

**ANDERSON DOS SANTOS**

**MUDANÇAS AMBIENTAIS E HIDROMETEOROLÓGICAS NA BACIA  
HIDROGRÁFICA DO RIO SÃO FRANCISCO, SEMIÁRIDO DO BRASIL**

**RECIFE-PE  
2023**

ANDERSON DOS SANTOS

**MUDANÇAS AMBIENTAIS E HIDROMETEOROLÓGICAS NA BACIA  
HIDROGRÁFICA DO RIO SÃO FRANCISCO, SEMIÁRIDO DO BRASIL**

Tese de doutorado apresentada à  
Universidade Federal Rural de  
Pernambuco, como parte das exigências do  
Programa de Pós-Graduação em  
Engenharia Agrícola.

Orientador: Prof. Dr. Geber Barbosa de  
Albuquerque Moura

Coorientador: Prof. Dr. Fabrício Marcos  
Oliveira Lopes

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)

---

S237m Santos, Anderson dos  
MUDANÇAS AMBIENTAIS E HIDROMETEOROLÓGICAS NA BACIA HIDROGRÁFICA DO RIO SÃO FRANCISCO, SEMLÁRIO DO BRASIL / Anderson dos Santos. - 2023.  
146 f. : il.

Orientador: Geber Barbosa de Albuquerque Moura.  
Coorientador: Pabrcio Marcos Oliveira Lopes.  
Inclui referências.

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

1. Caatinga. 2. Resiliência da vegetação. 3. Mudanças climáticas. 4. Índice de seca. 5. Uso e cobertura da terra. I. Moura, Geber Barbosa de Albuquerque, orient. II. Lopes, Pabrcio Marcos Oliveira, coorient. III. Título

CDD 630

---

**ANDERSON DOS SANTOS**

**MUDANÇAS AMBIENTAIS E HIDROMETEOROLÓGICAS NA BACIA  
HIDROGRÁFICA DO RIO SÃO FRANCISCO, SEMIÁRIDO DO BRASIL**

Tese defendida e aprovada em 11 de julho de 2023 pela Banca Examinadora:

Orientador:

---

Prof. Dr. Geber Barbosa de Albuquerque Moura  
Universidade Federal Rural de Pernambuco – UFRPE

Examinadores:

---

Prof. Dr. Ênio Farias de França e Silva  
Universidade Federal Rural de Pernambuco – UFRPE

---

Prof. Dr. Humberto Barbosa  
Universidade Federal de Alagoas – UFAL

---

Prof. Dr<sup>a</sup>. Nadjacleia Vilar Almeida  
Universidade Federal da Paraíba – UFPB

---

Prof. Dr. Ranyére Silva Nóbrega  
Universidade Federal de Pernambuco – UFPE

Aos meus pais, Cícero Bispo dos Santos e Maria de Lourdes dos Santos, as minhas irmãs Maria Telma dos Santos e Tatiane Aparecida dos Santos, ao meu padrinho Ginaldo de Souza Santos, aos meus sobrinhos e toda minha família, pelos incentivos e dedicações, por fazerem parte da minha vida, acreditando sempre no meu potencial e pelo apoio incondicional no fortalecimento das minhas decisões.

**DEDICO!**

## AGRADECIMENTOS

À Deus, por sempre me dar forças, sabedoria e perseverança para lutar por aquilo que acredito, mesmo nesses tempos ruins e por me guiar ao longo desta etapa tão almejada.

À Universidade Federal Rural de Pernambuco (UFRPE) e ao Programa de Pós-Graduação em Engenharia Agrícola (PGEA) pela oportunidade de execução deste curso, proporcionando aprendizados que levarei para o restante de minha vida pessoal e profissional.

À Coordenação de Aperfeiçoamento Pessoal de Nível Superior (CAPES) pela concessão da bolsa de estudo.

Ao meu orientador Prof. Dr. Geber Barbosa de Albuquerque Moura e ao meu coorientador Prof. Dr. Fabrício Marcos Oliveira Lopes, os quais tenho muita admiração, agradeço pela oportunidade de orientação, por terem acreditado em mim, pela convivência harmoniosa e sincera, paciência, conselhos, incentivo e ensinamentos enriquecedores transmitidos, que ajudaram muito no meu crescimento profissional e pessoal ao longo dessa jornada.

Aos amigos e colegas de turmas do PGEA que durante toda essa jornada passaram junto a mim, com determinação, perseverança e alegrias. Nesta mesma linha, estendo minha gratidão em especial a Alexandre Jardim, Gabriel Tavares, Marcos Vinícius, José Ediclécio, Jesiele Divincula, Geraldo Cangela, Kenny Montalvo, Jhon Lennon e Douglas Alberto, pelo companheirismo e conhecimentos partilhados, por trazerem iluminação, esperança e projeção em meio ao caos, saibam que vocês foram verdadeiros companheiros e peças essenciais nessa jornada, tornando-a mais leve e satisfatória.

Aos professores do PGEA por me ensinarem tanto, dentro e fora da sala de aula. E também aos funcionários administrativos que fazem parte da UFRPE.

Aos amigos e colegas das Expedições Científicas do São Francisco foi uma satisfação compartilhar conhecimentos científicos e perspectivas de vida com vocês e, juntos vivenciar toda a riqueza e exuberância do Velho Chico, mas também os problemas que afetam as “Águas e Mágoas do Rio São Francisco”. Os conhecimentos adquiridos com essa experiência foram fonte de inspiração e fundamentais na construção deste trabalho.

À comissão examinadora pela disponibilidade e relevantes contribuições durante todas as fases de execução deste trabalho.

Ao Prof. Dr. José Vieira Silva, por me inserir na vida acadêmica, o qual me ensinou a sempre superar meus limites e nunca desistir dos meus objetivos, sendo exemplo e inspiração

na minha vida. E também a Dr<sup>a</sup>. Roberta Samara Nunes de Lima, pelos conselhos, ensinamentos, ajuda e incentivo.

À Nádia Dariely e toda sua família por todo o carinho, apoio e incentivo, por estar sempre disposta a me ouvir nos bons e maus momentos, obrigado por sua amizade.

Enfim, o meu muito obrigado a todos aqueles que de alguma forma fizeram parte dessa vitória!

**Muito grato!**

*“Muitos medos vão tentar te segurar, muitas vozes vão dizer que não vai dar. Sempre persista não importa o que vão dizer, só nunca desista do sonho que existe em você.”*

(Rosa de Saron)

*“Às vezes, é melhor não ver todo o caminho que se estende diante de você. Deixe a vida surpreendê-lo. Há mais estrelas por aí do que as que já têm nome. E todas são lindas.”*

(Clace Vanderpool)



Santos, A. dos. **Mudanças ambientais e hidrometeorológicas na Bacia Hidrográfica do rio São Francisco, semiárido do Brasil**. 2023. 146f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal Rural de Pernambuco, Recife, Pernambuco, Brasil.

## RESUMO

No Brasil, a Bacia Hidrográfica do Rio São Francisco (BHSF) tem importância estratégica nacional devido ao seu potencial para agricultura, geração de energia, abastecimento de água urbano e industrial e turismo. No entanto, a BHSF tem enfrentado sérios problemas hídricos, degradação do solo e perda da biodiversidade, devido aos conflitos dos usos múltiplos da água e do uso da terra e problemas sistemáticos de seca nos últimos anos, levando a graves ameaças à segurança hídrica, alimentar e ambiental. Deste modo, objetivou-se avaliar as causas e consequências das mudanças ambientais e hidrometeorológicas na bacia hidrográfica do Submédio São Francisco, localizada no semiárido brasileiro. Para o desenvolvimento da pesquisa foram implementados dados hidrometeorológicos (precipitação pluviométrica, temperatura do ar e vazão) e dados geoespaciais de diferentes satélites/sensores (Landsat, MODIS, CHIRPS) junto com a aplicabilidade de softwares e scripts de processamento digital de imagens orbitais responsáveis por realizar estimativas dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) e índices de seca (SPI e SSI). Os padrões de distribuição e variabilidade espaço-temporal dos dados hidrometeorológicos, parâmetros biofísicos e uso e cobertura da terra foram avaliados por métodos analíticos estatísticos, incluindo o teste de tendência de Kendall, a análise de tendência mediana de Theisen, estatística descritiva, multivariada, correlação e regressão. Os resultados da análise de tendência mostram que as quantidades de chuva na BHSF não mudaram significativamente no período de 1991-2020, mas a temperatura média para a estação NDJ aumentou 0,57 °C e a vazão média anual reduziu 935 m<sup>3</sup> s<sup>-1</sup> no mesmo período. Em geral, os eventos de seca mostraram tendências crescentes em termos de duração, frequência e intensidade durante o período de 1991-2020, sobretudo entre os anos de 2012-2018, condições que comprometeram a resiliência da vegetação na BHSF, culminando em reduções dos valores médio do NDVI, LAI, NDMI em 15,75%, 8,66% e 28,56%, respectivamente, e aumento de 1,593 °C na LST. Vale destacar que, a análise das mudanças no uso e cobertura da terra detectou uma redução das áreas de Caatinga densa em 2,92%, como decorrência principalmente da conversão de vegetação nativa densa em áreas pastagem, Caatinga herbácea e agricultura, e uma redução de 15,19% das áreas de corpos hídricos, que evidenciou a potencialidade dos efeitos severos da seca na BHSF. Além disso, as modificações na distribuição regional da vegetação influenciaram na variabilidade da precipitação anual, com volume de chuvas 8% maior nas áreas de Caatinga densa em relação as áreas não vegetadas e com vegetação herbácea. Por fim, os menores valores de NDVI, LAI e NDMI e maiores valores de LST foram verificados sobre manchas de Planossolos, Luvissolos e Vertissolos em áreas não vegetadas e com formação vegetal não florestal, que apresentaram baixa resiliência da cobertura vegetal. Conclui-se que as mudanças na variabilidade espaço-temporal da precipitação causaram mudanças drásticas na resiliência da vegetação e nos corpos hídricos. Além disso, a tendência de aumento da frequência e intensidade dos eventos de seca, pode levar a um maior declínio da cobertura vegetal e possivelmente a uma mudança na composição das espécies vegetais que compõem a flora local, bem como aumento dos processos de degradação do solo e problemas de abastecimento hídrico, afetando os múltiplos usos da água na BHSF.

**Palavras-chave:** Caatinga, resiliência da vegetação, mudanças climáticas, índice de seca, degradação do solo, uso e cobertura da terra.

Santos, A. dos. **Environmental and hydrometeorological changes in the São Francisco River Basin, semi-arid region of Brazil**. 2023. 146f. Thesis (Ph.D. in Agricultural Engineering) – Federal Rural University of Pernambuco, Recife, Pernambuco, Brazil.

### ABSTRACT

In Brazil, the São Francisco River Basin (BSHF) has national strategic importance due to its potential for agriculture, power generation, urban and industrial water supply and tourism. However, BSHF has been facing serious water problems, soil degradation and loss of biodiversity, due to multiple conflicts over water and land use and systematic drought problems in recent years, leading to serious threats to water, food and environmental security. Thus, the objective was to evaluate the causes and consequences of environmental and hydrometeorological changes in the Lower-Middle São Francisco basin, in the Brazilian semi-arid region. For the development of the research, hydrometeorological data (rainfall, air temperature and flow) and geospatial data from different satellites/sensors (Landsat, MODIS, CHIRPS) were implemented together with the applicability of software and scripts for digital processing of orbital images responsible for estimate biophysical parameters (NDVI, LAI, NDMI and LST) and drought indexes (SPI and SSI). The patterns of distribution and spatiotemporal variability of hydrometeorological data, biophysical parameters, and land use and land cover were evaluated by statistical analytical methods, including Kendall's trend test, Theisen's median trend analysis, descriptive statistics, multivariate, of correlation and regression. Trend analysis results show that rainfall amounts in the BSHF did not change significantly over the period 1991-2020, but the average temperature for the NDJ station increased by 0.57 °C and the average annual discharge decreased by 935 m<sup>3</sup> s<sup>-1</sup> in the same period. In general, drought events showed increasing trends in terms of duration, frequency and intensity during the period 1991-2020, mainly between the years 2012-2018, conditions that compromised the resilience of vegetation in the BSHF, culminating in reductions in average values of NDVI, LAI, NDMI by 15.75%, 8.66% and 28.56%, respectively, and an increase of 1.593 °C in LST. It is worth mentioning that the analysis of changes in land use and land cover detected a reduction of areas of dense Caatinga by 2.92%, mainly due to the conversion of dense native vegetation into pasture, herbaceous Caatinga and agriculture, and a reduction of 15.19% of the areas of water bodies, which showed the potential of the severe effects of drought on the BSHF. In addition, changes in the regional distribution of vegetation influenced the variability of annual precipitation, with rainfall 8% higher in areas of dense Caatinga compared to non-vegetated areas and areas with herbaceous vegetation. Finally, the lowest values of NDVI, LAI and NDMI and the highest values of LST were verified on patches of Planosols, Luvisols and Vertisols in non-vegetated areas and with non-forest vegetation formation, which showed low resilience of the vegetation cover. It is concluded that changes in the space-time variability of precipitation caused drastic changes in the resilience of vegetation and water bodies. In addition, the trend towards an increase in the frequency and intensity of drought events may lead to a greater decline in vegetation cover and possibly a change in the composition of plant species that make up the local flora, as well as an increase in soil degradation processes and water supply problems, affecting the multiple uses of water in BSHF.

**Keywords:** Caatinga, vegetation resilience, climate change, drought index, soil degradation, land use and land cover.

## LISTA DE FIGURAS

- Figura 1** - Localização da bacia hidrográfica do rio São Francisco no Brasil, suas sub-bacias, bioma de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE - <https://ibge.gov.br>), e altitudes. ....24
- Figura 2** - Localização do bioma Caatinga no Brasil e sua dimensão em relação ao semiárido brasileiro. ....27
- Figura 3** - Localização da bacia do Rio São Francisco no Brasil, suas sub-bacias, e o Bioma Caatinga de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE - <https://ibge.gov.br>), juntamente com a Usina Hidrelétrica (UHE) de Sobradinho. E o mapa hipsométrico, com as estações meteorológicas e fluviométricas utilizadas no presente estudo. ....46
- Figura 4** - Grade CHIRPS da área de estudo incluindo a os municípios do vale do Submédio São Francisco.....49
- Figura 5** - Funcionamento da redução da coleção de imagens em uma única imagem.....51
- Figura 6** - Observações de precipitação terrestres e estimativas de precipitação baseadas em CHIRPS para o período 1991-2020. A linha azul indica a correspondência 1:1 e a linha vermelha tracejada fornece o melhor ajuste da regressão linear. ....67
- Figura 7** - Métricas estatísticas de desempenho agrupadas por categorias de precipitação pluviométrica para contraste das observações de precipitação nos pluviômetros das estações meteorológicas e estimativas de precipitação baseadas no produto CHIRPS. A linha azul tracejada indica a pontuação perfeita para cada métrica. ....69
- Figura 8** - Métricas estatísticas de desempenho agrupadas por mês para contraste das observações de chuva observadas nos pluviômetros das estações meteorológicas e estimativas de chuva baseadas no produto CHIRPS. A linha azul tracejada indica a pontuação perfeita para cada métrica.....70
- Figura 9** - Avaliação da variabilidade interanual da precipitação pluviométrica (a), temperatura média do ar (b) e vazão média, com a identificação dos respectivos anos com outliers, de 2001 a 2020. ....72
- Figura 10** - Precipitação total para a região em estudo da BHSF durante o período de 1991–2020, com base no conjunto de dados CHIRPS. (a) A estação chuvosa de NDJ (novembro, dezembro e janeiro), (b) a estação chuvosa de FMA (fevereiro, março e abril) e (c) o ano hidrológico (novembro-outubro). As linhas de tendência linear (pretas) são baseadas na inclinação de Sen. Insignificativa em  $\alpha = 0,05$  para o ano hidrológico e a estação chuvosa de

