas de uso e ocupação da terra via MapBiomas (Figura 28), observa-se que as áreas que apresentaram a distribuição da classe moderada de IVT ocorre quase sempre associada às classes baixa e muito baixa de vulnerabilidade em toda a área de estudo, correspondendo as áreas com Floresta (Caatinga). As áreas com risco alto e muito alto correspondem as áreas referente as classes Agricultura e Pecuária, resultados semelhantes foram encontrados por Santos et al. (2020) no estudo sobre causas e consequências das mudanças sazonais na vazão do rio São Francisco no semiárido brasileiro, o estudo revelou a predominância das classes alta e muito alta com valores médios de 15,3 e 58,5%, fator que é agravado em períodos de estiagem, devido às características intrínsecas da vegetação da Caatinga.

No período chuvoso (Figura 33) o índice de vulnerabilidade também permaneceu alto e constante durante toda série, os resultados apresentaram concordância com os dados do período seco, onde as áreas que apresentaram IVT moderado, baixo e muito baixo, correspondem as

áreas com Floresta (Caatinga) e as áreas com risco alto e muito alto correspondem as áreas referente as classes Agricultura e Pecuária, de acordo com os mapas de uso e ocupação da terra (Figura 28). Observa-se também que no período chuvoso, a redução do percentual das classes alta e muito alta é atribuída ao aumento da distribuição e volume das chuvas, conferindo uma maior cobertura vegetal a esta área, resultado semelhante ao obtido por Santos et al. (2020).



Figura 33. Dinâmica espaço-temporal do Índice de Vulnerabilidade das Terras (IVT) para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Nota-se na Tabela 22 que, apesar de manter a classe de índice de vulnerabilidade alto, durante o período chuvoso houve redução percentual da representatividade dessa classe na área. Esse fato também foi encontrado por Cantalice et al. (2019) em estudo com escoamentos laminares em ambiente semiárido, no qual observaram que a presença de vegetação nativa exerce um efeito maior na proteção da cobertura do solo, maior interceptação das chuvas e redução do escoamento superficial.

	1.00	Área das Classes (%)				
1 V 1	Ano	Muito Baixo	Baixo	Moderado	Alto	Muito Alto
	2010	0,43	6,98	25,19	67,27	0,13
	2011	5,73	26,77	24,77	37,35	5,38
	2013	1,72	25,89	44,56	27,53	0,30
	2014	1,12	8,51	25,14	64,56	0,67
Saaa	2015	1,05	15,15	29,42	54,02	0,35
Seco	2016	1,73	14,15	28,39	54,45	1,29
	2017	0,26	4,35	22,36	72,95	0,09
	2018	1,95	11,64	26,67	58,47	1,28
	2019	0,25	6,56	25,99	67,12	0,08
	2020	0,32	2,43	22,01	75,12	0,12
	2010	0,39	9,76	28,97	60,76	0,12
	2011	2,50	18,68	35,40	42,39	1,03
	2013	0,82	19,45	37,45	42,10	0,18
	2014	0,54	12,80	31,52	54,99	0,15
Chuyaga	2015	1,76	23,41	47,02	27,52	0,28
CIIUVOSO	2016	3,04	20,34	46,73	29,32	0,56
	2017	0,59	16,57	30,53	52,16	0,15
	2018	1,91	24,49	38,21	35,01	0,39
	2019	1,30	22,17	37,55	38,70	0,28
	2020	0,53	16,73	31,36	51,23	0,15

Tabela 22. Porcentagem representativa das áreas das classes do Índice de Vulnerabilidade das Terras (IVT) para os períodos seco e chuvoso dos anos de 2010 a 2020 na BHRI.

Como observado anteriormente, a classe de vulnerabilidade alta foi predominante na área em quase todos os anos, durante os períodos seco e chuvoso, com valores máximos de 72,95% (2017) e 60,76% (2010), respectivamente. A classe de vulnerabilidade moderada foi a segunda classe com maior representatividade, com valor de 44,56% (2013) e 47,02% (2015), nos períodos seco e chuvoso, respectivamente.

3.3.4. Análise da Série Temporal do Rebanho Efetivo, Vacas Ordenhadas e Produção de Leite

A análise espacial da série temporal para RE (Unidade Animal – UA) na área de estudo (Figura 34), demonstrou que houve uma queda no número de UA entre os anos de 2010 e 2012 no município de Itaíba – PE (Figura 26), que partiu de 95.000 UA em 2010 aumentando para 100.000 UA em 2011 e diminuindo para 50.000 (UA) em 2012, uma redução de 50%. A partir do ano de 2012-2020 o número do rebanho em todos os munícipios manteve-se estável, com pouca variação, com valor máximo de 60.005 UA em Itaíba e mínimo de 3.600 UA em Paranatama.



Figura 34. Dinâmica espaço-temporal do Rebanho Efetivo (RE) dos anos de 2010 a 2020 na BHRI.

O ranking dos municípios que representam os cinco maiores RE pode ser observado na Tabela 23, onde nota-se que houve pouca variação de posições. O município de Itaíba permaneceu como maior RE durante a série, exceto no período de 2014-2017, ficando em segundo lugar em detrimento do município de Bom Conselho. Houve também uma oscilação no RE do município de Buíque, que figurou entre o segundo e o quarto lugar, com maior permanência no terceiro lugar.

100	Município					
1110	1°	2°	3°	4^o	5°	
2010	Itaíba	Bom Conselho	Buíque	Pedra	Tupanatinga	
2011	Itaíba	Buíque	Bom Conselho	Águas Belas	Pedra	
2012	Itaíba	Bom Conselho	Buíque	Águas Belas	Pesqueira	
2013	Itaíba	Buíque	Bom Conselho	Pedra	Águas Belas	
2014	Bom Conselho	Itaíba	Buíque	Pedra	Águas Belas	
2015	Bom Conselho	Itaíba	Buíque	Águas Belas	Pedra	
2016	Bom Conselho	Itaíba	Buíque	Águas Belas	Pedra	
2017	Bom Conselho	Itaíba	Buíque	Águas Belas	Pedra	
2018	Itaíba	Bom Conselho	Buíque	Pedra	Águas Belas	
2019	Itaíba	Bom Conselho	Pedra	Buíque	Águas Belas	
2020	Itaíba	Bom Conselho	Águas Belas	Pedra	Major Isidoro	

Tabela 23. Ranking dos cinco Municípios com maior número de RE dos anos de 2010 a 2020 na BHRI.