FMA e, significativa para a estação chuvosa de NDJ. As linhas laranjas representam as médias climatológicas.....	74
<b>Figura 11</b> - Temperatura média do ar para a estação NDJ na região em estudo da BHSF durante o período de 1991–2020. A linha de tendência linear (preta) é baseada na inclinação de Sen, significativa em $\alpha = 0,05$ . A linha laranja representa a média climatológica.....	76
<b>Figura 12</b> - Vazão média anual do rio São Francisco na sua sub-região durante o período de 1991–2020 com base nos dados médios mensais das estações fluviométricas da ANA. Tendência linear (preto) com base na inclinação de Sen. Significativa em $\alpha = 0,05$ .....	77
<b>Figura 13</b> - Valores SSI-3 e SPI-3 (a) e SSI-12 e SPI-12 (b) de 1991–2020. Azul indica condições relativamente úmidas, enquanto vermelho indica condições relativamente secas no período de tempo antecedente indicado (3 ou 12 meses). .....	80
<b>Figura 14</b> - Séries interanuais compostas por valores médios derivados das imagens MODIS de 8 dias (a) NDVI, (b) LAI, (c) NDMI e (d) LST. Os valores dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) foram classificados de acordo com os valores de SPI-3, que indicam condições de seca (SPEI-3 < -1) ou úmidas (SPI-3 > 1). Uma linha de tendência (preta) foi ajustada em todos os dados com base na inclinação de Sen (significativa em $\alpha = 0,05$ ). .....	84
<b>Figura 15</b> - Série interanual baseada em valores de NDVI (a), LAI (b), NDMI (c) e LST (d) derivados das imagens MODIS de 8 dias para o período de 2001 a 2020. Com base no SPI-12 do ano hidrológico, as linhas representam os valores de NDVI (a), LAI (b), NDMI (c) e LST (d) pertencentes a anos normais (preto), secos (vermelho), chuvosos (azul) ou a um ano subsequente a um ano hidrológico seco (amarelo) com o uso de suavização de gráfico de dispersão estimado localmente (LOESS). .....	86
<b>Figura 16</b> - Resposta sazonal dos índices NDVI (a), LAI (b), NDMI (c) e LST (d) em diferentes regimes de seca entre 2001 e 2020. A linha amarela representa uma estação seca tanto durante o NDJ quanto em FMA, a linha verde representa que as duas estações foram normais e/ou chuvosas, a linha azul representa uma estação NDJ normal seguida por uma estação FMA seca e o marrom representa uma estação NDJ seca seguida por uma estação MAM normal. ....	88
<b>Figura 17</b> - Pontuações obtidas pela análise de componentes principais (PCA), PC1 e PC2 são a primeira e a segunda dimensões dos dados da PCA, respectivamente, (a) análise de componentes principais dos meses em função das variáveis biofísicas (NDVI, LAI, NDMI e LST) e variáveis climáticas (precipitação e temperatura do ar); (b) análise de componentes principais das variáveis biofísicas e variáveis climáticas em função dos meses no período de 2001-2020 na região em estudo da BHSF. ....	90

<b>Figura 18</b> - Classificação temática do uso e cobertura da terra do MapBiomass, entre os anos de 2001 a 2020, para a região em estudo da BHSF, Brasil. ....	92
<b>Figura 19</b> - Análise de tendência de Mann-Kendall e estimador de Sen para o quantitativo anual do uso e cobertura da terra na região em estudo da BHSF. (a) Caatinga densa, (b) formação vegetal não florestal, (c) agricultura (d) área não vegetada e (e) corpos hídricos. ....	93
<b>Figura 20</b> - Mudanças no uso e cobertura da terra que ocorreram na região em estudo da BHSF entre 2001 e 2020. ....	95
<b>Figura 21</b> - Distribuição espaço-temporal da precipitação pluviométrica, na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020. ....	98
<b>Figura 22</b> - Diagrama boxplot da precipitação pluviométrica anual para as classes de uso e cobertura da terra, na região em estudo da BHSF, entre 2001 e 2020. ....	99
<b>Figura 23</b> - Distribuição espaço-temporal do índice de vegetação por diferença normalizada (NDVI), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020. ....	101
<b>Figura 24</b> - Distribuição espaço-temporal do índice de área foliar (LAI, $m^2 m^{-2}$ ), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020. ....	103
<b>Figura 25</b> - Distribuição espaço-temporal do índice de umidade por diferença normalizada (NDMI), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020. ....	106
<b>Figura 26</b> - Distribuição espaço-temporal da temperatura da superfície terrestre (LST, °C), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020. ....	109
<b>Figura 27</b> - Distribuição geográfica dos solos da região em estudo da BHSF, no primeiro nível categórico, de acordo com Sistema Brasileiro de Classificação de Solos. ....	111
<b>Figura 28</b> - Diagramas boxplot de (a) NDVI, (b) LAI ( $m^2 m^{-2}$ ), (c) NDMI e (d) LST (°C) para as classes de uso e cobertura da terra: Caatinga densa, agricultura (irrigada), formação vegetal não florestal e área não vegetada. Em anos secos, normais, subsequentes a um ano hidrológico seco (ano de recuperação) e chuvosos. ....	113
<b>Figura 29</b> - Correlação entre os parâmetros biofísicos e a precipitação pluviométrica para diferentes defasagens temporais (Lag: 0, -1, -2, -3 e -4 meses). (a) agricultura irrigada, (b) Caatinga densa, (c) formação vegetal não florestal e (d) área não vegetada. ....	115
<b>Figura 30</b> - Tendência de variação média anual na região em estudo da BHSF entre os anos de 2001 a 2020. (a) NDVI, (b) LAI, (c) NDMI e (d) LST. ....	116

## LISTA DE TABELAS

<b>Tabela 1</b> - Características do produto do sensor MODIS, refletância da superfície. ....	51
<b>Tabela 2</b> - Características do produto do sensor MODIS, temperatura da superfície. ....	52
<b>Tabela 3</b> - Classificação dos valores de SPI. ....	54
<b>Tabela 4</b> - Critérios de categorização estatística para tendências de variação dos parâmetros biofísicos.....	66
<b>Tabela 5</b> - Métricas estatísticas de desempenho do produto CHIRPS que levam em consideração estações dentro da área de estudo. ....	68
<b>Tabela 6</b> - Análises de mudanças sazonais e anuais e tendências da precipitação pluviométrica, temperatura média do ar e vazão média utilizando os testes estatísticos de Mann-Kendall ( $Z_s$ ) e de tendência baseada na inclinação de Sen ( $Q$ ), durante o período de 1991-2020 na região em estudo da BHSF. ....	75
<b>Tabela 7</b> - Análise de tendência dos parâmetros biofísicos dos índices de seca (SPI e SSI) utilizando os testes estatísticos de Mann-Kendall ( $ZS$ ) e de tendência baseada na inclinação de Sen ( $Q$ ), durante o período de 1991-2020 na região em estudo da BHSF. ....	79
<b>Tabela 8</b> - Características dos principais eventos de seca meteorológica identificados na região em estudo da BHSF durante 1991 a 2020. ....	81
<b>Tabela 9</b> - Características dos principais eventos de seca hidrológica identificados na região em estudo da BHSF durante 1991 a 2020. ....	83
<b>Tabela 10</b> - Análise de tendência dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) utilizando os testes estatísticos de Mann-Kendall ( $ZS$ ) e de tendência baseada na inclinação de Sen ( $Q$ ), durante o período de 2001-2020 na região em estudo da BHSF. ....	83
<b>Tabela 11</b> - Análises das mudanças anuais e tendências do uso e cobertura da terra utilizando os testes estatísticos de Mann-Kendall ( $Z_s$ ) e estimador de Sen ( $Q$ ), durante o período de 2001 a 2020 na região em estudo da BHSF. ....	91
<b>Tabela 12</b> - Matriz de transição entre as classes de uso e cobertura da terra da região em estudo da BHSF de 2001 a 2020. As áreas de transição estão em $\text{km}^2$ . A área total é a soma das classes: Caatinga densa (CAA), formação vegetal não florestal (FVNF), Agricultura (AGR), área não vegetada (ANV) e corpos hídricos (CH). ....	94
<b>Tabela 13</b> - Análise estatística da tendência de variação média anual do NDVI, LAI, NDMI e LST na região em estudo da BHSF durante os anos de 2001 a 2020.....	117

## LISTA DE QUADROS

<b>Quadro 1</b> - Especificações técnicas do sensor MODIS.....	41
<b>Quadro 2</b> - Especificações das bandas espectrais do sensor MODIS. ....	42
<b>Quadro 3</b> - Produtos do Sensor MODIS para a superfície Terrestre.....	43

## LISTA DE ABREVIATURAS E SIGLAS

AITG	Gradiente de Temperatura da Superfície do Mar Inter-Hemisférico do Atlântico
ANA	Agência Nacional de Águas e Saneamento Básico
BA	Bahia
BHSF	Bacia Hidrográfica do Rio São Francisco
CHESF	Companhia Hidro Elétrica do São Francisco
CHIRPS	<i>Climate Hazards Group InfraRed Precipitation and Station</i>
CP	Componentes Principais
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CV	Coefficiente de Variação
DOL	Distúrbios Ondulatórios de Leste
DP	Desvio padrão
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ENOS	El Niño-Oscilação Sul
EOS	<i>Earth Observing System</i>
ESS	Financiado pela NASA Earth Science Enterprises
FMA	Fevereiro, Março e Abril
FS	Sistemas Frontais
GEE	Google Earth Engine
IBGE	Instituto Brasileiro de Geografia e Estatística
IBVL	Índice de Biomassa da Vegetação Lenhosa
INMET	Instituto Nacional de Meteorologia
LAI	<i>Leaf Area Index</i>
LI's	Linhas de instabilidade
LST	<i>Land Surface Temperature</i>
MCTI	Ministério da Ciência Tecnologia e Inovação

ME	Erro Médio
MK	Mann-Kendall
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
NASA	<i>National Aeronautics and Space Administration</i>
NDJ	Novembro, Dezembro e Janeiro
NDMI	<i>Normalized Difference Moisture Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NE	Nordeste do Brasil
NIR	Infravermelho Próximo
NSE	Coefficiente de Eficiência de Nash-Sutcliffe
ODP	Oscilação Decadal do Pacífico
PBIAS	Erro Percentual Médio
PE	Pernambuco
Q	Tendência Baseada na Inclinação de Sen
r	Coefficiente de correlação de Pearson
Red	Vermelho Visível
RMSE	Erro Quadrático Médio da Raiz
RSF	Rio São Francisco
SAVI	<i>Soil Adjusted Vegetation Index</i>
SDTFs	Florestas Tropicais Sazonalmente Secas
SPI	<i>Standardized Precipitation Index</i>
SSI	<i>Standardized Streamflow Index</i>
SUDENE	Superintendência de Desenvolvimento do Nordeste
SWIR	Infravermelho de Ondas Curtas
Tair	Air Temperature
TRMM	Tropical Rainfall Measuring Mission
USGS	<i>United States Geological Survey</i>
VCAN	Vórtices Ciclônicos de Altos Nível
ZCAS	Zona de Convergência do Atlântico Sul
ZCIT	Zona de Convergência Intertropical
Z <sub>s</sub>	Teste estatístico de Mann-Kendall



## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>19</b>
1.1 Hipóteses .....	22
1.2 Objetivos.....	23
1.2.1 Objetivo geral.....	23
1.2.2 Objetivos específicos.....	23
<b>2 REVISÃO DE LITERATURA</b> .....	<b>24</b>
2.1 Bacia hidrográfica do São Francisco .....	24
2.2 Semiárido e Caatinga .....	27
2.3 Impacto das atividades antrópicas na Bacia Hidrográfica do São Francisco.....	31
2.4 Precipitação e vulnerabilidade climática.....	33
2.5 Sensoriamento remoto aplicado a análises ambientais .....	37
2.6 Sensor MODIS .....	40
2.7 Plataforma Google Earth Engine .....	43
<b>3 MATERIAL E MÉTODOS</b> .....	<b>45</b>
3.1 Área de estudo.....	45
3.2 Conjunto de dados .....	47
3.2.1 Dados meteorológicos e fluviométricos.....	47
3.2.2 Dados derivados de satélites Landsat (Uso e ocupação da terra) .....	48
3.2.3 Precipitação CHIRPS.....	49
3.2.4 Dados orbitais do sensor MODIS do satélite Terra .....	50
3.3 Índices de Seca .....	53
3.3.1 Standard Precipitation Index (SPI) .....	53
3.3.2 Standardized Streamflow Index (SSI) .....	54
3.4 Parâmetros Biofísicos com Produtos MODIS.....	55
3.5 Análise dos dados e índices estatísticos.....	57
3.5.1 Análises estatísticas de validação dos dados CHIRPS .....	57
3.5.2 Efeitos da seca na cobertura e na resiliência vegetal.....	60
3.5.2 Efeito da precipitação no uso e cobertura da terra .....	61
3.5.3 Estatística descritiva.....	62
3.5.4 Análise de tendência da seca, parâmetros biofísicos e uso e cobertura da terra (Teste de Mann-Kendall e estimador de inclinação de Sen).....	63
3.5.5 Análise multivariada dos dados .....	66
<b>4 RESULTADOS E DISCUSSÃO</b> .....	<b>67</b>
4.1 Validação dados CHIRPS .....	67
4.2 Precipitação pluviométrica, temperatura do ar e vazão .....	71

<b>4.3 Ocorrência de eventos de seca para o período 1991-2020.....</b>	<b>78</b>
<b>4.4 Cobertura Vegetal e Resiliência .....</b>	<b>83</b>
<b>4.5 Análise multivariada das variáveis meteorológicas e parâmetros biofísicos .....</b>	<b>89</b>
<b>4.6 Variações espaço-temporais no uso e cobertura da terra .....</b>	<b>91</b>
<b>4.7 Variação espacial e temporal da Precipitação pluviométrica .....</b>	<b>97</b>
<b>4.8 Variação espacial e temporal dos índices de cobertura vegetal .....</b>	<b>100</b>
<b>4.9 Variação espacial e temporal do Índice de Umidade por Diferença Normalizada (NDMI) .....</b>	<b>105</b>
<b>4.10 Variação espacial e temporal da Temperatura da superfície (LST) .....</b>	<b>107</b>
<b>4.11 Efeito da variabilidade pluviométrica e das mudanças no uso da terra nos parâmetros biofísicos da superfície da terra .....</b>	<b>112</b>
<b>4.12 Análise de tendência das alterações espaciais e temporais dos parâmetros biofísicos da superfície da terra .....</b>	<b>116</b>
<b>5 CONCLUSÕES.....</b>	<b>118</b>
<b>REFERÊNCIAS .....</b>	<b>120</b>

## 1 INTRODUÇÃO

A bacia hidrográfica do submédio São Francisco está localizada no semiárido brasileiro, região caracterizada por chuvas insuficientes, ocorrência frequente de secas, e vegetação predominantemente do bioma Caatinga, que possui alta diversidade ecológica de espécies vegetais, sendo considerado o maior bioma do mundo em condições semiáridas (ARNAN et al., 2018; FERREIRA et al., 2020). Durante as últimas décadas, a Caatinga foi afetada amplamente devido às mudanças climáticas e as mudanças antrópicas no uso e cobertura da terra, reduzindo as áreas de vegetação natural a fragmentos isolados. Além disso, apenas 1,75% desse bioma foi convertido em unidades de conservação de proteção integral (CORREIA FILHO et al., 2019; ANTONGIOVANNI et al., 2020; MARQUES et al., 2020; SALAZAR et al., 2021).

Neste contexto, a expansão das atividades antrópicas nos municípios ribeirinhos da bacia hidrográfica do submédio São Francisco, como, por exemplo, Petrolina-PE e Juazeiro-BA, foi favorecida pela construção de grandes barragens como a de Sobradinho, evento que gerou implicações socioeconômicas positivas, mas também ocasionou o aumento de conflitos relacionados ao uso da terra e água (CUNHA et al., 2015; VASCO et al., 2017; JONG et al., 2018; FERREIRA et al., 2020).

Diante disso, a redução da paisagem natural, através da expansão das áreas agrícolas, avanço do pastejo intensivo, expansão urbana e introdução de espécies exóticas, (SILVA et al., 2017; MARENGO et al., 2017; MARTINS et al., 2018a; QUEIROZ et al., 2020), juntamente com a ausência de técnicas adequadas para o manejo do solo provocam mudanças significativas nos processos hidrológicos e nas condições de uso do solo da bacia hidrográfica, facilitando a evolução dos processos erosivos que contribuem diretamente no processo de degradação ambiental e desertificação das terras (CUNHA et al., 2015; TOMASELLA et al., 2018).

Os problemas ambientais no bioma Caatinga têm sido agravados ainda pela ocorrência cada vez mais frequente de fenômenos climáticos extremos, que causam redução das chuvas e eventos de seca intensificados, uma vez que a cobertura vegetal do bioma Caatinga é largamente influenciada pela quantidade de precipitação e pela ocorrência de secas. Devido a esses fatores, o bioma Caatinga pode ficar mais suscetível à desertificação, comprometendo a disponibilidade dos recursos naturais e a sustentabilidade ambiental (COSTA et al., 2021; RIBEIRO et al., 2016; TOMASELLA et al., 2018). Isso porque as mudanças nas propriedades da superfície e das variáveis biofísicas (e.g., cobertura vegetal, temperatura da superfície da

terra, e albedo) podem deixar o ambiente mais hostil (TEIXEIRA et al., 2017; BARBOSA et al., 2018; CUNHA et al., 2020). Contudo, poucos estudos abordam os efeitos das mudanças antrópicas na cobertura vegetal, principalmente no contexto da resiliência da vegetação as mudanças climáticas (por exemplo, PAREDES-TREJO et al., 2021; REFATI et al., 2023; SILVA et al., 2023).

Portanto, o monitoramento dos indicadores físico-hídricos das condições das mudanças ambientais, como a variabilidade e distribuição das chuvas, e o uso e ocupação da terra é de fundamental importância. Uma vez que, pode auxiliar na gestão dos recursos naturais, planejamento das atividades agrícolas, bem como no manejo de áreas secas e no uso e manejo sustentáveis dos recursos naturais (TOMASELLA et al., 2018; PARENTE; FERREIRA, 2018; PARENTE et al., 2019; XAVIER JR et al., 2019; SOUZA et al., 2020; PIMENTA et al., 2021; ROSA et al., 2021).

Para isso, o uso de geotecnologias incluindo o geoprocessamento, e especificamente os conjuntos de técnicas de sensoriamento remoto surgem como alternativas eficiente no monitoramento ambiental da cobertura e uso da terra (BARBOSA et al., 2018; BARBOSA; HUETE; BAETHGEN, 2006; CUNHA et al., 2015, 2020). Essas ferramentas tecnológicas podem ser aplicadas para recursos hídricos e atividades agropecuárias, como também no monitoramento da intensificação das secas e tendências de desertificação ao longo do tempo. A avaliação da variabilidade das chuvas e a dinâmica da cobertura vegetal pode auxiliar no entendimento da degradação da terra devido as mudanças climáticas (FERREIRA et al., 2020; MARENGO et al., 2020; MARIANO et al., 2018; NDEHEDEHE et al., 2020; SANTOS et al., 2020).

De maneira geral, as técnicas de sensoriamento remoto usam índices estáticos como o *Normalized Difference Vegetation Index* (NDVI) (HUETE, 1988; ALLEN et al., 2002; BARBOSA et al., 2006; ALLEN et al., 2007), *leaf area index* (LAI) (ALLEN et al., 2002; ALLEN et al., 2007), *Normalized Difference Water Index* (NDMI) (GAO, 1996), *Standardized Precipitation Index* (SPI) (MCKEE et al., 1993) e o *Standardized Streamflow Index* (SSI) (VICENTE-SERRANO et al., 2012), Estes índices têm sido usados essencialmente como parâmetros biofísicos na compreensão dos processos e impactos das mudanças climáticas e das atividades antrópicas sobre o ecossistema.

Contudo, os produtos oriundos do sensoriamento remoto necessitam de equipamentos computacionais sofisticados para o seu processamento, em virtude de exigirem um consumo maior da memória desses dispositivos (GORELICK et al., 2017; KC et al., 2021; TAMIMINIA et al., 2020; XULU; MBATHA; PEERBHAY, 2021). Neste sentido, o desenvolvimento de

plataformas com elevada capacidade de processamento digital em nuvem para análise geoespacial em escala planetária (por exemplo, Google Earth Engine - GEE), aliado ao uso de imagens de satélites de alta resolução (por exemplo, Landsat, Terra/Aqua - Modis e CHIRPS), possibilitaram avanços em diversas áreas de pesquisa, dentre as quais estão o mapeamento da cobertura e uso da terra, e os estudos relacionados as mudanças climáticas (PARENTE; FERREIRA, 2018; LI et al., 2020; PIMENTA et al., 2021; WANG et al., 2020; WIEGAND et al., 2021).

## **1.1 Hipóteses**

Houve aumento dos períodos de seca em conjunto com a expansão das atividades antrópicas de alta intensidade extensiva sobre as áreas de vegetação nativa do bioma Caatinga? Isso podem prejudicar a resiliência do tipo de cobertura vegetal, e favorecer o processo de degradação ambiental e desertificação das terras ocasionando mudanças irreversíveis na disponibilidade hídrica da bacia hidrográfica do Submédio São Francisco, no semiárido do Brasil?

A avaliação das mudanças hidrometeorológicas e do uso e cobertura da terra utilizando sensoriamento remoto, podem contribuir para formulação de políticas públicas de mitigação e adaptação aos eventos climáticos extremos.

## 1.2 Objetivos

### 1.2.1 Objetivo geral

Avaliar as causas e consequências das mudanças ambientais e hidrometeorológicas na bacia hidrográfica do Submédio São Francisco no semiárido brasileiro.

### 1.2.2 Objetivos específicos

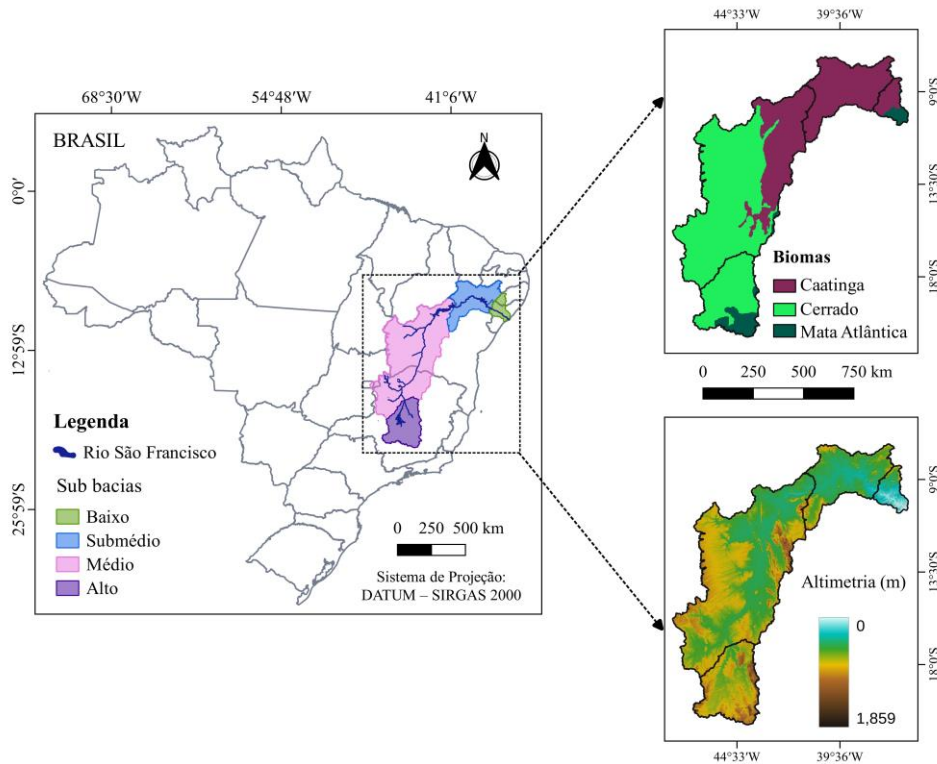
- ✓ Analisar a variabilidade e distribuição das chuvas, por meio de séries temporais usando o conjunto de dados do produto *Climate Hazards Group InfraRed Precipitation and Station* (CHIRPS).
- ✓ Avaliar a ocorrência de secas na região do Submédio São Francisco, por meio do SPI e SSI, a fim de compreender suas características de curto e longo prazo.
- ✓ Identificar tendências anuais de mudanças da cobertura e uso da terra por meio de dados geoespaciais da plataforma MapBiomas Brasil.
- ✓ Analisar a dinâmica espaço-temporal dos parâmetros biofísicos na região do Submédio São Francisco em função da precipitação para investigar a resiliência da cobertura vegetal à seca em diferentes escalas de tempo, conforme a classe de uso e ocupação da terra.
- ✓ Avaliar estatisticamente os resultados quantitativos e temáticos das condições físico-hídricas anuais a partir de análises descritiva, multivariada, correlação e regressão.

## 2 REVISÃO DE LITERATURA

### 2.1 Bacia hidrográfica do São Francisco

O Rio São Francisco (RSF), também chamado coloquialmente como “Velho Chico”, é o principal rio da maior bacia hidrográfica localizada exclusivamente em terras brasileiras e a quarta maior área de drenagem da América Latina. Localizada entre as latitudes 7,2° S e 21,1° S e as longitudes 36,3° W e 47,6° W (Figura 1), a Bacia Hidrográfica do Rio São Francisco (BHSF) corresponde a 8% do território nacional. Este rio recebeu o título de Rio da Integração Nacional porque sua bacia de drenagem abrange mais de 500 municípios, ligando o Sudeste e Centro-Oeste ao Nordeste (TRAINI et al., 2012; FREITAS, 2015; MARTINS et al., 2018b; CASTRO; PEREIRA, 2019; VASCO et al., 2019). Desde as suas nascentes, em Minas Gerais, onde o rio nasce, na Serra da Canastra (1.800 metros acima do nível do mar) (PAREDES-TREJO et al., 2021), escoando no sentido sul-norte por Bahia e Pernambuco, em curso para leste até sua foz, onde deságua, na divisa de Sergipe e Alagoas, percorrendo 2.696 km (TREJO et al., 2016).

Figura 1 - Localização da bacia hidrográfica do rio São Francisco no Brasil, suas sub-bacias, bioma de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE - <https://ibge.gov.br>), e altitudes.



Fonte: Autor, 2023.



Devido a sua extensão de 639.219 km<sup>2</sup> da nascente até a foz e diferentes domínios climáticos percorridos pelo RSF, a bacia foi dividida em quatro regiões fisiográficas: Alto (102.275,04 km<sup>2</sup>, 16%), Médio (402.707,97 km<sup>2</sup>, 63%), Submédio (108.667,23 km<sup>2</sup>, 17%) e Baixo (25.568,76 km<sup>2</sup>, 4%) (Figura 1). O Alto São Francisco se estende das nascentes até Pirapora (MG), o Médio segue de Jequitaiá (MG) à cidade de Remanso (BA), às margens do reservatório de Sobradinho, o Submédio compreende o trecho entre Remanso (BA) e Paulo Afonso (BA) e o baixo, de Paulo Afonso (BA) até a foz (SUN et al., 2016; VASCO et al., 2019; TEIXEIRA et al., 2020; CHESF, 2021).

Com grande diversidade ambiental, a BHSF possui diversas condições naturais e abrange diferentes biomas, em sua maior parte, Cerrado e Caatinga (Figura 1). O Cerrado, ocupa basicamente metade da bacia, com predominância em Minas Gerais e no oeste e sul da Bahia (Alto e Médio São Francisco). Por outro lado, a Caatinga domina as regiões áridas e semiáridas da Bahia, Pernambuco e oeste de Alagoas e Sergipe (Médio, Submédio e Baixo São Francisco) (CREECH et al., 2015; CBHSF, 2016; OLIVEIRA et al., 2017; TEIXEIRA et al., 2020).

No Alto, Médio e Baixo São Francisco, há predominância de solos com aptidão para a agricultura irrigada (latossolos e podzólicos). Por outro lado, o Submédio é a área do vale com os menores potenciais de solos e as reduzidas possibilidades de irrigação. Cerca de 13% da área total da bacia apresenta perda de solo superior a 10 t.ha<sup>-1</sup>.ano<sup>-1</sup>, o que representa o limite de tolerância para a maioria dos solos tropicais (CASTRO; PEREIRA, 2019).

Embora na região denominada Vale do Submédio São Francisco, localizada entre os municípios de Petrolina (PE) e Juazeiro (BA), verifique-se crescimento da agricultura irrigada, devido ao fácil acesso ao RSF que mantém o fornecimento de água mesmo em períodos de seca. As lavouras irrigadas compreendem principalmente a fruticultura, sendo as mais comuns uvas, manga, goiaba, banana e coco, cercadas por vegetação de caatinga (SCHOELLHAMER et al., 2013; FERREIRA et al., 2020; TEIXEIRA et al., 2021).

No que diz respeito às características climáticas, a precipitação na região hidrográfica do São Francisco varia em magnitude, com médias de 350 mm entre Sento Sé e Paulo Afonso (Submédio) a 1.500 mm nas nascentes do rio (Alto São Francisco). A principal estação chuvosa ocorre no Alto e Médio São Francisco entre novembro e janeiro, atingindo o pico em dezembro, contribuindo com 55% a 60% da precipitação anual, enquanto o mais seco é de junho a agosto; no Submédio, chuvas persistentes são observadas entre janeiro e abril e no Baixo a estação chuvosa ocorre de março a agosto (TREJO et al., 2016; MARENGO et al., 2017; OLIVEIRA et al., 2017; VASCO et al., 2017; CASTRO; PEREIRA, 2019). A temperatura média anual

varia de 18 a 27 °C, com ocorrência das condições térmicas mais elevadas nas baixas altitudes do Submédio; taxas de evaporação relativamente altas de 2300 a 3000 mm ano<sup>-1</sup> e insolação de 2400 a 3300 horas.ano<sup>-1</sup> (GENZ; LUZ, 2012; VASCO et al., 2019). Vale ressaltar que mais da metade da BHSF, encontra-se no semiárido brasileiro, uma região com afluentes sazonais, sujeita a secas prolongadas, severas e cíclicas, altas taxas de evapotranspiração e tipos de solo com baixa retenção de água.

O RSF possui 168 afluentes, dos quais 99 são perenes e 69, intermitentes. Os rios afluentes localizados no Alto e Médio São Francisco são perenes, sendo responsáveis pelo fornecimento de quase 70% das águas superficiais do São Francisco. Por outro lado, os afluentes, situados no Submédio São Francisco, são intermitentes, secam nos períodos de pouca pluviosidade e produzem grandes torrentes na época das chuvas. O RSF, é responsável por quase 70% da disponibilidade de águas superficiais do Nordeste e das necessidades hídricas dos habitantes de seu território (CREECH et al., 2015; MEDEIROS et al., 2015; CASTRO; PEREIRA, 2019).