Para a análise de VO (Figura 35), observou-se uma concordância com as informações contidas na análise de RE, onde o valor máximo foi de 33.000 no município de Itaíba (2011) e 497 em Paranatama (2014). Observa-se que assim como no RE, o número de VO no município de Itaíba apresentou uma redução entre os anos de 2010 a 2012, passando de 30.000 VO em 2010 para 33.000 em 2011 e reduzindo para 18.000 em 2012, uma redução de 45,5% no número de VO, valor próximo a redução de 50% em seu RE.



Figura 35. Dinâmica espaço-temporal de Vacas Ordenhadas (VO) dos anos de 2010 a 2020 na BHRI.

O ranking dos cinco municípios com maior número de VO (Tabela 24), demonstra que, apesar do município de Itaíba possuir o maior RE durante quase todos os anos, o número de vacas ordenhadas no município só esteve em primeiro lugar durante 2011-2012 e 2019-2020. Observa-se que os municípios de Buíque, Pedra e Bom Conselho, figuram entre os municípios com maior número de VO de toda a série.

100			Municíp	io	
Ano –	1°	2°	3°	4^o	5°
2010	Itaíba	Buíque	Pedra	Bom Conselho	Pesqueira
2011	Itaíba	Buíque	Pedra	Bom Conselho	Pesqueira
2012	Buíque	Itaíba	Pedra	Bom Conselho	Pesqueira
2013	Pedra	Buíque	Itaíba	Bom Conselho	Tupanatinga
					127

Tabela 24. Ranking dos cinco Municípios com maior número de VO dos anos de 2010 a 2020 na BHRI.

2014	Bom Conselho	Pedra	Buíque	Águas Belas	Itaíba
2015	Bom Conselho	Buíque	Pedra	Águas Belas	Itaíba
2016	Bom Conselho	Buíque	Águas Belas	Pedra	Itaíba
2017	Buíque	Pedra	Bom Conselho	Itaíba	Águas Belas
2018	Buíque	Pedra	Bom Conselho	Itaíba	Águas Belas
2019	Itaíba	Buíque	Bom Conselho	Pedra	Águas Belas
2020	Itaíba	Pedra	Bom Conselho	Águas Belas	Major Isidoro

Ao analisarmos a PL (Figura 36), o padrão observado nas análises anteriores foi repetido. A PL do município de Itaíba, durante os três primeiros anos da série, apresentou o mesmo comportamento, um aumento entre os anos de 2010 para 2011 e uma redução em 2012, com valores de 86.797 (x1000), 102.383 (x1000) e 59.625 (x1000), respectivamente, uma redução de 41,8% na produção. Como esperado, pela análise das variáveis anteriores, o município de Paranatama foi o que apresentou a menor PL, com 72 (x1000), seguindo o padrão de menor RE e a menor quantidade de VO em 2014.



Figura 36. Dinâmica espaço-temporal de Produção de Leite (VO) dos anos de 2010 a 2020 na BHRI.

Os municípios de Buíque, Pedra e Bom Conselho continuaram aparecendo no ranking (Tabela 25) entre os municípios com maior PL da série. Resultados semelhantes foram destacados por Silva e Costa Júnior (2019) no estudo de ²²⁸Ra em leite de vaca de região anômala de Pernambuco, no qual o município de Pedra figura entre os mais relevantes na produção de leite Estado de Pernambuco e, de acordo com o IBGE (2021), esta região é a segunda maior região produtora de leite do NEB.

Ano —			Município		
	1°	2°	3°	4^o	5°
2010	Itaíba	Buíque	Pedra	Tupanatinga	Pesqueira
2011	Itaíba	Buíque	Pedra	Tupanatinga	Pesqueira
2012	Itaíba	Buíque	Pedra	Major Isidoro	Tupanatinga
2013	Pedra	Buíque	Itaíba	Tupanatinga	Major Isidoro

Tabela 25. Ranking dos cinco Municípios com maior PL dos anos de 2010 a 2020 na BHRI.

2014	Pedra	Buíque	Itaíba	Bom Conselho	Major Isidoro
2015	Bom Conselho	Pedra	Buíque	Itaíba	Venturosa
2016	Bom Conselho	Buíque	Águas Belas	Itaíba	Pedra
2017	Buíque	Bom Conselho	Águas Belas	Pedra	Itaíba
2018	Buíque	Pedra	Águas Belas	Bom Conselho	Itaíba
2019	Buíque	Itaíba	Bom Conselho	Pedra	Águas Belas
2020	Itaíba	Pedra	Bom Conselho	Águas Belas	Buíque

Na comparação dos dados apresentados com as informações do mapa de uso e ocupação da terra via MapBiomas (Figura 28) e o IVT (Figuras 32 e 33), verifica-se que os municípios que figuram nos rankings de maior RE, VO e PL estão localizados nas áreas de Agricultura e Pecuária no uso e ocupação da terra, e na classe de vulnerabilidade alta no IVT, corroborando a relação entre todas as variáveis analisadas.

3.3.5. Análise da Dinâmica de Cobertura e Qualidade de Pastagem

-

A análise de cobertura de pastagem via Atlas de Pastagem (Figura 37) traz o quantitativo de pastagem da área total dos municípios.



Figura 37. Dinâmica espaço-temporal da Área de Cobertura de Pastagem Total dos municípios dos anos de 2010 a 2020 na BHRI.

Observa-se mais uma relação entre os valores de maiores áreas de pastagem com os parâmetros de Rebanho Efetivo, Vacas Ordenhadas e Produção de Leite (x1000), onde o município que apresentou maior área de pastagem foi o município de Itaíba com valor máximo de 83.846 ha em 2015 e mínimo de 76.067 ha em 2020 (Tabela 26). De 2010 a 2018, dentro dos cinco maiores municípios com área de pastagem, Buíque ocupou a segunda posição, com valores máximo de 75.984 ha em 2015 e mínimo de 65.709 ha em 2010. Nos anos de 2019 e 2020 o município de Ibimirim figurou em segundo lugar, com 75.555 ha e 75.110 ha, respectivamente, durante os anos 2014 a 2018 ficou em terceiro lugar, e de 2010 a 2013 em quarto lugar. Os outros municípios com maior área são Águas Belas, Tupanatinga e Pedra, com valores máximos de 63.963 ha em 2019, 44.065 ha em 2015, 46.026 ha em 2018, respectivamente.