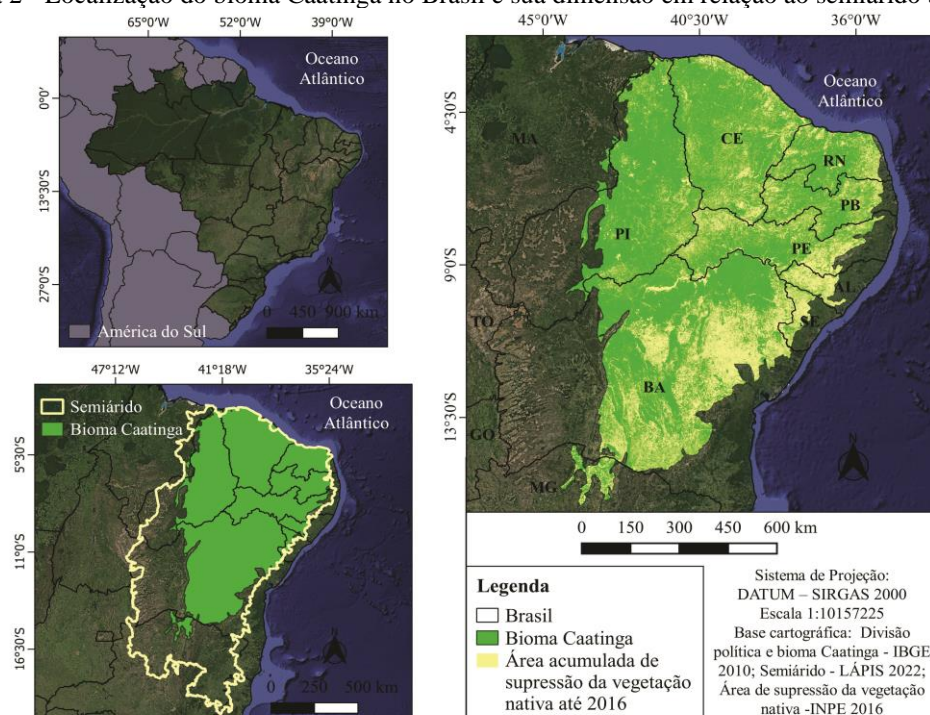
A disponibilidade hídrica superficial da BHSF, definida a partir da Q95 (vazão que passa no rio em pelo menos 95% do tempo) das vazões nos lagos de reservatórios e das vazões liberadas a jusante das respectivas barragens, é de 821 m<sup>3</sup> s<sup>-1</sup>, e possui vazão média de 2.900 m<sup>3</sup> s<sup>-1</sup>, que se enquadra na tipologia de rio de médio a grande porte (ANA, 2020; SOARES et al., 2021). A BHSF abastece cerca de 18 milhões de habitantes o equivalente a 8% da população do País, com uma população urbana correspondente a 77% desse total, a maior densidade demográfica é verificada na região metropolitana de Belo Horizonte (CASTRO; PEREIRA, 2019; CODEVASF, 2019). As águas da BHSF são utilizadas para geração de energia elétrica, irrigação, navegação, abastecimento de água, aquicultura e pesca (SANTOS; POMPEU; KENJI, 2012).

A geração de energia e a irrigação destacam-se como os principais usos econômicos, sendo o RSF responsável por cerca de 13% (10.473MW) da demanda elétrica brasileira e 70% do abastecimento elétrico do Nordeste, distribuídos num sistema em cascata de barragens, totalizando 6 barragens principais (Três Marias, Queimado, Sobradinho, Itaparica, Complexo Paulo Afonso e Xingó), com um volume armazenado em seus reservatórios em torno de 71 km<sup>3</sup> (MEDEIROS et al., 2014; TREJO et al., 2016; CASTRO; PEREIRA, 2019; JONG et al., 2018). O fornecimento de cerca de 120 m<sup>3</sup>s<sup>-1</sup> destinados à alimentação de projetos de irrigação da região, com mais de 300 mil hectares irrigados, correspondente a 11% da agricultura irrigada total do Brasil (BUCKLEY, 2010; CREECH et al., 2015; CODEVASF, 2019).

## 2.2 Semiárido e Caatinga

O Semiárido brasileiro se estende pelos nove estados da região Nordeste e pelo norte de Minas Gerais e do Espírito Santo (Figura 2), essa região foi delimitada pela Superintendência de Desenvolvimento do Nordeste - SUDENE considerando condições climáticas dominantes de semiaridez, em especial a precipitação pluviométrica. No total, ocupa 12% do território nacional e abriga cerca de 28 milhões de habitantes divididos entre zonas urbanas (62%) e rurais (38%), sendo, portanto, um dos semiáridos mais povoados do mundo (IBGE, 2010; MCTI, 2019). Como reflexo das condições climáticas, a hidrografia é frágil, em seus amplos aspectos, sendo insuficiente para manutenção de rios perenes nos longos períodos de ausência de seca. Constitui-se exceção o rio São Francisco (IBGE, 2018).

Figura 2 - Localização do bioma Caatinga no Brasil e sua dimensão em relação ao semiárido brasileiro.



Fonte: Autor, 2023.

A região semiárida do Brasil é caracterizada por um longo período de seca e um período de chuvas curto e irregular, alta temperatura do ar, elevada incidência de radiação solar, baixa umidade relativa do ar, forte potencial de evapotranspiração e sazonalidade bem definida, apresentando déficit hídrico na maior parte do ano, embora sejam verificados eventos extremos de chuva em alguns meses do ano (OLIVEIRA et al., 2017; MUTTI et al., 2019). A escassez de água do Semiárido brasileiro tem causas naturais fundamentais, como extensos terrenos

cristalinos, oscilação anual da Zona de Convergência Intertropical (ZCIT) e eventos cíclicos de ENOS (El Niño-Oscilação Sul). Estes estão associados as mudanças ambientais provenientes do impacto antropogênico na geografia regional (CORREIA FILHO et al., 2019; RODRIGUES; MCPHADEN, 2014).

Com mais de onze mil espécies vegetais catalogadas, o bioma predominante do Semiárido brasileiro é a Caatinga (MCTI, 2019). Esse bioma é típico de regiões semiáridas, e em escala global, faz parte das Florestas Tropicais Sazonalmente Secas (SDTFs), que não eram consideradas pela comunidade científica como um bioma global distinto até poucos anos atrás (SILVA et al., 2017).

O bioma Caatinga é coberto por um mosaico de diferentes fitofisionomias que forma um ecossistema totalmente funcional e compreende uma área contínua estimada de 844.453 km<sup>2</sup>, o equivalente a 53% da região Nordeste do Brasil e 10% do território nacional, o qual compreende os estados de Alagoas, Bahia, Ceará, Maranhão, Pernambuco, Paraíba, Rio Grande do Norte, Piauí, Sergipe e o norte de Minas Gerais (Figura 2) em contraste com a maioria das (SDTFs), localizadas do noroeste do México ao norte da Argentina, geralmente compostas por fragmentos isolados de tamanhos variáveis (CORREIA FILHO et al., 2019a; MARQUES et al., 2020; MMA, 2021; SALAZAR et al., 2021).

A vegetação típica da Caatinga é caracterizada por diferentes mosaicos florísticos, com predominância de árvores e arbustos, além de áreas abertas, que apresentam sua distribuição condicionada às variações climáticas e ambientais, sobretudo, a intensidade e regularidade de chuvas (MENDES et al., 2017), como também, configurações geológicas e propriedades do solo. Em geral, a paisagem da Caatinga é composta por solos arenosos que retêm pouca água, pontuados por afloramentos rochosos nus, conhecidos como serrotes (SILVA et al., 2017; JARED et al., 2020), outro aspecto importante é a presença de bromas, ervas anuais e geófitas na camada do solo (BARBOSA et al., 2018).

De maneira geral, as plantas da Caatinga desenvolveram características adaptativas para tolerar o estresse hídrico e prosperar sob restrições ambientais adversas, como folhas micrófilas, cutículas impermeáveis, acúleos e espinhos, presença de estratos herbáceos anuais, suculência (principalmente cactos), predominância de arbustos e árvores de pequeno porte, com as árvores maiores atingindo uma altura média de 3 a 9 m, e cobertura descontínua de copas (SILVA et al., 2017; BARBOSA et al., 2019; CORREIA FILHO et al., 2019; SALAZAR et al., 2021). Contudo, talvez a característica mais notável seja a caducifólia que torna o solo exposto durante a estação seca (agosto-novembro) e resulta em uma paisagem com troncos secos e esbranquiçados, de onde originou o termo “Caatinga” (caa = floresta, tinga = branco, no tupi).

Por outro lado, com o início da estação chuvosa as plantas começam produzir expressiva quantidade de biomassa (TEIXEIRA et al., 2009; BARBOSA et al., 2019).

A Caatinga foi identificada como uma das regiões de vida selvagem mais importantes do globo e florestas secas de maior biodiversidade (KOCH et al., 2017), abrangendo 4.662 espécies de plantas registradas das quais 702 são endêmicas, as Leguminosae apresentam o maior número de espécies endêmicas (112), o que representa 16% de todas as espécies endêmicas no bioma Caatinga (SILVA et al., 2017). A composição florística desse bioma é rica em cactáceas, bromeliáceas, euforbiáceas e leguminosae, porém é pobre em gramíneas. Além disso, abriga uma alta biodiversidade animal contendo 183 espécies de mamíferos, 548 de aves, 210 de répteis, 98 de anfíbios, 386 de peixes, 276 de formigas e 221 de abelhas (SILVA et al., 2017; MMA, 2021).

As famílias mais diversas são Leguminosae (112 gêneros e 474 espécies), Euphorbiaceae (25/187), Poaceae (58/151), Asteraceae (71/127), Rubiaceae (45/106), Malvaceae (27/109), Cyperaceae (13/101), Convolvulaceae (10/88), Apocynaceae (23/85), Bromeliaceae (14/78) e Cactaceae (22/73) que além de compor a emblemática paisagem seca da Caatinga, são o exemplo mais marcante de alto endemismo, com cerca de 50% sendo endêmicas. Juntas, essas famílias correspondem a mais de 50% do número total de espécies da Caatinga (SILVA et al., 2017). E as espécies encontradas com maior frequência são *Aspidosperma pyrifolium* Mart.; *Myracrodruon urundeuva* Allemão, *Cereus jamacaru* DC.; *Anadenanthera colubrina* var. *cebil* (Griseb.) Altschul; *Handroanthus impetiginosus* (Mart. ex DC.) Mattos; *Jatropha mollissima* (Pohl) Baill.; *Cynophalla hastata* (Jacq.) J. Presl, *Commiphora leptophloeos* (Moric.) J. S. Mill. e *Mimosa tenuiflora* (Willd.) Poir. (BANDA et al., 2016).

A Caatinga vem experimentando a conversão de sua vegetação natural em paisagens modificadas pelo homem desde a chegada dos europeus no século XVI, com intensa degradação ambiental e perda de biodiversidade nas últimas décadas, principalmente pela intensificação da agricultura (por exemplo, cultivo de sequeiro e irrigado), expansão urbana e avanço de áreas de pastagem. Hoje em dia, a paisagem da Caatinga consiste em (a) áreas dedicadas à agricultura intensiva (corte e queima) e pastagens; (b) vegetação secundária com diferentes estágios sucessionais, mas exposta à exploração dos recursos vegetais; (c) áreas degradadas que frequentemente estão sujeitas a desertificação; e (d) pequenos e antigos fragmentos de vegetação (SILVA et al., 2017; MARENGO et al., 2017; MARTINS et al., 2018a).

Os remanescentes da Caatinga cobrem atualmente 413.991,96 km<sup>2</sup>, correspondendo a 50% da vegetação original. Além disso, a Caatinga encontra-se subdividida em 47.100

fragmentos, embora 91% deles sejam menores que 5 km<sup>2</sup>, 720 fragmentos são maiores que 100 km<sup>2</sup>, correspondendo a 78% da vegetação remanescente. No entanto, apenas 1,75% desse bioma foi convertido em unidades de conservação de proteção integral e 7% em unidades de conservação de uso sustentável (ANTONGIOVANNI; VENTICINQUE; FONSECA, 2018)

A Caatinga e outras SDTFs têm recebido menos atenção do que as florestas tropicais em relação aos esforços de pesquisa (KOCH et al., 2017; TOMASELLA et al., 2018). Embora, os avanços das mudanças no uso da terra e as constantes alterações do clima global, aliados aos níveis relativamente altos de endemismo do bioma Caatinga apontam para uma necessidade urgente de mais estudos e medidas de proteção desse bioma (SILVA et al., 2017; SANTOS; DO NASCIMENTO; DA SILVA, 2020; ESPINDOLA et al., 2021). Visto que, alguns cientistas acreditam que as espécies da caatinga já estejam operando em seus limites fisiológicos (SANTOS et al., 2012).

No entanto, o monitoramento ambiental realizado em campo frente às mudanças de estrutura e dinâmica da cobertura vegetal da Caatinga, torna-se inviável devido às dificuldades de tempo, monitoramento em larga escala, custo e principalmente o deslocamento para áreas mais remotas do semiárido (SILVA et al., 2020b). Deste modo, surge a necessidade buscar alternativas que visem o monitoramento ambiental de forma prática e eficiente frente a essas dificuldades, e possibilitem relacionar a cobertura vegetal e a interação dessa com os fenômenos atmosféricos.

Um dos métodos mais práticos utilizados atualmente para identificação e classificação da fitofisionomia da Caatinga foi proposto por Chaves et al. (2008) e utiliza o Índice de Biomassa da Vegetação Lenhosa (IBVL) em imagens de satélites. O qual, segundo Francisco et al. (2013), quando associado às técnicas de sensoriamento remoto, pode contribuir no mapeamento de áreas com diferentes estados de vulnerabilidade das terras e degradação ambiental, e assim, produzir informações que facilitam estudos de monitoramento e gerenciamento ambiental.

### 2.3 Impacto das atividades antrópicas na Bacia Hidrográfica do São Francisco

O RSF considerado o mais importante do Nordeste, pelo volume de água transportado para o semiárido tem sofrido constantes intervenções antrópicas desde os tempos imperiais, que exerceram demandas adicionais sobre a bacia ocasionando diversos impactos ambientais. De modo que, dos grandes rios localizados completamente em território brasileiro é o que apresenta os maiores desafios e problemas de preservação, conservação e proteção do seu manancial ao longo de todo seu percurso, da nascente à foz (SANTOS et al., 2012; FREITAS, 2015; SOARES et al., 2021).

Na região da BHSF os conflitos pelo uso dos recursos naturais têm sido crescentes, devido principalmente a construção de diversas barragens no curso principal do RSF, que se destinam a diversos usos, dentre os quais se destacam a geração de energia e redução das vazões. Para atender à demanda de energia do sistema ao qual estão conectados, esses reservatórios acumulam água durante a estação chuvosa (verão e início da primavera) e, então, durante a estação seca (inverno e outono) liberam o volume acumulado (VASCO et al., 2017; JONG et al., 2018; MARTINS et al., 2018b). Deste modo, os elevados picos de vazões de 8.000 a 15.000 m<sup>3</sup> s<sup>-1</sup>, que ocorriam naturalmente nos primeiros meses do ano (janeiro a março), foram drasticamente reduzidas (MEDEIROS et al., 2014).

Os conflitos iniciaram-se a partir do ano de 1955, com a inauguração da hidrelétrica de Três Marias a primeira das seis maiores hidrelétricas existentes atualmente no rio (SANTOS et al., 2012; MEDEIROS et al., 2014; FREITAS, 2015). Como resultado da construção dos barramentos, desde 1994 com a implantação da última grande hidrelétrica (Xingó), a região do submédio São Francisco teve anos consecutivos com reduções das vazões, atingindo diminuição de mais de 50% em sua vazão média, de 3150 m<sup>3</sup> s<sup>-1</sup> para 2060 m<sup>3</sup> s<sup>-1</sup>, que ocasionou alterações hidrológicas dramáticas (BERNARDES et al., 2012; GENZ; LUZ, 2012; CAVALCANTE et al., 2017).