Ano	Município					
	1°	2°	3°	4^o	5°	
2010	Itaíba	Buíque	Águas Belas	Ibimirim	Tupanatinga	
2011	Itaíba	Buíque	Águas Belas	Ibimirim	Tupanatinga	
2012	Itaíba	Buíque	Águas Belas	Ibimirim	Tupanatinga	
2013	Itaíba	Buíque	Águas Belas	Ibimirim	Tupanatinga	
2014	Itaíba	Buíque	Ibimirim	Águas Belas	Tupanatinga	
2015	Itaíba	Buíque	Ibimirim	Águas Belas	Tupanatinga	
2016	Itaíba	Buíque	Ibimirim	Águas Belas	Tupanatinga	
2017	Itaíba	Buíque	Ibimirim	Águas Belas	Pedra	
2018	Itaíba	Buíque	Ibimirim	Águas Belas	Pedra	
2019	Itaíba	Ibimirim	Buíque	Águas Belas	Pedra	
2020	Itaíba	Ibimirim	Buíque	Águas Belas	Pedra	

Tabela 26. Ranking dos cinco Municípios com maior área de Cobertura de Pastagem dos anos de 2010 a 2020 na BHRI

A qualidade das pastagens via MapBiomas (Figura 38) demostrou dados visuais semelhantes em relação a cobertura de pastagem apontada pelo Atlas de Pastagens (Figura 37), no entanto, a metodologia de classificação das áreas de qualidade de pastagens não apresenta valores quantitativos por município, sendo classificada qualitativamente, dessa forma, um comparativo entre os dados por área de município não foi realizado.



Figura 38. Dinâmica espaço-temporal da Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI.

A análise das classes da qualidade de pastagem permite uma comparação entre as classes de Degradação Severa, Degradação Moderada e Não Degradada, que pode ser observada na Tabela 27.

Classes	Área (ha)				
Clusses	Degradação Severa	Degradação Moderada	Não Degradada		
2010	93.359	150.009	195.328		
2011	118.347	199.882	100.442		
2012	182.393	185.604	51.579		
2013	204.220	173.107	46.250		
2014	272.222	152.569	24.260		
2015	234.501	192.537	35.032		
2016	221.027	183.626	42.873		

Tabela 27. Área das classes de Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI.

2017	210.405	175.385	48.414
2018	185.251	190.702	71.657
2019	139.294	192.502	96.151
2020	146.173	197.212	97.255

As áreas com Degradação Severa apresentaram valores crescentes de 2010 até 2014, com valor máximo de 272.222 ha em 2014, a partir do ano de 2015 houve uma diminuição gradativa na classe, alcançando o valor mínimo de 139.294 ha em 2019, voltando a crescer em 2020. A classe de Degradação Moderada manteve valores médios elevados, com valor máximo de 199.882 ha em 2011 e valor mínimo de 150.009 ha em 2010. Por fim, as áreas da classe de pastagens Não Degradadas foi a menor de toda a classificação, com valores que oscilaram, alcançando valor máximo de 195.328 ha em 2010 e valor mínimo de 24.260 ha em 2014. A Figura 39 representa a variação das classes em relação aos anos.



Figura 39. Representação gráfica da área das classes de Qualidade de Pastagem dos anos de 2010 a 2020 na BHRI.

Segundo a FAO (2009), uma das principais causas da degradação de pastagens de influência antrópica direta é o manejo inadequado, em particular, o uso sistemático de taxas de lotação que excedam a capacidade do pasto de se recuperar do pastejo e do pisoteio, fato que justifica, como podemos observar na quantificação do RE (Figura 34), as áreas que representam a classe de Degradação Severa corresponderem aos municípios que apresentam os maiores
números de RE. Gosch et al. (2021) realizaram avaliação via Landsat da dinâmica quantitativa e qualitativa das áreas de pastagem em assentamentos rurais no Estado de Goiás, concluindo que foi possível extrair informações de imagens de satélites com eficiência e precisão a respeito da qualidade das pastagens, no entanto, ressaltaram que explorar os padrões de qualidade das pastagens via MapBiomas, não apresenta uma acurácia elevada, justificam que a plataforma utiliza padrões gerais sobre a qualidade das pastagens.

3.3.6. Análises Estatísticas

A Tabela 28 apresenta as estatísticas de componentes multivariados por componentes principais (PC), com os autovalores, variância total e variância total acumulada (%) de todos os componentes principais 1 a 8 (PC1 e PC8). De acordo com o critério de Kaiser (1958), os autovalores dos PC1 e 2 foram maiores que 1, portanto, utilizados na geração e interpretação dos gráficos biplot. Juntos representam uma porcentagem de representatividade maior que 70%.

Período Seco								
	<i>PC</i> (1)	<i>PC</i> (2)	<i>PC</i> (3)	<i>PC</i> (4)	<i>PC</i> (5)	<i>PC</i> (6)	<i>PC</i> (7)	<i>PC</i> (8)
Autovalor	4,43	1,76	1,00	0,42	0,21	0,17	0,02	0,00
Variância Total	0,55	0,22	0,12	0,05	0,03	0,02	0,00	0,00
Variância Acumulada (%)	55,3%	77,3%	89,8%	95,1%	97,7%	99,8%	100,0%	100,0%
Período Chuvoso								
		Р	eríodo (Chuvoso				
	<i>PC</i> (1)	P PC(2)	eríodo (PC(3)	Chuvoso PC(4)	<i>PC</i> (5)	<i>PC</i> (6)	<i>PC</i> (7)	<i>PC</i> (8)
Autovalor	<i>PC(1)</i> 4,26	PC(2) 1,91	eríodo (PC(3) 0,99	Chuvoso PC(4) 0,55	<i>PC</i> (5) 0,21	<i>PC(6)</i> 0,06	<i>PC</i> (7) 0,02	<i>PC</i> (8) 0,00
Autovalor Variância Total	<i>PC(1)</i> 4,26 0,53	PC(2) 1,91 0,24	eríodo (PC(3) 0,99 0,12	Chuvoso PC(4) 0,55 0,07	<i>PC</i> (5) 0,21 0,03	<i>PC(6)</i> 0,06 0,01	<i>PC</i> (7) 0,02 0,00	<i>PC(8)</i> 0,00 0,00

Tabela 28. Componentes principais 1 a 8 (PC1 e PC8) das variáveis estudadas, precedidos de seus respectivos autovalores, variância total e acumulado da variância total (%).