Esse cenário foi agravado com a seca severa na região que iniciou em 2012 e se prolongou por vários anos, agravando à escassez de água e elevando o déficit hídrico na região (JONG et al., 2018; MARENGO et al., 2018). Como consequência da seca, o reservatório de Sobradinho, principal responsável pelo controle das vazões ao longo do curso do RSF, operar próximo ao volume morto devido os baixos níveis de sua capacidade verificados nos meados de novembro de 2015 e 2016, comprometendo a disponibilidade hídrica para os múltiplos usos, dentre os quais se destacam o abastecimento humano e dos setores irrigados que tiveram seus

rendimentos comprometidos (CAVALCANTE et al., 2017; CHESF, 2017; JONG et al., 2018; MARENGO et al., 2018).

A redução da vazão pós-construção das barragens, também está relacionada a outros fatores como a crescente demanda por água para usos múltiplos na BHSF, principalmente nos perímetros irrigados, associada à criação dos lagos artificiais que elevaram as perdas por evaporação, e a execução do projeto de transferência de águas entre bacias (conhecido informalmente como Transposição), que além da redução das vazões podem aumentar o déficit hídrico em alguns períodos do ano (TEIXEIRA et al., 2009; VASCO et al., 2017; VASCO et al., 2019). Quando somados, ausência de gerenciamento e controle do uso da água, os conflitos são potencializados. Entretanto, os principais problemas dessas regiões são o tipo de solo e a grande taxa de evaporação devido à baixa capacidade de armazenamento da água. Nessa conjuntura, é necessário buscar o desenvolvimento e implementação de estratégias de uso e manejo do solo que mitiguem os efeitos degradantes nos recursos naturais.

Analogamente, a construção da barragem de Sobradinho impulsionou a exploração e a mudança no uso da terra nas vizinhanças do rio São Francisco, levando a múltiplos programas de irrigação e desenvolvimento agrícola na região que estimularam a expansão urbana e crescimento econômico, principalmente nas cidades de Petrolina (PE) e Juazeiro (BA) que constituem no maior polo de exportação de frutas do semiárido brasileiro (CABRAL JÚNIOR et al., 2019; FERREIRA et al., 2020; SALAZAR et al., 2021).

Nesse contexto, ao longo das últimas décadas, as mudanças no uso e cobertura da terra têm sido um dos principais agentes de transformação do ecossistema terrestre (NEWBOLD et al., 2015; SONG et al., 2018), devido aos seus impactos na intensificação dos processos de degradação dos recursos terrestres e hídricos, redução da vegetação nativa e perda da biodiversidade (FRANCISCO et al., 2013; CREECH et al., 2015; SANTOS; DO NASCIMENTO; DA SILVA, 2020). Fatores que associados aos limites restritivos dos atributos dos solos e da agressividade climática causam frequentes impactos ambientais, relacionados aos processos de degradação e desertificação (FRANCISCO et al., 2013; SILVA et al., 2017).

Essas mudanças estão relacionadas particularmente com a expansão das áreas agrícolas e avanço do pastejo intensivo em áreas de vegetação nativa aliadas a ausência de técnicas adequadas para manejo do solo, expansão urbana e introdução de espécies exóticas (MARENGO et al., 2017; MARTINS et al., 2018a; QUEIROZ et al., 2020). Que em conjunto com as mudanças climáticas, como redução de chuvas e eventos de seca intensificada, tornam o bioma Caatinga o ecossistema brasileiro mais ameaçado e suscetível à desertificação,



comprometendo cada vez mais os recursos naturais e a sustentabilidade ambiental (COSTA et al., 2021; RIBEIRO et al., 2016; TOMASELLA et al., 2018).

Ainda convém destacar que, as mudanças no uso da terra têm exercido forte pressão sobre a vegetação da Caatinga. Sobretudo na Caatinga rural, onde a pobreza humana e a degradação do solo estão intimamente relacionadas, promovendo o abandono da terra e a desertificação (ANTONGIOVANNI et al., 2020; RIBEIRO et al., 2015). Essa relação pode ser descrita como um paradoxo socioecológico em que a exploração dos recursos naturais reduz continuamente a produtividade do ecossistema e conduz áreas de caatinga com porte arbóreo e denso em direção à vegetação subarbustiva e aberta ou mesmo a áreas desertificadas. Além de reduzir a renda da população e a capacidade de adoção de tecnologias apropriadas, levando a um novo ciclo de exploração para compensar a produtividade reduzida (SILVA et al., 2017).

Associado a essa questão, a supressão das matas ciliares aliada as mudanças climáticas, têm causado uma série de impactos na BHSF, por exemplo, menor interceptação de chuvas, alterações nas propriedades e características da infiltração de água no solo, aumento do fluxo superficial e evolução dos processos erosivos, que contribuem diretamente no processo de degradação ambiental e desertificação das terras, gerando uma carga de sedimentos e materiais que é dispersada e depositada ao longo da calha principal do rio e de seus reservatórios de barramento, acelerando o assoreamento do rio (APARECIDO et al., 2018; CANTALICE et al., 2019; CHABARIBERY et al., 2008; SANTOS et al., 2020; SOARES; SILVA; NAVAS, 2021).

## **2.4 Precipitação e vulnerabilidade climática**

As condições meteorológicas, como a alta variabilidade pluviométrica e irregular distribuição espaço-temporal das chuvas, e os efeitos agravantes das mudanças climáticas, como a intensificação dos eventos de seca, aliados a alta densidade populacional, fazem com que a região semiárida do Brasil enfrente diversos transtornos e conflitos devido ao aumento da escassez hídrica. Este conjunto de eventos causam graves problemas naturais, sociais e econômicos, principalmente na agricultura de subsistência, historicamente muito praticada no semiárido brasileiro, onde grande parte da população que habita essa região vive realmente em situação de extrema pobreza (CUNHA et al., 2015; OLIVEIRA et al., 2017; COSTA et al., 2020; MUTTI et al., 2020).

Diversos estudos alertam para o aumento da suscetibilidade do semiárido brasileiro as mudanças climáticas, que promovem aumento da temperatura média, aumento das taxas de evaporação e redução dos valores de chuva, além de aumentarem a variabilidade dos eventos

de chuva, com implicações no ciclo hidrológico e nos recursos hídricos (CUNHA et al., 2015; MARENGO et al., 2017, 2018; COSTA et al., 2020).

Entre os desastres naturais causados pelo clima e mudanças climáticas, a seca é considerada um dos desastres naturais adversos mais importantes que ameaça à segurança alimentar e hídrica em regiões semiáridas de todo o mundo (QURESHI et al., 2022; ACHITE et al., 2021; HARSÁNYI et al., 2021; KALISA et al., 2021; PAREDES-TREJO et al., 2021). Isso é atribuído às características complicadas das secas, que geralmente têm início lento, mas podem se estender por meses ou até anos (SCHUBERT et al., 2016; CUNHA et al., 2019; RAZA et al., 2021). Além disso, o aumento da aridez em decorrência dos maiores e mais frequentes períodos de seca tem provocado modificações na cobertura e uso da terra, e aumento do processo de desertificação (TOMASELLA et al., 2018; MARENGO et al., 2018, 2020; COSTA et al., 2020).

A seca é categorizada em quatro tipos principais (com base na duração, impacto e taxa de recuperação): seca meteorológica, hidrológica, agrícola e socioeconômica (KALISA et al., 2021; PAREDES-TREJO et al., 2021). Um déficit prolongado de precipitação corresponde à seca meteorológica (CUNHA et al., 2019). A seca hidrológica ocorre após o início da seca meteorológica, sendo caracterizada pela redução anormal da disponibilidade de água superficial e subterrânea (VAN LOON; LAAHA, 2015; KALISA et al., 2021). A seca agrícola ocorre quando o declínio da umidade do solo da zona radicular disponível para a vegetação é persistente no tempo afetando o rendimento da safra (SAMANIEGO et al., 2013; CUNHA et al., 2015).

Quando a disponibilidade hídrica não é suficiente para satisfazer as demandas feitas pelas atividades humanas e pela vegetação no abastecimento de água de uma região é chamada de seca socioeconômica, no entanto essa é uma perspectiva que não tem sido aplicada a muitos estudos, visto que ela é vista como um resultado, ou seja, impacto da seca ao invés de uma categoria de seca (SAMANIEGO et al., 2013; KALISA et al., 2021).

A precipitação está intimamente relacionada a circulação atmosférica e é um componente crítico do ciclo hidrológico. Na região semiárida do Brasil a instabilidade das chuvas é influenciada pela soma de vários componentes climáticos que operam mais precisamente na escala sinótica e sub-sinótica (JARDIM et al., 2021a); por exemplo, oscilações da zona de convergência intertropical (ZCIT) (HOUNSOU-GBO et al., 2015; UTIDA et al., 2019; MEDEIROS et al., 2020; MOURA et al., 2020), zona de convergência do Atlântico Sul (ZCAS) (MARENGO et al., 2018), distúrbios ondulatórios de leste (DOL) (COSTA et al., 2018; LIMA et al., 2019; RODRIGUES et al., 2020a), vórtices ciclônicos de altos níveis

(VCAN) (WIEGAND et al., 2021) e Sistemas Frontais (FS) (MOLION; BERNADO, 2002). Além disso, na região semiárida brasileira, existem modos de variabilidade climática que interferem na variabilidade climática e na dinâmica do bioma Caatinga (CORREIA FILHO et al., 2019a), por exemplo, El Niño-Oscilação Sul (ENOS) e Oscilação Decadal do Pacífico (ODP) e gradiente de temperatura da superfície do mar inter-hemisférico do Atlântico (AITG) – (ERFANIAN et al., 2017; LYRA et al., 2017; MARENGO et al., 2013, 2018).

Estudos indicam que as mudanças climáticas podem aumentar a frequência e a severidade das secas na região semiárida do Brasil nos próximos anos. Diversos estudos já apontam aumentos significativos da temperatura média, aumento de áreas degradadas sobre pastagem e áreas de Caatinga e substituição da vegetação do bioma Caatinga (cobertura vegetal do Semiárido Brasileiro), por vegetação típica de condições áridas (TOMASELLA et al., 2018; MARENGO et al., 2020).

Durante o período de 2000 a 2018 o semiárido brasileiro perdeu cerca 26,96% da cobertura de vegetação florestal nativa, equivalente a 60.769,39 km<sup>2</sup> (SANTOS; NASCIMENTO; SILVA, 2020). Barbosa et al. (2018) avaliaram os padrões espaço-temporais do impacto da seca no bioma Caatinga, entre os anos de 2008 e 2016, a partir da relação entre o NDVI e a precipitação, e verificaram, sobretudo no período de 2012 a 2015, uma forte diminuição na atividade da vegetação em função do impacto severo da seca.

Analisar as tendências das mudanças climáticas, em particular as variáveis de precipitação, é de extrema complexibilidade, pois envolve diversos fatores e condições, principalmente devido à alta variabilidade espaço-temporal das chuvas e aos efeitos das mudanças climáticas. Nesse contexto, numerosos estudos apontam a necessidade de verificar mudanças tanto no total de chuvas quanto no comportamento médio desta variável para identificar, por exemplo, a ocorrência de eventos extremos de chuva e ocorrência de seca (NÓBREGA et al., 2015; XAVIER et al., 2016; COSTA et al., 2020).

Destaca-se que, para uma detecção dos eventos extremos de chuva e estimativa precisa dos impactos da seca no ecossistema, ainda existem vários desafios metodológicos e relacionados aos dados que devem ser abordados, visto que a obtenção de dados precisos de precipitação é essencial para a análise meteorológica, climática, e também a chave para o gerenciamento bem-sucedido dos recursos hídricos (SIEBERT et al., 2017; XIANG et al., 2021).

Para melhor analisar e detectar mudanças climáticas da precipitação, a Organização Meteorológica Mundial (OMM) criou um grupo de trabalho que desenvolveu uma ampla gama de índices de variabilidade climática e extremos para chuva (COSTA et al., 2020); por exemplo,

*Standardized Precipitation Index* (SPI) (MCKEE et al., 1993), *Palmer Drought Severity Index* (PDSI) (ALLEY, 1984), ou o *Standardized Precipitation Evapotranspiration Index* (SPEI) (VICENTE-SERRANO et al., 2010).

O SPI é um dos principais índices empregados na caracterização dos eventos de secas e chuvas na região semiárida do Nordeste brasileiro e no mundo (COSTA et al., 2021; DA SILVA et al., 2020; NDEHEDEHE et al., 2020). O SPI é calculado a partir de dados de precipitação de diferentes escalas, como, por exemplo, diário, mensal, trimestral, semestral e/ou anual, possibilitando a estimativa das condições de seca ou úmidas de uma região (MARENGO et al., 2020; SOUZA; RIBEIRO NETO; SOUZA, 2021).

É importante destacar que esses índices são geralmente derivados de conjuntos de dados climáticos em grade que podem enviesar a estimativa dos impactos da seca sobre o ecossistema (AUFFHAMMER et al., 2013). No Brasil, isso ocorre porque esses dados dependem geralmente de uma rede composta por estações meteorológicas e pluviômetros distribuídos pontualmente que não é capaz de captar o clima local e as heterogeneidades biofísicas da paisagem, além de apresentarem, geralmente, falhas e erros na coleta de dados por instrumentos automáticos e/ou erros de leitura manual (XAVIER et al., 2016; XAVIER JR et al., 2019).

Para superar essa limitação, diversas pesquisas estão utilizando produtos geoespaciais de sensoriamento remoto ou derivados de algoritmos que auxiliam na estimativa dos volumes de chuva com base em modelos climáticos de circulação global (SANTOS et al., 2021), os quais têm sido utilizados nos cálculos de índices de variabilidade climática, via sensoriamento remoto como meio de fornecer uma medição de alta resolução dos impactos das mudanças climáticas sobre o ecossistema (WU et al., 2014; GARCÍA-LEÓN et al., 2019). Alguns desses produtos são: CHIRPS (GUO et al., 2017; QUESADA-MONTANO et al., 2019; MESA et al., 2021), *Tropical Rainfall Measuring Mission* (TRMM) (ADANE et al., 2021; RAHMAN et al., 2021; WANG et al., 2021), WorldClim (ESSE et al., 2021; KIM; JUNG, 2020; ZHANG et al., 2020), PRISM (BERNHARDT; CARLETON, 2019; DI VITTORIO; MILLER, 2013).

Contudo, poucos estudos se preocuparam com a avaliação de produtos geoespaciais para estimativas de precipitação na região semiárida do Brasil. As poucas pesquisas realizadas têm voltado seus esforços em produtos geoespaciais específicos como CHIRPS (PAREDES-TREJO et al., 2017; BRITO et al., 2021) e TRMM (BONTEMPO et al., 2020; RODRIGUES et al., 2020a). Desses poucos estudos, Paredes-Trejo et al. (2017), avaliando o CHIRPS para a região Nordeste do Brasil, mostrou que as estimativas provenientes das imagens orbitais têm uma boa correlação geral ( $r = 0,94$ ), mas tendem a subestimar os valores de precipitação nos períodos secos e superestimar nos períodos chuvosos.

Desenvolvido pelo US Geological Survey (USGS) e pelo *Climate Hazards Group da University of California, Santa Barbara*, o *Climate Hazards group Infrared Precipitation with Stations* (CHIRPS) é um conjunto de dados de precipitação quase global (50 ° S-50 ° N) e se estende por todas as longitudes, com registros de longo prazo (1981 até o presente) e resolução espacial relativamente 0,05° ( $\pm$  5,3 km) em relação a outros produtos de precipitação baseados em satélite, que normalmente têm uma resolução espacial de 0,25° ou 0,1°. O CHIRPS apresenta resoluções temporais diárias a sazonais, disponível mundialmente desde 1981 (FUNK et al., 2015).