A variância total aponta representatividade e significância dos dados em 77,3% para o período seco e 77,2% para o período chuvoso no acumulado em PC2, indicando a significância das correlações entre o índice IVT, as classes majoritárias do MapBiomas (cinco classes), o Rebanho Efetivo e a Pastagem. Em estudo de Silva et al. (2021), aplicando multivariada por

componentes principais em monitoramento de indicadores do solo e áreas de produção de pastagens, foram encontradas variâncias totais entre 50 e 60%, onde foi possível extrair informações significativas das correlações entre os índices e estabelecer um modelo de regressão múltipla com resultados satisfatórios. Salvati et al. (2015), em avaliação multivariada da paisagem agroflorestal encontrou variância total de 52%, Zeraatpisheh et al. (2019), utilizaram análises estatísticas de covariância e multivariadas em estudo de caso em regiões semiáridas, encontraram uma variância total nos dois primeiros componentes (PCA 1 e PCA 2) que explicaram mais de 42% da variabilidade total.

No período seco (Figura 40) é possível observar uma correlação inversa entre a variável Floresta e as variáveis Pastagem e Agricultura e Pecuária. O ano de 2010 foi o que mais se correlacionou com a variável Floresta e os anos de 2017, 2018, 2019 e 2020 os que mais se correlacionaram com as variáveis Pastagem e Agricultura e Pecuária. A variável IVT manteve uma correlação com as variáveis Formação Natural Não Florestal e Área Não Vegetada, o que se explica pelo fato de o IVT aumentar com o aumento dessas variáveis, e uma correlação inversa com as variáveis de Floresta, Rebanho Efetivo e Corpos d'Água. Os anos de 2013, 2014, 2015 e 2016 estão relacionados as classes de Formação Natural Não Florestal e Área Não Vegetada, e o ano de 2011 foi mais relacionado as variáveis de Rebanho Efetivo e Corpos d'Água, corroborando com os dados obtidos pelo MapBiomas (Figuras 28 e 29) e Análise Temporal do Rebanho Efetivo (Figura 34), bem como as maiores contribuições dos anos 2013 e 2017 pelas classes Formação Natural Não Florestal, Área Não Vegetada e Agricultura e Pecuária.



Figura 40. Análise de Principais Componentes das variáveis de IVT, as classes majoritárias do MapBiomas (cinco classes), o Rebanho Efetivo e Pastagem para o período seco dos anos de 2010 a 2020 na BHRI.

Quando consideramos as correlações entre todas as variáveis (Figura 41), observou-se uma forte correlação entre elas ($R^2 > 0.8$), exceto as variáveis Pastagem e IVT, que apresentaram correlações relativamente baixas ($R^2 < 0.6$).



Figura 41. Correlação dos Principais Componentes das variáveis de IVT, as classes majoritárias do MapBiomas (cinco classes), o Rebanho Efetivo e Pastagem para o período seco dos anos de 2010 a 2020 na BHRI.

Para o período chuvoso (Figura 42), observou-se que a variável Floresta e IVT apresentaram correlações inversas às variáveis Pastagem e Agricultura e Pecuária, a variável Floresta foi representativa no ano de 2011. As variáveis Formação Natural Não Florestal e Área Não Vegetada também mantiveram uma forte correlação entre si e uma correlação inversa as variáveis de Rebanho Efetivo e Corpos d'Água. O ano de 2010 foi mais representativo para as variáveis de Rebanho Efetivo e Corpos d'Água, os anos de 2013 a 2016 para Formação Natural Não Florestal e Área Não Vegetada e os anos de 2017 a 2020 para Pastagem e Agricultura e Pecuária, corroborando com os dados obtidos pelo MapBiomas (Figuras 28 e 29) e Análise Temporal do Rebanho Efetivo (Figura 34).



Figura 42. Análise de Principais Componentes das variáveis de NDVI, IVV, IBVL, IVT, as classes majoritárias do MapBiomas (cinco classes) e o Rebanho Efetivo para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Quando consideramos as correlações entre a maioria das variáveis (Figura 43), observou-se que correlação se manteve elevada ($R^2 > 0.8$), exceto as variáveis de Formação Natural Não Florestal e Pastagem ($0.6 < R^2 < 0.7$) e o IVT que apresentou a menor correlação ($R^2 < 0.5$).



Figura 43. Correlação dos Principais Componentes das variáveis de NDVI, IVV, IBVL, IVT, as classes majoritárias do MapBiomas (cinco classes) e o Rebanho Efetivo para o período chuvoso dos anos de 2010 a 2020 na BHRI.

Diante do contexto apresentado, observa-se que ao longo dos 10 anos que compreendem o período de estudo (2010-2020), as bacias leiteiras de Pernambuco e Alagoas, inseridas na BHRI, apresentaram um forte processo de degradação, com perdas significativas da vegetação nativa do Bioma Caatinga, aumento das áreas de pastagem da vulnerabilidade da terra. Resultados semelhantes foram encontrados por Silva et al. (2020b), que estudaram uma série temporal de 20 anos (1998-2018), afirmaram que o principal fator de degradação do solo e da vegetação nesta região está ligada à expansão da atividade agropecuária, principalmente pela necessidade de expansão das áreas de pastagens para dar suporte à pecuária leiteira na região e Melo et al. (2022) que observou, durante os anos de 2017-2020, a ocorrência da degradação do solo e da vegetação, em parte da região da bacia leiteira do estado de Pernambuco.

3.4. CONCLUSÃO

O uso de sensoriamento remoto e geoprocessamento para a avaliação das variáveis analisadas, em conjunto com o uso de análise multivariada por componentes principais, demonstraram que as informações obtidas foram substancialmente eficientes para responder o objetivo proposto, que foi avaliar a dinâmica espaço-temporal da vulnerabilidade da terra e as áreas de pastagens da área das bacias leiteiras inseridas na BHRI.

Através dos mapas de IVT, somados aos do MapBiomas (LULC), e a quantificação de rebanho efetivo, pastagem e a qualidade das pastagens, nos últimos 10 anos, observou-se que os índice de vulnerabilidade da terra aumentaram entre os anos, apesar de diminuírem entre os períodos seco e chuvoso de cada ano, houve reduções significativas da vegetação nativa do Bioma Caatinga, dos Corpos d'Água e um aumento das áreas de Agricultura e Pecuária e Pastagem, evidenciando a ocorrência de processos de degradação, causados pela influência antrópica no uso da terra e intensificados pelos períodos de seca observados na região.

3.5. REFERÊNCIAS

ABATZOGLOU, J.T.; DOBROWSKI, S.Z.; PARKS, S.A.; et al.. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. Scientific Data. v.5, n.1, p. 1–12. 2018. Disponível em: https://doi.org/10.1038/sdata.2017.191>. Acesso em novembro de 2022.

ALTHOFF, T. D.; MENEZES, R. S. C.; PINTO, A. S.; et al.. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. Agriculture, Ecosystems & Environment. v. 254, p. 26–34. 2018. Disponível em: https://doi.org/10.1016/j.agee.2017.11.016>. Acesso em janeiro de 2023.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**. v. 22, n. 6, p. 711–728, 2013. Disponível em: https://doi.org/10.1127/0941-2948/2013/0507>. Acesso em dezembro de 2021

ANDERSON, E. P.; SUE JACKSON, R. E.; THARME, M. D.; et al.. Understanding Rivers and Their Social Relations: A Critical Step to Advance Environmental Water Management." **WIREs Water.** v.6, n.6. 2019. Disponível em: <https://doi.org/10.1002/wat2.1381>. Acesso em novembro de 2022.

ANDRADE, C. W. L.; MONTENEGRO, S. M. G. L.; MONTENEGRO, A. A. A.; et al.. Climate change impact assessment on water resources underRCPscenarios: A case study in Mundaú River Basin, Northeastern Brazil. **International Journal of Climatology**. v. 41, n. S1. 2020. Disponível em: https://doi.org/10.1002/joc.6751. Acesso em janeiro de 2023.

BARRETO-GARCIA, P. A. B.; BATISTA, S. G. M.; GAMARODRIGUES, E. F.; et al.. Shortterm effects of forest management on soil microbial biomass and activity in caatinga dry forest, Brazil. **Forest Ecology and Management.** v.481, 118790, 2021. Disponível em: http://doi.org/10.1016/j.foreco.2020.118790>. Acesso em janeiro de 2023. BATISTA, P. H. D.; ALMEIDA, G. L. P.; SILVA, J. L. B.; et al.. Short-term grazing and its impacts on soil and pasture degradation. **DYNA**. v. 87, n. 213, p. 123–128. 2020. Disponível em: https://doi.org/10.15446/dyna.v87n213.81853>. Acesso em janeiro de 2023.

BECK, H. E.; ZIMMERMANN, N. E.; MCVICAR, T. R.; *et al.* Present and future Köppen-Geiger climate classification maps at 1-km resolution. **Scientific Data**. v. 5, n. 1. 2018. Disponível em: https://doi.org/10.1038/sdata.2018.214>. Acesso em novembro de 2022.

BEZERRA, A. C.; SILVA, J. L. B.; MOURA, G. B. A.; et al.. Dynamics of Land Cover and Land Use in Pernambuco (Brazil): Spatio-Temporal Variability and Temporal Trends of Biophysical Parameters. **Remote Sensing Applications: Society and Environment**. v.25, article: 100677. 2022. Disponível em: https://doi.org/10.1016/j.rsase.2021.100677. Acesso em novembro de 2022.

BHERING, A. P.; ANTUNES, I. M. H. R.; MARQUES, E. A. G.; *et al.* Geological and hydrogeological review of a semi-arid region with conflicts to water availability (southeastern Brazil). **Environmental Research**. v. 202, article: 111756. 2021. Disponível em: https://doi.org/10.1016/j.envres.2021.111756>. Acesso em novembro de 2022.

BURNEY, J., CESANO, D., RUSSELL, J.; *et al.* Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. **Climatic Change.** v. 126, p. 45–59. 2014. Disponível em: https://doi.org/10.1007/s10584-014-1186-0>. Acesso em novembro de 2022.

CAMPOS, S. A. C.; FERREIRA, M. D. P.; COELHO, A. B.; et al. Degradação ambiental agropecuária no bioma Caatinga. **Revista Econômica do Nordeste**, v. 46, n. 3, p. 155–170, 2015. Disponível em: https://www.bnb.gov.br/revista/index.php/ren/article/view/265/243. Acesso em janeiro de 2023.

CANTALICE, J. R. B.; NUNES, E. O. S.; CAVALCANTE, D. M.; et al. Vegetative-hydraulic parameters generated by agricultural crops for laminar flows under a semi-arid environment of Pernambuco, Brazil. **Ecological Indicators**. v. 106, p. 105496. 2019. Disponível em https://doi.org/10.1016/j.ecolind.2019.105496>. Acesso em janeiro de 2023.

DENG, X.; SONG, C.; LIU, K.; et al.. Remote sensing estimation of catchment-scale reservoir water impoundment in the upper Yellow River and implications for river discharge alteration. **Journal of Hydrology**. v. 585, article: 124791. 2020. Disponível em: https://doi.org/10.1016/j.jhydrol.2020.124791. Acesso em novembro de 2022.

DIAS FILHO, M. B.. **Diagnóstico das pastagens no Brasil.** Embrapa Amazônia Oriental: Belém – PA. 2014. 36 p. ISSN 1983-0513; Documentos: 402). Disponível em: <https://www.infoteca.cnptia.embrapa.br/bitstream/doc/986147/1/DOC402.pdf>. Acesso em janeiro de 2023.

EMBRAPA – Empresa Brasileira De Pesquisa Agropecuária. **Sistema Brasileiro de Classificação de Solos**. 2^a ed. Brasília – DF, 2006. 286p. Disponível em: <https://www.agrolink.com.br/downloads/sistema-brasileiro-de-classificacao-dossolos2006.pdf>. Acesso em novembro de 2022.

FAO – Food and Agriculture Organization of the United Nations. **The State of Food and Agriculture: Livestock in the balance**. Italy: Rome. 2009. Disponível em: https://www.fao.org/3/i0680e/i0680e.pdf>. Acesso em janeiro de 2023.

FERNANDES, M. M.; FERNANDES, M. R. M.; GARCIA, J. R.; *et al.* Land use and land cover changes and carbon stock valuation in the São Francisco river basin, Brazil. **Environmental Challenges**. v. 5, article: 100247. 2021. Disponível em: https://doi.org/10.1016/j.envc.2021.100247>. Acesso em novembro de 2022.

GIBBS, H. K.; SALMON, J. M. Mapping the world's degraded lands. Applied Geography.
v. 57, p. 12–21. 2015. Disponível em: https://doi.org/10.1016/j.apgeog.2014.11.024>.
Acesso em janeiro de 2023.

GOMES, M. G.; VARGAS, T.; BELLADONA, R.; et al.. Aplicação do Interpolador IDW para elaboração de Mapas Hidrogeológicos Paramétricos na Região da Serra Gaúcha. **Scientia Cum Industria**. v.6, p. 38–43. 2018. Disponível em: http://dx.doi.org/10.18226/23185279.v6iss3p38>. Acesso em novembro de 2022. GUERRA, A.; REIS, L. K.; BORGES, F. L. G.; *et al.* Ecological restoration in Brazilian biomes: Identifying advances and gaps. **Forest Ecology and Management**. v. 458, p. 117802. 2020. Disponível em: https://doi.org/10.1016/j.foreco.2019.117802>. Acesso em novembro de 2022.