## **2.5 Sensoriamento remoto aplicado a análises ambientais**

Monitorar e caracterizar as respostas dos ecossistemas frente aos cenários de mudanças climáticas e ambientais globais tem sido área de interesse de pesquisa em uma ampla gama de campos científicos, e merece atenção considerando a interação estreitamente relacionada entre uso e cobertura da terra, clima e biosfera (POUSA et al., 2019; ALENCAR et al., 2020; JAAFAR; MOURAD, 2021; PIMENTA et al., 2021).

Dentre a infinidade de métodos que podem ser utilizados para avaliar e monitorar a dinâmica do ecossistema e modelar os processos da biosfera, o sensoriamento remoto oferece grande vantagem sobre as técnicas de campo, pois permite a amostragem de grandes áreas, incluindo lugares remotos, em tempo real aproximado em diferentes escalas espaciais e resoluções (FEYISA et al., 2014; BONTEMPO et al., 2020). Isso é possível devido aos avanços tecnológicos ocorridos nas últimas décadas, em especial o desenvolvimento de sensores a bordo de satélites, como o Terra e Aqua (MODIS), Landsat 8 OLI, Sentinel-2, que orbitam o planeta e coletam informações espaciais e temporais da superfície terrestre, obtidas a partir da energia refletida pela Terra (BROVELLI et al., 2020; TEIXEIRA et al., 2020; FERREIRA et al., 2020; PIMENTA et al., 2021).

Historicamente, as pesquisas científicas voltadas ao sensoriamento remoto têm se concentrado na estimativa de índices de multiespectrais, que são calculados a partir de duas ou mais bandas espectrais, e são importantes para distinguir características da paisagem como vegetação, corpos hídricos ou áreas impermeáveis enquanto minimizam os efeitos de iluminação e sombras (SOUZA et al., 2020, PAREKH et al., 2021). Os índices de multiespectrais são produtos de dados robustos e contínuos calculados de forma semelhante em todos os pixels no tempo e no espaço, independentemente do tipo de bioma, condição de

cobertura da terra e tipo de solo e, portanto, representam verdadeiras medições de superfície (HUETE et al., 2011).

Os índices multiespectrais são comumente usados para estimar parâmetros biofísicos, visando o monitoramento das mudanças sazonais e interanuais da superfície terrestre, sejam elas de origem natural ou antrópica. Entre os diferentes índices espectrais que podem ser aplicados para o monitoramento das variações da cobertura da terra, da vitalidade e densidade da vegetação o índice de vegetação por diferença normalizada (*Normalized Difference Vegetation Index* – NDVI) (HUETE, 1988; ALLEN et al., 2002) é atualmente um dos mais difundidos na literatura mundial, principalmente no semiárido brasileiro, juntamente com o *leaf area index* – LAI (ALLEN et al., 2002; ALLEN et al., 2007), que podem ser obtidos utilizando as faixas do vermelho visível (Red) e do infravermelho próximo (NIR).

O NDVI, especificamente, foi dos primeiros indicadores, baseado em sensoriamento remoto, utilizado para a identificação e monitoramento de regiões afetadas pela seca nas escalas regional e global, uma vez que a sazonalidade da vegetação é fortemente associada ao regime de precipitação local (CUNHA et al., 2015). Segundo Ghulam et al. (2007), os índices espectrais apresentam algumas vantagens sobre os índices relacionados a dados climáticos, visto que cobrem grandes áreas e podem mostrar, por exemplo, como a seca está progredindo em uma determinada região.

Um terceiro índice espectral é o índice de água por diferença normalizada (*Normalized Difference Water Index* – NDWI) (MCFEETERS, 1996) que se destaca por capturar características sutis da água de forma mais estável e tem sido usado para caracterizar a condição hídrica da superfície terrestre, fazendo uso da radiação refletida nas faixas do verde (Green) e do infravermelho (NIR), uma vez que o verde discrimina melhor os pixels de água (GAO, 1996). De acordo com Ahmed; Akter, (2017) e Gao (1996), o NDWI é um bom indicador das mudanças na cobertura vegetal e é menos sensível aos efeitos atmosféricos do que o NDVI. Contudo, o NDWI não remove completamente os efeitos de reflectância do solo de fundo, semelhante ao NDVI.

O NDWI é um dos índices hídricos mais recomendados para aplicações ambientais em regiões semiáridas, incluindo mapeamento de águas superficiais, análises de mudanças de uso/cobertura da terra, alternâncias na umidade do solo e susceptibilidade à desertificação em áreas degradadas (MARTINS et al., 2018b; SILVA et al., 2019a, 2019b) e, tem sido testado como um indicador de seca (GU et al., 2008). Gu et al. (2007, 2008) descobriram que os valores de NDWI exibiram uma resposta mais rápida às condições de seca do que o NDVI.

Ao contrário do NDWI, o NDVI tem capacidade limitada para recuperar informações sobre o conteúdo de água da vegetação, uma vez que fornece informações sobre o verde da vegetação (clorofila), que não está diretamente relacionada à quantidade de água na vegetação (AHMED; AKTER, 2017; ASHOK; RANI; JAYAKUMAR, 2021; CECCATO et al., 2002).

Vale a pena mencionar aqui que Gao (1996) também desenvolveu um índice de umidade de diferença normalizada (*Normalized Difference Moisture Index* – NDMI) combinando as bandas espectrais do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR). Notavelmente, foi demonstrado o NDMI é indicador confiável do conteúdo de água da vegetação e pode ser utilizado no monitoramento ambiental para detectar a condição de umidade da vegetação, principalmente em áreas onde as condições de seca é uma preocupação. Além disso, o NDMI é mais sensível ao início do estresse hídrico em comparação com o NDVI (GAZNAYEE et al., 2023; GHAZARYAN et al., 2020; WILSON; SADER, 2002).

As bandas NIR e SWIR foram selecionadas para a equação de banda NDMI para mitigar os efeitos da iluminação e da atmosfera. A combinação do NIR com o SWIR remove as variações induzidas pela estrutura interna da folha e pelo teor de matéria seca da folha, melhorando a precisão na recuperação do teor de água da vegetação. A região do NIR (0,7-1  $\mu\text{m}$ ) apresenta bom contraste entre solo e corpos d'água, permitindo o mapeamento de corpos hídricos e áreas úmidas, ressaltasse que nessa região a absorção da água é geralmente baixa. Por outro lado, a região SWIR (1-3  $\mu\text{m}$ ) é sensível ao teor de água da folha devido à absorção da energia eletromagnética neste comprimento de onda. A reflectância SWIR geralmente diminui à medida que o conteúdo de água nas folhas (JI et al., 2011; WILSON; SADER, 2002; GAO, 1996).

Além da estimativas de índices multiespectrais, a estimativa, por sensoriamento remoto, de parâmetros biofísicos como temperatura da superfície pode funcionar como indicadores dos impactos das ações antrópicas sobre o ecossistema e das mudanças climáticas, tendo em vista que a temperatura pode ser correlacionada com os diferentes índices de vegetação, ao passo que são parâmetros essenciais na regulação dos processos físicos, químicos e biológicos, e estão envolvidos diretamente nos processos de troca de energia entre a superfície terrestre e atmosfera, o que os tornam componentes do saldo de radiação à superfície, e conseqüentemente do balanço de energia (CHANG et al., 2017; DOS SANTOS et al., 2020a; LEE; KIM, 2016; TEIXEIRA et al., 2017).

A temperatura da superfície da terra está entre os parâmetros mais importantes no monitoramento dos processos físico-químicos da superfície da terra em escalas regionais e globais, sendo uma métrica representativa das interações superfície-atmosfera e fluxos

turbulentos de calor entre a atmosfera e a superfície do solo (LI et al., 2013; WAN, 2008). E é atualmente amplamente utilizada nas áreas de solos, hidrologia, biologia e geoquímica. Além de ser um dos principais indicadores das mudanças da cobertura e uso da terra (DENG et al., 2018; HAO; LI; DENG, 2016).

Com os avanços na tecnologia de sensoriamento remoto, os dados de satélite possibilitam mapear a temperatura da superfície da terra em todo o globo de forma eficaz, com resolução espacial e temporal suficientemente alta, a partir das bandas térmicas de vários sensores de satélite, como MODIS, AVHRR, VIIRS, TM, ETM + e TIRS (LI et al., 2013; LONG et al., 2020; CHANDRA et al., 2021). Assim o monitoramento espaço-temporal da temperatura da superfície da terra desempenha um papel essencial em vários campos, como monitoramento da umidade do solo para gestão de recursos hídricos agrícolas, evapotranspiração, avaliação da seca, mudanças climáticas e ciclo hidrológico (CUI et al., 2020; JABER; ABU-ALLABAN, 2020; LU et al., 2020).

Nesse contexto, torna-se necessário realizar também um monitoramento espaço-temporal de componentes do ciclo hidrológico, em específico, a precipitação (XAVIER JR et al., 2019). Visto que, cruzar as informações das condições físico-hídricas com as informações dos parâmetros biofísicos pode auxiliar na compreensão e avaliação dos impactos ambientais na dinâmica espaço-temporal da vegetação, em especial a vegetação do bioma Caatinga (BARBOSA et al., 2018; CUNHA et al., 2015; FERREIRA et al., 2020; RODRIGUES et al., 2020a; SANTOS et al., 2020; TEIXEIRA et al., 2021a).

## **2.6. Sensor MODIS**

Com os avanços recentes na tecnologia de sensoriamento remoto, o *Moderate Resolution Imaging Spectroradiometer* (MODIS) se tornou a principal fonte de dados para pesquisa em grande escala nos mais diversos ecossistemas do planeta Terra, devido às suas características vantajosas, como alta qualidade, ampla cobertura de área, alta resolução temporal e acessibilidade (ANYAMBA; TUCKER, 2005; KANG et al., 2021). O sensor MODIS está operando a bordo dos satélites Terra (originalmente conhecido como EOS AM-1) e Aqua (originalmente conhecido como EOS PM-1), ambos pertencem ao programa de pesquisas de observação espacial do Earth Observing System (EOS), financiado pela NASA Earth Science Enterprises (ESE) (NASA/MODIS, 2021; NASA/USGS, 2021)

Lançado em 18 de dezembro de 1999, o satélite Terra foi o primeiro grande satélite EOS multi-sensor, e sua órbita ao redor da Terra é cronometrada para que passe de norte a sul através



do equador durante a manhã. Por sua vez, satélite Aqua lançado em 4 de maio de 2002, percorre sua órbita de sul para norte ao longo do equador no período da tarde. Esse trabalho em conjunto permite visualizar a mesma área do globo pela manhã e tarde, o que garante maior precisão das medições do MODIS e otimiza o sensoriamento remoto sem nuvens da superfície, além de minimizar quaisquer efeitos ópticos - como sombras ou reflexos (LINDSEY et al., 2020).

O sensor MODIS apresenta um padrão de varredura de  $\pm 55$  graus, com uma altitude padrão de 705 km, onde atinge uma faixa de visualização de 2330 km (Quadro 1), e fornece cobertura global a cada um ou dois dias. Além de apresentar alta resolução radiométrica (12 bits) e oferecer 36 bandas espectrais, ou grupos de comprimento de ondas, variando de 0,405 a 14,385  $\mu\text{m}$ . Ele coleta dados em três resoluções espaciais: 250, 500 e 1000 metros (Quadro 1) - (JUSTICE et al., 2002; NASA/MODIS, 2021; NASA/USGS, 2021)

Quadro 1 - Especificações técnicas do sensor MODIS.

<b>Órbita</b>	Heliosíncrona, polar, 705 km; 10h30min a.m. descendente; 1h30min p.m. ascendente
<b>Alcance Espectral</b>	0,4-14,4 $\mu\text{m}$
<b>Cobertura Espectral</b>	+/- 55°, 2330 km em fileira (“scans” contínuos em nadir no Equador)
<b>Resolução Espacial</b>	250 m (1-2 bandas), 500 m (3-7 bandas), 1000 m (8-36 bandas) em nadir
<b>Precisão Radiométrica</b>	5% absoluto, < 3 $\mu\text{m}$ ; 1% absoluto > 3 $\mu\text{m}$ ; 2% de reflectância
<b>Cobertura de repetição</b>	Diária, a norte da latitude 30° e a cada dois dias, para latitudes inferiores a 30°
<b>Quantização</b>	12 bits
<b>Taxa de Dados</b>	6.2 Mbps (média), 10,8 Mbps (dia), 2,5 Mbps (noite)
<b>Força</b>	162,5 W (média para uma órbita), 168,5 W (pico)

Fonte: NASA (2020).

O monitoramento espaço-temporal pelo sensor MODIS produz dados pré-processados de imagens atmosféricas, terrestres e oceânicas, permitindo avaliar condições climáticas/ambientais em escala regional e global, destacando os estudos sobre as mudanças climáticas do planeta Terra e as consequências dos efeitos das atividades antrópicas ao meio ambiente. Vale ressaltar que os dados orbitais do sensor MODIS são georreferenciados e corrigidos para os principais efeitos atmosféricos, como nuvens e aerossóis, entre outros (JUSTICE et al., 2002; NASA/MODIS, 2021; NASA/USGS, 2021). O Quadro 2 apresenta as características das bandas multiespectrais do sensor MODIS.

Quadro 2 - Especificações das bandas espectrais do sensor MODIS.

Uso Primário	Banda	Largura de Banda <sup>1</sup>	Radiância Espectral <sup>2</sup>	SNR <sup>3</sup>
Superfície Terrestre/Nuvem	1	620-670	21,8	128
	2	841-875	24,7	201
Propriedades da Superfície/Nuvem	3	459-479	35,5	243
	4	545-565	29,0	228
	5	1230-1250	5,4	74
	6	1628-1652	7,3	275
	7	2105-215	1,0	110
Cor dos Oceanos/Fitoplâncton/ Bioquímica	8	405-420	44,9	880
	9	438-448	41,9	838
	10	483-493	32,1	802
	11	526-536	27,9	754
	12	546-556	21,0	750
	13	662-672	9,5	910
	14	673-683	8,7	1087
	15	743-753	10,2	586
Vapor d'água Atmosférico	16	862-877	6,2	516
	17	890-920	10,0	167
	18	931-941	3,6	57
	19	915-965	15,0	250
Uso Primário	Banda	Largura de Banda <sup>1</sup>	Radiância Espectral <sup>2</sup>	NEΔT(K) <sup>4</sup>
Temperatura nuvens/Superfície	20	3,660-3,840	0,45(300K)	0,05
	21	3,929-3,989	2,38(335K)	2,00
	22	3,929-3,989	0,67(300K)	0,07
	23	4,020-4,080	0,79(300K)	0,07
Temperatura Atmosférica	24	4,433-4,498	0,17(250K)	0,25
	25	4,482-4,549	0,59(275K)	0,25
Nuvens Cirrus	26	1,360-1,390	6,00	150(SNR)
Vapor d'água	27	6,535-6,895	1,16(240K)	0,25
	28	7,175-7,475	2,18(250K)	0,25
	29	8,400-8,700	9,58(300K)	0,05
Ozônio	30	9,580-9,880	3,69(300K)	0,25
Temperatura Nuvens/Superfície	31	10,780-11,280	9,55(300K)	0,05
	32	11,770-12,270	8,94(300K)	0,05
Altitude Topo da Nuvem	33	13,185-13,485	4,52(260K)	0,25
	34	13,485-13,785	3,76(250K)	0,25
	35	13,785-14,085	3,11(240K)	0,25
	36	14,085-14,385	2,08(220K)	0,35

<sup>1</sup>Bandas 1-19, em nm; Bandas 20-36, em  $\mu\text{m}$ , <sup>2</sup>( $\text{W m}^{-2} \mu\text{m}^{-1} \text{sr}^{-1}$ ), <sup>3</sup>SNR=Signal-to-noise ratio, <sup>4</sup>NEΔT=Noise-equivalent temperature difference

Fonte: NASA (2020).