HOPKINS, W.G. **A new view of statistics: Correlation coefficient**. 2009. Disponível em: http://www.sportsci.org/resource/stats/correl.html>. Acesso em novembro de 2022.

HOSSAIN, A.; KRUPNIK, T. J.; TIMSINA, J.; et al.. Agricultural Land Degradation: Processes and Problems Undermining Future Food Security. **Environment, Climate, Plant and Vegetation Growth**. p. 17–61. 2020. Disponível em: https://doi.org/10.1007/978-3-030-49732-3_2. Acesso em janeiro de 2023.

HUANG, J. et al. Global semi-arid climate change over last 60 years. **Climate Dynamics**, v. 46, n. 3-4, p. 1131–1150, 13 maio 2015. Disponível em: https://doi.org/10.1007/s00382-015-2636-8>. Acesso em janeiro de 2023.

HUANG, Z.; LIU, X.; SUN, S.; *et al.* Global assessment of future sectoral water scarcity under adaptive inner-basin water allocation measures. **Science of The Total Environment**. v. 783, article: 146973. 2021. Disponível em: https://doi.org/10.1016/j.scitotenv.2021.146973. Acesso em novembro de 2022.

IBGE – Instituto Brasileiro de Geografia e Estatística. Panorama Brasil [online]. 2021.Disponível em: https://cidades.ibge.gov.br/brasil/panorama>. Acesso em janeiro de 2023.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo Agro 2017**. 2021. Disponível em: https://censos.ibge.gov.br/agro/2017/templates/censo_agro/resultadosagro/pecuaria.html?loc alidade=0&tema=75657>. Acesso em novembro de 2022.

INMET. Instituto Nacional de Meteorologia. **Dados Históricos Anuais**. 2021. Disponível em: https://portal.inmet.gov.br/dadoshistoricos. Acesso em novembro de 2022.

INMET. Instituto Nacional de Meteorologia. **Normais Climatológicas Do Brasil**. 2010. Disponível em: https://portal.inmet.gov.br/normais. Acesso em novembro de 2022.

IPCC. **The Intergovernmental Panel on Climate Change**. 2021. Disponível em: https://www.ipcc.ch/. Acesso em novembro de 2022.

IPCC. **The Intergovernmental Panel on Climate Change**. 2021. Disponível em: https://www.ipcc.ch/. Acesso em novembro de 2022.

KAISER, H. F. The varimax criterion for analytic rotation in factor analysis. **Psychometrika**, v. 23, n. 3, p. 187–200. 1958. Disponível em: https://doi.org/10.1007/BF02289233. Acesso em janeiro de 2023.

KIM, D.; LEE, H.; JUNG, H. C.; et al.. Monitoring river basin development and variation in water resources in transboundary Imjin River in North and South Korea using remote sensing. **Remote** Sensing. v.12, article: 195. 2020. Disponível em: https://doi.org/10.3390/rs12010195>. Acesso em novembro de 2022.

LAPIG/UFG. Laboratório de Processamento de Imagens e Geoprocessamento da Universidade Federal de Goiás. **Áreas de Pastagem.** 2023. Disponível em: < https://atlasdaspastagens.ufg.br/assets/hotsite/documents/metodos/pt/%C3%81rea%20de%20 Pastagem.pdf>. Acesso em janeiro de 2023.

LOPES, I. C. P. ; CAMPOS, J. A.. Capacidade de uso da terra da sub-bacia do Córrego Maria Comprida usando Sistemas de Informações Geográficas. **Journal of Environmental Analysis and Progress**. p. 110–121, 2019. Disponível em: <https://doi.org/10.24221/jeap.4.2.2019.2358.110-121>. Acesso em novembro de 2022.

MAIA, A. G.; Silveira, R. L. F.; Fonseca, C. V. C.; et al.. Climate resilience programmes and technical efficiency: evidence from the smallholder dairy farmers in the Brazilian semi-arid region. **Climate and Development**. v. 14, n. 3, p. 197-207. 2022. Disponível em: https://doi.org/10.1080/17565529.2021.1904812>. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Análise de Acurácia**. 2023. Disponível em: https://mapbiomas.org/analise-de-acuracia. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Pastagens Brasileiras Ocupam Área Equivalente a todo o Estado do Amazonas**. 2023. Disponível em: https://mapbiomas.org/pastagens-brasileiras-ocupam-area-equivalente-a-todo-o-estado-do-amazonas. Acesso em janeiro de 2023.

MAPBIOMAS BRASIL. **Plataforma de Mapas e Dados**. 2021. Disponível em: http://plataforma.mapbiomas.org/map>. Acesso em novembro de 2022.

MARANHÃO, S. R.; SILVA, R. G.; ARAÚJO, G. G. L.; et al.. Modeling the water balance of a ruminant production system in the semi-arid region. **African Journal of Agricultural Research**. v. 18, n. 2, p. 127–135. 2022. Disponível em: https://doi.org/10.5897/AJAR2021.15675>. Acesso em janeiro de 2023.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; *et al.* Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**. v. 90, n. 2 suppl 1, p. 1973–1985. 2018. Disponível em: https://doi.org/10.1590/0001-3765201720170206>. Acesso em novembro de 2022.

MARENGO, J. A.; GALDOS, M. V.; CHALLINOR, A.; *et al.* Drought in Northeast Brazil: A review of agricultural and policy adaptation options for food security. **Climate Resilience and Sustainability.** v. 1, n. 1. 2021. Disponível em: https://doi.org/10.1002/cli2.17>. Acesso em: novembro de 2022.

MCFEETERS, S. K.. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**. v.17:7, p. 1425-1432. 1996. Disponível em: https://doi.org/10.1080/01431169608948714>. Acesso em novembro de 2022.

MEDEIROS, A. S.; MAIA, S. M. F.; SANTOS, T. C.; et al.. Soil carbon losses in conventional farming systems due to land-use change in the Brazilian semi-arid region. Agriculture, Ecosystems & Environment. v. 287, p. 106690. 2020. Disponível em: https://doi.org/10.1016/j.agee.2019.106690>. Acesso em janeiro de 2023.

MEDEIROS, S. S. Estabelecimentos Agropecuários do Semiárido Brasileiro. 1º. ed. Campina Grande: Instituto Nacional do Semiárido, 2018, 149 p. MELO, M. V. N.; OLIVEIRA, M. E. G.; ALMEIDA, G. L. P.; et al. Spatiotemporal characterization of land cover and degradation in the agreste region of Pernambuco, Brazil, using cloud geoprocessing on Google Earth Engine. **Remote Sensing Applications: Society and Environment**. v. 26, p. 100756. 2022. Disponível em: https://doi.org/10.1016/j.rsase.2022.100756>. Acesso em janeiro de 2023.

NAOREM, A.; JAYARAMAN, S.; DANG, Y. P.; et al.. Soil Constraints in an Arid Environment—Challenges, Prospects, and Implications. **Agronomy**. v. 13, n. 1, p. 220. 2023. Disponível em: https://doi.org/10.3390/agronomy13010220>. Acesso em fevereiro de 2023.

OLIVEIRA, M. L.; SANTOS, C. A. C.; OLIVEIRA, G.; et al.. Effects of human-induced land degradation on water and carbon fluxes in two different Brazilian dryland soil covers. **Science of The Total Environment**. v. 792, p. 148458. 2021.

OLIVEIRA-JÚNIOR, J. F.; SILVA JUNIOR, C. A.; TEODORO, P. E.; et al.. Confronting CHIRPS dataset and in situ stations in the detection of wet and drought conditions in the Brazilian Midwest. **International Journal of Climatology**. v. 41 (9), p. 4478–4493. 2021. Disponível em: https://doi.org/10.1002/joc.7080. Acesso em novembro de 2022.

PEREIRA, A. P.; LIMA, L. A. L.; BEZERRA, W. M.; *et al.* Grazing exclusion regulates bacterial community in highly degraded semiarid soils from the Brazilian Caatinga biome. **Land Degradation & Development**. v. 32, n. 6, p. 2210–2225. 2021. Disponível em: https://doi.org/10.1002/ldr.3893. Acesso em novembro de 2022.

PEREIRA, P.; BOGUNOVIC, I.. Land degradation neutrality. How to reverse land degradation with conservation agriculture practices?. Proceedings of the **12th International Scientific/Professional Conference Agriculture in Nature and Environment Protection**, Osijek, Croatia, 27–29. 2019. Disponível em: https://www.bib.irb.hr/1003912/download/1003912.Pereira_Bogunovic_LDN_Osijek_Final.pdf>. Acesso em janeiro de 2023.

QGIS – Quantum Geographic Information System. **QGIS Training Manual**. 2022. Disponível em: https://docs.qgis.org/3.16/en/docs/training_manual/. Acesso em janeiro de 2023.

QUEIROZ, M. G., SILVA, T. G. F.; ZOLNIER, S.; et al.. Spatial and temporal dynamics of soil moisture for surfaces with a change in land use in the semi-arid region of Brazil. **CATENA**. v. 188, p. 104457. 2020. Disponível em https://doi.org/10.1016/j.catena.2020.104457. Acesso em janeiro de 2023.

SALVATI, L.; MAVRAKIS, A.; COLANTONI, A.; et al.. Complex Adaptive Systems, soil degradation and land sensitivity to desertification: A multivariate assessment of Italian agro-forest landscape. **Science of The Total Environment**. v. 521-522, p. 235–245. 2015. Disponível em: https://doi.org/10.1016/j.scitotenv.2015.03.094>. Acesso em janeiro de 2023.

SALVATIERRA, L. H. A.; LADLE, R. J.; BARBOSA, H.; *et al.* Protected areas buffer the Brazilian semi-arid biome from climate change. **Biotropica**. v. 49, n. 5, p. 753–760. 2017. Disponível em: https://doi.org/10.1111/btp.12459>. Acesso em novembro de 2022.

SANTOS, A.; LOPES, P. M. O.; SILVA, M. V.; et al.. Causes and consequences of Seasonal changes in the water flow of the São Francisco river in the semiarid of Brazil. **Environmental and Sustainability Indicators**. v. 8, 1–15. 2020. Disponível em: https://doi.org/10.1016/j.indic.2020.100084>. Acesso em novembro de 2022.

SANTOS, A.; LOPES, P. M. O.; SILVA, M. V.; *et al.* Causes and consequences of seasonal changes in the water flow of the São Francisco river in the semiarid of Brazil. **Environmental and Sustainability Indicators**. v. 8, article: 100084. 2020. Disponível em: https://doi.org/10.1016/j.indic.2020.100084>. Acesso em novembro de 2022.

SEDDON, A. W. R.; MACIAS-FAURIA, M.; LONG, P. R.; et al.. Sensitivity of global terrestrial ecosystems to climate variability. **Nature**. v. 531, n. 7593, p. 229–232, 2016. Disponível em: https://doi:10.1038/nature16986>. Acesso em novembro de 2022.

SILVA, C. M.; COSTA JÚNIOR, C. E. O..²²⁸Ra in cow's milk from an anomalous region of Pernambuco-Brazil. **International Journal of Environmental Studies**. 1–13. 2019. Disponível em: https://doi.org/10.1080/00207233.2019.1579581. Acesso em janeiro de 2023.

SILVA, J. L. B.; MOURA, G. B. A.; SILVA, M. V.; et al.. Environmental degradation of vegetation cover and water bodies in the semiarid region of the Brazilian Northeast via cloud geoprocessing techniques applied to orbital data. Journal of South American Earth Sciences.
v. 121, p. 104164. 2023. Disponível em: https://doi.org/10.1016/j.jsames.2022.104164>.
Acesso em janeiro de 2023.

SILVA, J. L. B.; MOURA, G. B. A.; SILVA, M. V.; et al.. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**. v. 20, article: 100372. 2020a. Disponível em: https://doi.org/10.1016/j.rsase.2020.100372>. Acesso em novembro de 2022.

SILVA, J. L. B.; REFATI, D. C.; LIMA, R. C. C.; et al.. Techniques of Geoprocessing via Cloud in Google Earth Engine Applied to Vegetation Cover and Land Use and Occupation in the Brazilian Semiarid Region. **Geographies**. v. 2, n. 4, p. 593–608. 2022. Disponível em: https://doi.org/10.3390/geographies2040036>. Acesso em janeiro de 2023.

SILVA, M. V.; PANDORFI, H.; ALMEIDA, G. L. P.; et al.. Spatio-temporal monitoring of soil and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semiarid region. Journal of South American Earth Sciences. v. 107, article: 103155. 2021. Disponível em: https://doi.org/10.1016/j.jsames.2021.103155. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; LOPES, P. M. O.; et al.. Pilot monitoring of caatinga spatialtemporal dynamics through the action of agriculture and livestock in the brazilian semiarid. *Remote Sensing Applications: Society and Environment.* v. 19, article: 100353, 2020b. Disponível em: https://doi.org/10.1016/j.rsase.2020.100353>. Acesso em novembro de 2022.