Usando algoritmos com base física e empírica, os computadores de alta velocidade processam dados MODIS para produzir 44 produtos de dados globais que descrevem muitos dos sinais vitais da Terra, desde a temperatura do oceano e da superfície da terra até as propriedades físicas das nuvens (JUSTICE et al., 2002; NASA/MODIS, 2021; NASA/USGS, 2021). Alguns produtos fazem uma composição de 8 (oito) e 16 (dezesseis) dias, outros mensais e anuais, a depender do produto e nível de processamento, sendo essa composição feita a partir

da menor cobertura de nuvens possível, baixo ângulo de visada e o maior valor (DIDAN et al., 2015). O Quadro 3 apresenta alguns dos produtos derivados Sensor MODIS para a superfície Terrestre.

Quadro 3 - Produtos do Sensor MODIS para a superfície Terrestre.

Terra	
MOD09/MYD09	Reflectância da Superfície
MOD11/MYD11	Temperatura e Emissividade da superfície terrestre
MOD21/MYD21	Emissividade da Superfície Terrestre
MCD12	Cobertura da Terra/Mudança da Cobertura da terra
MOD13/MYD13	Índices de Vegetação (NDVI e EVI)
MOD14/MYD14	Anomalias termais, fogos e queimadas
MOD15MYD15	Índice de área foliar e FPAR
MOD16/MYD16	Evapotranspiração
MOD17/MYD17	Fotossíntese líquida e Produtividade primária
MCD43	Distribuição Bidirecional de Refletância Função e Albedo
MOD44B	Campo de Vegetação Contínua
MDC46	Área Queimada
MOD44W	Máscara de Água

Fonte: NASA (2020).

Os sensores MODIS a bordo do Terra e Aqua iniciarão coletas de dados de longo prazo necessária para monitorar e compreender as mudanças que ocorrem no planeta Terra. Visto que, algumas dessas mudanças acontecem rapidamente e são imediatamente reconhecíveis, mas muitos processos que moldam a Terra e seu clima acontecem de forma lenta, imperceptíveis a curto prazo. Algumas das mudanças mais facilmente reconhecíveis estão ocorrendo em terra. Mudanças induzidas pelo homem, como desmatamento, urbanização e projetos hidrelétricos e de irrigação, que combinados com os ciclos de incêndio, erosão e inundações alteram a paisagem da Terra. Deste modo, monitorar e avaliar as condições na superfície da Terra é fundamental para compreender os impactos do tempo e das mudanças climáticas e das atividades humanas (LINDSEY et al., 2020).

## 2.7. Plataforma Google Earth Engine

O uso de imagens temporais de satélites para identificar tendências e mudanças no uso e cobertura da terra pode ser computacionalmente intensivo se uma área de estudo for relativamente grande e se forem adotadas abordagens de mapeamento convencionais (por exemplo, download de imagens e seu processamento em desktops). Por exemplo, uma única cena Landsat 8 descompactada é maior que 1,6 gigabytes e, portanto, o número total de imagens de satélites a serem analisadas torna-se limitado, devido à grande demanda de recurso

computacionais. Além disso, o processamento digital de imagens orbitais de satélites a partir de softwares com base em algoritmos requerer um conhecimento prévio adequado sobre, por exemplo, modelos de correção atmosférica e principalmente especialização técnica e vasto conhecimento sobre o uso de diferentes tipos de softwares (GORELICK et al., 2017; KC et al., 2021; TAMIMINIA et al., 2020; XULU; MBATHA; PEERBHAY, 2021).

Para superar alguns desses desafios, plataformas baseadas em nuvem para análise geoespacial em escala planetária foram desenvolvidas. Dentre essas plataformas desenvolvidas, o *Google Earth Engine* (GEE), tem servido como uma nova ferramenta tecnológica para a realização de estudos inovadores a partir do fornecimento de um volume sem precedentes de dados geoespaciais, disponíveis gratuitamente, associados aos sistemas globais de dados orbitais de satélites, incluindo observações de uma variedade de sistemas de imagens aéreas e de satélite (por exemplo, MODIS, Landsat, Sentinel) em comprimentos de onda ópticos e não ópticos, variáveis ambientais, previsões meteorológicas e climáticas, cobertura da terra, topografia e conjuntos de dados socioeconômicos. Ao armazenar e processar imagens em vários servidores remotos, o GEE elimina a necessidade de baixar e processar dados em computadores autônomos locais (GORELICK et al., 2017; KC et al., 2021; LUO et al., 2021).

O GEE traz os enormes recursos computacionais do Google para lidar com uma variedade de questões socioambientais de alto impacto, incluindo mudanças no uso e cobertura global da terra, desmatamento, eventos severos de seca, queimadas, desastres ambientais, doenças, segurança alimentar, gestão dos recursos hídricos, monitoramento do clima e proteção ambiental. Vale destacar, a plataforma não se limita apenas aos profissionais específicos da área de sensoriamento remoto, pois os demais públicos de diferentes campos de atuação são convidados a interagirem aplicando e gerando conhecimento numa escala planetária sobre diferentes temas transversais. Deste modo, o Earth Engine ajuda os pesquisadores a disseminar facilmente seus resultados para outros pesquisadores, formuladores de políticas, ONGs, trabalhadores de campo e até mesmo o público em geral (GORELICK et al., 2017; JIANG et al., 2021).

Com uma interface de programação de aplicativos acessível pela Internet e um ambiente de desenvolvimento interativo baseado na web, o GEE permite que o pesquisador desenvolva seu próprio script de programação/manipulação de dados para a geração de modelos, utilizando algoritmos de aprendizado de máquina, disponíveis tanto para a linguagem de programação JavaScript quanto para a linguagem Python, sem a necessidade de ser um especialista em desenvolvimento de aplicativos, programação da web ou HTML (GORELICK et al., 2017; TAMIMINIA et al., 2020).

Estudos recentes exploraram e demonstraram a utilidade do GEE, como pré-processamento e automatização de procedimentos de classificação de imagens de satélite usando processamento paralelo (LI et al., 2020; JIANG et al., 2021), mapeamento de atividades agropecuárias e a saúde da vegetação em escalas regionais (PARENTE; FERREIRA, 2018; PARENTE et al., 2019; SARAIVA et al., 2020; PIMENTA et al., 2021) e globais (CAMPOS-TABERNER et al., 2018; TRAGANOS et al., 2018), quantificação de áreas urbanas globais (YANG et al., 2018; CARNEIRO et al., 2021), monitoramento de águas superficiais (DENG et al., 2019; LI et al., 2020; WANG et al., 2020), mapeamento de vegetação e mapeamento das alterações do uso e ocupação da terra (ROITMAN et al., 2018; DINIZ et al., 2019; SOUZA et al., 2020; L.S.ARRUDA et al., 2021; ROSA et al., 2021; LUO et al., 2021).

### **3 MATERIAL E MÉTODOS**

#### **3.1 Área de estudo**

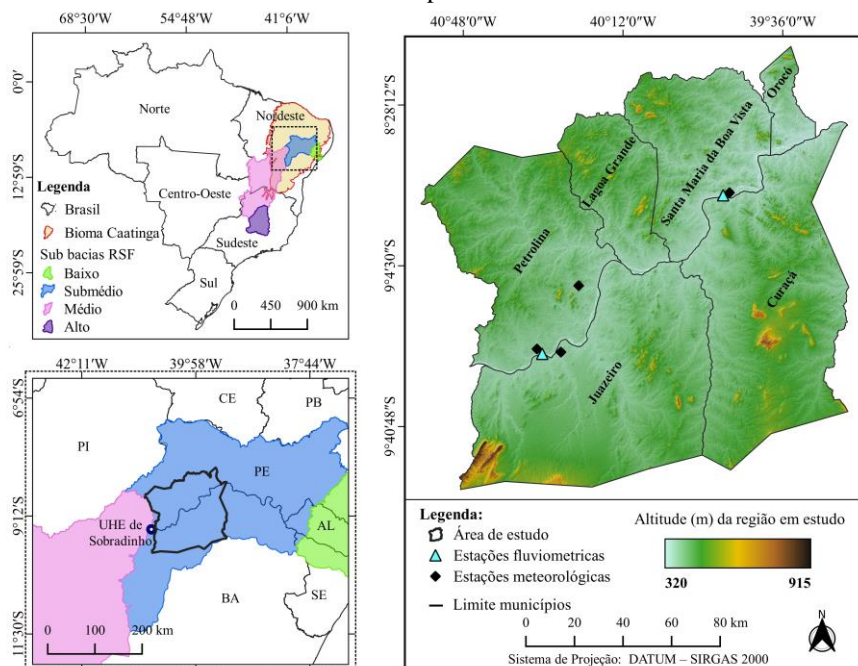
A área de estudo está localizada na Bacia Hidrográfica do Submédio São Francisco, centro de uma importante região agrícola que tem experimentado grande crescimento devido ao desenvolvimento da agricultura irrigada para exportação de frutas (TEIXEIRA et al., 2015); contendo porção dos municípios de Petrolina, Lagoa Grande, Santa Maria da Boa Vista e Orocó pertencentes ao estado de Pernambuco (PE); e Juazeiro e Curaçá pertencentes ao estado da Bahia (BA). Medindo 8,25° S a 9,92° S em latitude e 39,36° W a 40,96° W em longitude, com extensão territorial de 22.546,35 km<sup>2</sup> (Figura 3).

Nas últimas décadas, a Bacia do Submédio Rio São Francisco tem sido impactada por uma quantidade significativa de mudanças de origem antrópica, como o represamento de suas águas a partir da construção do reservatório de Sobradinho que, provocou impactos na quantidade e qualidade da água, principalmente em períodos de seca como os observados entre os anos de 2012 e 2017 (JONG et al., 2018). Além disso, estimulou mudanças no uso e ocupação da terra, levando a múltiplos programas de irrigação e desenvolvimento agrícola na região, elevando o crescimento econômico e a pressão sobre os recursos naturais (CUNHA et al., 2015; FERREIRA et al., 2020).

Por outro lado, a ausência de cobertura vegetal, como consequência da substituição de áreas de paisagem natural por agricultura, pecuária e desenvolvimento urbano, ocasionou o carreamento de sedimentos do solo desprotegido para dentro das calhas dos afluentes e do rio

São Francisco, agravando o assoreamento do rio. A cobertura do solo na região é predominantemente composta por formações de vegetação de caatinga, pastagens e áreas agrícolas (Figura 3).

Figura 3 - Localização da bacia do Rio São Francisco no Brasil, suas sub-bacias, e o Bioma Caatinga de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE - <https://ibge.gov.br>), juntamente com a Usina Hidrelétrica (UHE) de Sobradinho. E o mapa hipsométrico, com as estações meteorológicas e fluviométricas utilizadas no presente estudo.



Fonte: Autor, 2023.

Conforme a classificação climática de Köppen-Geiger o clima da região em estudo da BSF é do tipo “BSh”, semiárido quente (ALVARES et al., 2013). A temperatura máxima do ar varia de 29,7 °C (julho) a 34,2 °C (novembro), com média anual de 32,3 °C; e a temperatura mínima do ar varia de 20,0 °C (julho) a 23,5 °C (dezembro) com média anual de 22,2 °C; a precipitação média mensal varia de 1,4 mm (agosto) a 114,1 mm (março); a maior parte (70,4%) cai entre janeiro e abril, com precipitação anual de 482,6 mm ( FERREIRA et al., 2020).

Mesmo com os baixos volumes e má distribuição das chuvas, o abastecimento de água da região não é significativamente prejudicado, visto que o fornecimento de quase 70% das águas é oriundo do Alto São Francisco e Médio São Francisco, o qual permite o desenvolvimento da fruticultura local através da irrigação, mesmo em períodos de seca (MEDEIROS et al., 2015; CASTRO; PEREIRA, 2019).

Pertencente ao polígono de secas do nordeste brasileiro, a região em estudo é caracterizada por verão quente e inverno ameno com períodos de seca prolongados, o regime

de chuva na região é irregular ao longo do ano, decorrente de sua localização geográfica com extensos terrenos cristalinos, eventos cíclicos de El Niño e a influência da Zona de Convergência Intertropical (ZCIT) (MARENGO et al., 2017; OLIVEIRA et al., 2017). Os solos predominantes na região são Argissolos, Latossolos, Luvisolos, Planossolos e Vertissolos (SANTOS et al., 2011), com relevo suavemente ondulado e altitude entre 333 m e 693 m.

As variações climáticas e ambientais, sobretudo, a intensidade e regularidade de chuvas da região em estudo se refletem na cobertura vegetal, assim como, as configurações geológicas e propriedades do solo (AZEVEDO et al., 2018; SILVA et al., 2020c). O bioma Caatinga apresenta diferentes mosaicos florísticos, constituídos por vegetação arbórea ou arbustiva, compreendendo principalmente árvores e arbustos baixos, muitos dos quais com espinhos, microfilas e algumas feições xerofíticas, além de áreas abertas (BARBOSA et al., 2018). O recobrimento do dossel das espécies do bioma Caatinga apresentam características descontínuas, caracterizado pela queda de folhas na estação seca (agosto a novembro) e com expressiva produção de biomassa na estação chuvosa (TEIXEIRA et al., 2009; SANTOS et al., 2017).

## **3.2. Conjunto de dados**

### **3.2.1 Dados meteorológicos e fluviométricos**

Os dados mensais de precipitação e temperatura do ar utilizados neste estudo foram obtidos de quatro estações meteorológicas pertencentes ao Instituto Nacional de Meteorologia (INMET - <https://portal.inmet.gov.br>), a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA - <https://www.embrapa.br/semiárido>) e a Companhia Hidrelétrica do São Francisco (CHESF - <https://www.chesf.com.br>), localizadas nos municípios de Petrolina-PE (duas estações, INMET e EMBRAPA Semiárido), Santa Maria da Boa Vista-PE (uma estação, CHESF) e Juazeiro-BA (uma estação, EMBRAPA Semiárido), para o período de 1991 a 2020 (Figuras 3).

As séries temporais das vazões médias mensais foram obtidas de estações fluviométricas da Agência Nacional de Águas e Saneamento Básico (ANA - [snirh.gov.br/hidroweb](http://snirh.gov.br/hidroweb)), localizadas nos municípios de Juazeiro (BA) e Santa Maria da Boa Vista (PE) (Figura 3). Vale destacar que com o objetivo de trazer maior robustez para as análises de tendência e estimativas dos índices SPI e SSI e melhor compreender a influência climática na região em estudo, buscou-

se trabalhar com uma série de dados de 30 anos compreendendo o período de janeiro de 1991 a dezembro de 2020.

### **3.2.2 Dados derivados de satélites Landsat (Uso e ocupação da terra)**

Os dados de uso e cobertura da terra foram obtidos da plataforma MapBiomas Brasil, referente a coleção 6 (Projeto MapBiomas, 2021), que usa procedimentos de classificação automática aplicados a imagens de satélite para gerar dados de cobertura e uso da terra. Esta coleção apresenta alta confiabilidade e inclui dados anuais de cobertura e uso da terra. Na região em estudo verifica-se a ocorrência das seguintes classes: Caatinga (arbórea, arbustiva e herbácea), agricultura, pastagem, mosaico de agricultura e pastagem, área não vegetada e corpos d'água (FENDRICH et al., 2020; PÉREZ-HOYOS et al., 2017).