SILVA, M. V.; PANDORFI, H.; OLIVEIRA-JÚNIOR, J. F.; et al.. Remote Sensing Techniques via Google Earth Engine for Land Degradation Assessment in the Brazilian Semiarid Region, Brazil. Journal of South American Earth Sciences. v.120, article: 104061. 2022. Disponível em: https://doi.org/10.1016/j.jsames.2022.104061. Acesso em novembro de 2022.

SO, H. B.; KHALIFA, A. M.; YU, B.; et al. MINErosion 3: Using measurements on a tilting flume-rainfall simulator facility to predict erosion rates from post-mining landscapes in Central Queensland, Australia. **PLOS ONE**. v. 13, n. 3, p. e0194230. 2018. Disponível em: https://doi.org/10.1371/journal.pone.0194230>. Acesso em janeiro de 2023.

STAVI, I.; PINHO, J. R.; PASCHALIDOU, A. K.; et al.. Food security among dryland pastoralists and agropastoralists: The climate, land-use change, and population dynamics nexus.
The Anthropocene Review. 9(3), 299–323. 2021. Disponível em: https://doi.org/10.1177/20530196211007512>. Acesso em janeiro de 2023.

TEIXEIRA, D. B.; VELOSO, M. F.; FERREIRA, F. L. V.; et al.. Spectro-temporal analysis of the Paraopeba River water after the tailings dam burst of the Córrego do Feijão mine, in Brumadinho, Brazil. **Environmental Monitoring and Assessment**. v.193, p. 435. 2021. Disponível em: https://doi.org/10.1007/s10661-021-09218-4. Acesso em novembro de 2022.

TOLCHE, A. D.; GURARA, M. A.; PHAM, Q. B.; et al.. Modelling and accessing land degradation vulnerability using remote sensing techniques and the analytical hierarchy process approach. **Geocarto International**. 37:24, 7122-7142. 2021. Disponível em: https://doi.org/10.1080/10106049.2021.1959656>.

USGS/NASA. United States Geological Survey/National Aeronautics and Space Landsat Satellite Missions. 2022. Administration. Disponível em: https://www.usgs.gov/landsat-missions/landsat-satellite-missions. Acesso em novembro de 2022.

VIEIRA, R. M. D. S. P.; TOMASELLA, J.; BARBOSA, A. A.; et al.. Desertification risk assessment in Northeast Brazil: Current trends and future scenarios. Land Degradation & Development. v. 32, n. 1, p. 224–240. 2020. Disponível em: https://doi.org/10.1002/ldr.3681>. Acesso em janeiro de 2023.

WARRICK, A. W.; NIELSEN, D. R.. Spatial variability of soil physical properties in the field. In: HILLEL, D. (Ed.). **Applications of Soil Physics**. New York: Academic, v.2, p. 319-344. 1980. WASHINGTON, B.; SEYMOUR, L.; MOTE, T.; et al.. Identifying and extracting a seasonal streamflow signal from remotely sensed snow cover in the Columbia River Basin. **Remote Sensing Applications: Society and Environment**. v. 14, p. 207–223. 2019. Disponível em: https://doi.org/10.1016/j.rsase.2018.03.003>. Acesso em novembro de 2022.

XU, H.. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**. v. 27, p. 3025-3033. 2006. Disponível em: https://doi.org/10.1080/01431160600589179>. Acesso em novembro de 2022.

ZERAATPISHEH, M., AYOUBI, S., SULIEMAN, M.; et al.. Determining the spatial distribution of soil properties using the environmental covariates and multivariate statistical analysis: a case study in semi-arid regions of Iran. **Journal of Arid Land**. v. 11, n. 4, p. 551–566. 2019. Disponível em: https://doi.org/10.1007/s40333-019-0059-9>. Acesso em Janeiro de 2023.

ZHOU, N.; HU, X.; BYSKOV, I; et al.. Overview of recent land cover changes, forest harvest areas, and soil erosion trends in Nordic countries. **Geography and Sustainability**. v. 2, n. 3, p. 163–174. 2021. Disponível em: https://doi.org/10.1016/j.geosus.2021.07.001. Acesso em janeiro de 2023.

CONSIDERAÇÕES FINAIS

O uso de sensoriamento remoto e geoprocessamento, na avaliação dos índices e variáveis analisadas, demonstrou que as informações obtidas foram substancialmente eficientes para responder o objetivo proposto nesse trabalho. Somando-se a isso, o processamento automático de imagens em nuvem, através do Google Earth Engine (GEE), proporcionou a otimização do tempo e minimização de erros de processamento.

Nos últimos dez anos (2010-2020) a vulnerabilidade da terra aumentou. O estudo identificou mudanças nas condições de uso do solo na Caatinga, levando à perda da cobertura vegetal e dos corpos d'água. A variabilidade das chuvas, devido a baixos totais anuais, também impactou diretamente a dinâmica e a resiliência da vegetação, dos corpos hídricos, na disponibilidade hídrica da bacia, e na pecuária leiteira da área, evidenciando os efeitos severos da estiagem e comprovando a ocorrência de processos de degradação, causados pela influência antrópica no uso da terra e intensificados pelos períodos de seca observados na região.

A metodologia utilizada, embora tenha apresentado algumas limitações, permitiu coletar informações importantes para o diagnóstico e a modelagem espaço-temporal da vulnerabilidade da terra e suas inferências nas bacias leiteiras dos Estados de Pernambuco e Alagoas, inseridos na Bacia Hidrográfica do Rio Ipanema, podendo ser aplicada em futuros estudos em outras regiões de Caatinga. Ressalta-se, no entanto, que a divisão do estudo entre período seco e chuvoso apresentou limitações em relação a incidência de nuvens nas imagens de satélite.

Por fim, o presente trabalho mostrou a importância do monitoramento da vulnerabilidade da terra e suas inferências, auxiliando na construção de um arcabouço com embasamento técnico e científico no planejamento e estabelecimento de técnicas de manejo conservacionista para a atividade agropecuária, como implantação os sistemas agroflorestais com animais, o manejo agroecológico de pastagens, agricultura de conservação e a integração lavoura-pecuária-floresta e na utilização dos recursos naturais de forma sustentável nas bacias leiteiras dos Estados de Pernambuco e Alagoas inseridas na Bacia Hidrográfica do Rio Ipanema e em toda região semiárida, proporcionando cenários futuros menos pessimistas.