Ainda seguindo a metodologia aplicada pelo MAPBIOMAS a Caatinga pode ser classificada em dois tipos: (1) Caatinga densa (arbórea, arbustiva), que tem uma cobertura lenhosa de aproximadamente 60–80%; e (2) a Caatinga aberta (herbácea), que se caracteriza por estar em diferentes estágios de desenvolvimento, apresentando gramíneas e áreas abandonadas, e possui uma cobertura lenhosa de aproximadamente 20 a 60% (ROMAN, 2017; SALAZAR et al., 2021; MAPBIOMAS, 2022). Vale ressaltar que, mosaico de agricultura e pastagem é uma classe composta por áreas de uso agropecuário onde não foi possível distinguir entre pastagem e agricultura não irrigada (MAPBIOMAS, 2022).

Neste estudo, as classes Caatinga herbácea, pastagem e mosaico agricultura pastagem foram agrupadas em uma única classe renomeada de formação vegetal não florestal. Com o intuito de minimizar os efeitos de confusão espectral existentes, uma vez que na região em estudo essas classes apresentam forte influência de atividades antrópicas e do clima que degradam o extrato vegetal, fator que promove coberturas vegetais com respostas espectrais semelhantes. Deste modo, o estudo foi realizado baseado nas seguintes classes de uso e cobertura da terra: Caatinga densa (arbórea e arbustiva), formação vegetal não florestal (Caatinga herbácea, pastagem e mosaico de agricultura e pastagem), agricultura, área não vegetada (infraestrutura urbana e solo exposto) e corpos hídricos. Neste estudo, os dados de uso e cobertura da terra foram estudados de 2001 a 2020.

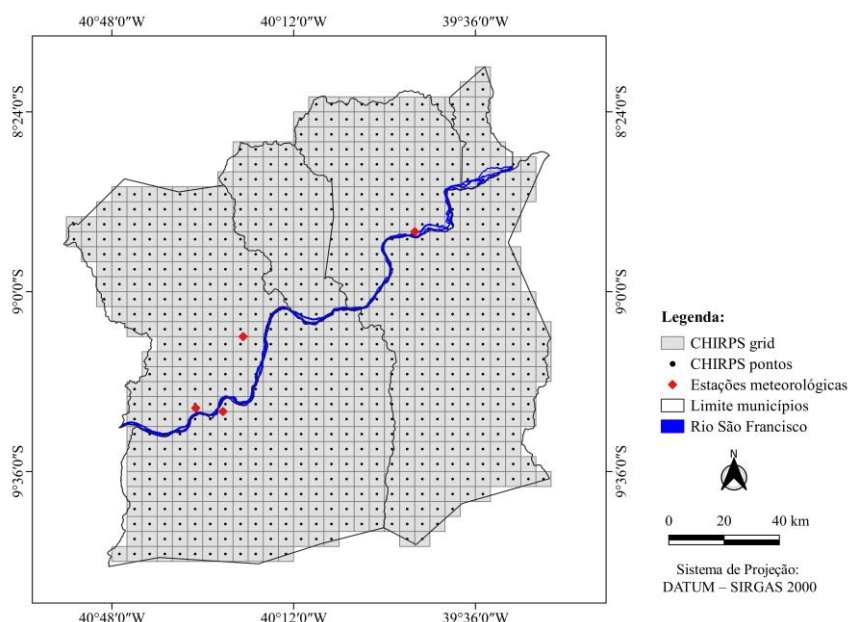


### 3.2.3 Precipitação CHIRPS

Nesse estudo, dados *in situ* são escassos, pois a área em estudo apresenta uma rede grosseira de dados pluviométricos (baixa disponibilidade e distribuída irregularmente no espaço), condição que pode enviesar a estimativa dos impactos da seca sobre a vegetação, uma vez que as características locais da seca não podem ser generalizadas. Contudo, reanálises e técnicas baseadas em satélite podem fornecer dados hidrometeorológicos contínuos, desta maneira cada série temporal de pixels do mapa de precipitação pode ser considerada como uma "estação meteorológica virtual" para os dados em questão (GARCÍA-LEÓN; CONTRERAS; HUNINK, 2019; PAREDES-TREJO et al., 2021).

Assim, os somatórios de precipitação correspondentes às escalas diárias, mensais e anuais foram obtidos com base nos dados de precipitação diária do produto CHIRPS (Climate Hazards Group InfraRed Precipitation with Station). O CHIRPS é um conjunto de dados observacionais diários de precipitação de última geração que usa dados de satélite infravermelho, com resolução espacial de  $0,05^\circ \times 0,05^\circ$  ( $\pm 5,3$  km) e está disponível a partir de 1981 (FUNK et al., 2015).

Figura 4 - Grade CHIRPS da área de estudo incluindo a os municípios do vale do Submédio São Francisco.



Fonte: Autor, 2023.

O conjunto de dados CHIRPS utilizado neste estudo corresponde a um período de 30 anos de observações, iniciando-se em janeiro 1991 até dezembro de 2020. Esses dados foram

extraídos na plataforma Google Earth Engine (<https://earthengine.google.com/>) usando linguagem de programação em JavaScript, e usando o conjunto de dados da coleção `ee.ImageCollection("UCSB-CHG/CHIRPS/DAILY")`.

O método estatístico responsável pela caracterização da distribuição espacial da precipitação sobre a região em estudo e sua influência na cobertura vegetal foi o interpolador espacial estatístico Krigagem Ordinária (SABAREESHWARI et al., 2021), baseado em modelos estatísticos de autocorrelação entre os pontos amostrados, que são um total de 1157 pixels de estimativa explicando, assim, a variação espacial dos dados a partir de técnicas de média ponderada (Figura 4).


### **3.2.4 Dados orbitais do sensor MODIS do satélite Terra**

No presente estudo, serão determinados os parâmetros NDVI, LAI, NDMI e LST no período de 1 de janeiro de 2001 a 31 de dezembro de 2020, a partir de imagens orbitais pertencentes ao sensor MODIS, a bordo do satélite Terra (MOD) - (<https://modis.gsfc.nasa.gov/>), contidas nos quadrantes h14v09 e h14v10 (1.200 por 1.200 km). O processamento das imagens será realizado por meio da plataforma digital em nuvem do *Google Earth Engine* (<https://earthengine.google.com/>), ambiente que comporta diferentes coleções de imagens de satélites e apresenta alta capacidade de processamento de dados com múltiplas funções de análises matemáticas/estatísticas e modelagem computacional, que permitem o processamento de imagens de satélites e cálculo de diferentes parâmetros biofísicos à superfície, a partir de algoritmos específicos.

Ressalta-se que, os produtos MODIS contêm sinalizadores de controle de qualidade que contêm informações sobre a utilidade do pixel, o que exclui pixels ruins com nuvens e sombras, eliminando as contaminações de ruído causadas por estes (SAJADI et al., 2021). O índice de utilidade será aplicado para que pixels de “boa” qualidade (com base na banda QA) sejam selecionados e o restante seja excluído.

Após o tratamento dos produtos MODIS, foram geradas imagens representativas dos parâmetros biofísicos em escala anual, a partir de uma redução baseada no pixel médio de cada índice biofísico ao longo da série temporal, que compreende um processamento digital sobre todas as imagens orbitais com resolução temporal de 8 dias ao longo de cada ano, onde obtém-se uma imagem com valor médio de cada pixel para o período de avaliação (ano) – (Figura 5). Esse procedimento, possibilitou realizar uma avaliação espaço-temporal das mudanças e do comportamento de todos os parâmetros biofísicos à superfície.

Figura 5 - Funcionamento da redução da coleção de imagens em uma única imagem.



Fonte: Google Earth Engine

Para a geração dos parâmetros biofísicos foi necessário criar as funções para cálculo de novas bandas NDVI, LAI, NDMI e LST conforme metodologia abaixo. Os produtos MODIS escolhidos para execução dessa etapa foram: Refletância da Superfície da Terra 8 dias L3 global 500 m (MOD09A1 v006), sendo utilizadas as sete bandas de refletância de 500 m para obtenção dos índices de vegetação (Tabela 1); e Temperatura da Superfície Terrestre/Emissividade 8 dias L3 global 1 km (MOD11A2 v006), que possui 1 km de resolução espectral, sendo utilizada a temperatura da superfície (K), o horário local e as emissividades das bandas 31 e 32 (Tabela 2).

Tabela 1 - Características do produto do sensor MODIS, refletância da superfície.

Produto do sensor MODIS					
Refletância da superfície – Terra (MOD09A1), Versão 6					
Banda multiespectral	Resolução temporal	Resolução espacial	Resolução radiométrica	Nível de processamento	Fator multiplicador
r <sub>1</sub> (0,620 – 0,670 μm)					
r <sub>2</sub> (0,841 – 0,876 μm)					
r <sub>3</sub> (0,459 – 0,479 μm)					
r <sub>4</sub> (0,545 – 0,565 μm)	8 dias	500 m	16 bits	L3	0,0001
r <sub>5</sub> (1,230 – 1,250 μm)					
r <sub>6</sub> (1,628 – 1,652 μm)					
r <sub>7</sub> (2,105 – 2,155 μm)					

Fonte: Adaptado de Vermote et al. (2015) e NASA/MODIS (2021).

Os produtos MOD11A2 e MOD09A1 são composições de 8 dias. Desse modo, para a aplicação adequada e utilização eficaz das imagens do sensor MODIS na plataforma *Google Earth Engine*, esse produto é corrigido/calibrado, por meio de fatores de correção – multiplicador e adicional – referente à cada camada, de forma a gerar uma imagem com valores reais. Vale destacar que o nível de processamento L3 apresenta variáveis em grades uniformes em diversas resoluções espaciais e temporais (Tabelas 1 e 2).

O produto da refletância do sensor MODIS (Terra – MOD09A1, versão 6) fornece uma estimativa da refletância espectral de superfície das bandas multiespectrais de 1 a 7, as quais são corrigidas para as condições atmosféricas, como gases, aerossóis e espalhamento de Rayleigh. O produto MOD09A1 é composto por valores pixel a pixel referentes a um período de 8 dias, tal qual é escolhido um valor base para cada banda que contém a melhor observação durante esse período, valor este relacionado às melhores condições de correção atmosférica bem como à ausência e/ou sombra de nuvens (VERMOTE et al., 2015).

Tabela 2 - Características do produto do sensor MODIS, temperatura da superfície.

<b>Produto do sensor MODIS</b>					
<b>Temperatura da superfície – Terra (MOD11A2) Versão 6</b>					
<b>Camada</b>	<b>Resolução temporal</b>	<b>Resolução espacial</b>	<b>Resolução radiométrica</b>	<b>Nível de processamento</b>	<b>Fator multiplicador/adicional</b>
LST_Day_1km			16 bits		0,02 /0,0
Hora local do dia					0,1 /0,0
Emissividade da banda 31	8 dias	1000 m	8 bits	L3	0,002 /0,49
Emissividade da banda 32					0,002 /0,49

Fonte: Adaptado de NASA/MODIS (2021).

O produto da temperatura da superfície do sensor MODIS (MOD11A2) é estimado a partir das emissividades das bandas 31 e 32, que, por sua vez, são obtidas a partir da modelagem matemática em função dos tipos de cobertura e uso da terra, pixel a pixel da imagem, que fornece uma estimativa média de temperatura da superfície composta por valores referentes a um período de 8 dias (WAN, 2008)

### 3.3 Índices de Seca

#### 3.3.1 Standard Precipitation Index (SPI)

O método SPI foi utilizado neste trabalho para analisar a ocorrência, intensidade e duração das secas meteorológicas, usando dados do produto CHIRPS para cada ponto da grade que cobre a região em estudo (1157 séries temporais), uma vez que, esse produto apresenta-se como uma rede espacial e temporalmente robusta de dados confiáveis de precipitação. O SPI foi desenvolvido por McKee et al. (1993) e descreve a probabilidade de variação da precipitação (em relação a um valor normal), ou seja, a ocorrência de anomalias, para o período de referência em um determinado local, em um intervalo de tempo mensal (ou vários meses). O SPI é amplamente aplicado e recomendado para caracterizar eventos de secas meteorológicas (BRITO et al., 2018; CUNHA et al., 2019; DA SILVA et al., 2020).

A formulação do SPI é baseada na função densidade e probabilidade Gamma (Equação 1), calculado de forma mensal, onde  $\alpha$  é o parâmetro de forma ( $\alpha > 0$ ),  $\beta$  é o parâmetro de escala ( $\beta > 0$ ), determinados através do método de máxima verossimilhança; o  $x$  é a quantidade de chuva, sendo que, o mesmo pode variar de acordo com  $\alpha$  e  $\beta$ . Os valores atribuídos são normalizados e transformados para uma distribuição normal (i.e. média, zero e variância um) (EDWARDS; MCKEE, 1997).

$$F(x) = \int_0^x f(x)dx = \frac{1}{\Gamma(\alpha)\beta^\alpha} \int_0^x x^{\alpha-1} e^{-\frac{x}{\beta}} dx = \quad (1)$$

O cálculo do SPI usa apenas dados de precipitação para identificar períodos úmidos e secos, com base na comparação de observações para um intervalo de tempo de interesse (por exemplo, 1, 3, 6, 12 e 48 meses) com o registro histórico de longo prazo desse intervalo. Requer dados mensais, de preferência contínuos e por 30 anos ou mais (OLIVEIRA-JÚNIOR et al., 2012; LYRA et al., 2017; VERHOEVE et al., 2021).

O SPI é calculado para cada mês, utilizando o próprio mês e um número de meses anteriores, que juntos são iguais a escala de tempo. Por exemplo: ao calcular o SPI de março com escala de tempo de 3 meses, utiliza-se a precipitação acumulada de janeiro, fevereiro e março. Esse valor é então comparado com o registro de longo prazo da precipitação cumulativa de janeiro a março. O SPI categoriza períodos chuvosos quando apresenta valores positivos,

enquanto valores negativos caracterizam déficits de chuva (OLIVEIRA-JÚNIOR et al., 2012; LYRA et al., 2017).

No presente estudo, o SPI foi calculado para escalas de tempo de acumulação de 3 e 12 meses, para identificar os períodos de seca na região em estudo da BHSF entre 1991 e 2020. A escala de 3 meses (SPI-3) fornece uma estimativa sazonal da precipitação (FANG et al., 2021; PAREDES-TREJO et al., 2021). Enquanto, a escala de 12 meses (SPI-12), além dos eventos de precipitação de longo prazo, também pode estar associada a anomalias das vazões dos rios e níveis dos reservatórios (FREITAS et al., 2022). Para o cálculo do SPI, foi utilizado um script de processamento digital, usando linguagem de programação JavaScript, na plataforma Google Earth Engine. As séries mensais de precipitação utilizadas nos cálculos do SPI (SPI-3 e SPI-12) não continham dados faltantes.

Para calcular as características espaciais deste tipo de seca, os seguintes critérios foram aplicados em cada ponto da grade CHIRPS. Um período de seca começa quando o  $SPI \leq -1,00$  por pelo menos dois meses consecutivos e termina quando o  $SPI > -1,00$ . A duração de um período de seca é o número de meses entre o início e o fim. O pico é o valor mínimo do SPI durante a ocorrência de um período de seca. A severidade de um evento de seca é o valor absoluto da soma dos valores do SPI do início ao fim do referido evento de seca. Para um determinado mês, a cobertura espacial da seca é a porcentagem de pixels com valores de  $SPI \leq -1,00$  (MCKEE et al., 1993; PAREDES-TREJO et al., 2021). Além dos critérios para definir uma seca, McKee et al. (1993), criaram um sistema para classificar os valores do SPI em sete categorias de secas meteorológicas, conforme exposto na Tabela 3.

Tabela 3 - Classificação dos valores de SPI.

SPI	Classificação
$\geq 2,00$	Extremamente úmido
1,50 a 1,99	Muito úmido
1,00 a 1,49	Moderadamente úmido
0,99 a -0,99	Próximo ao normal
-1,00 a -1,49	Moderadamente seco
-1,50 a -1,99	Severamente seco
$\leq -2,00$	Extremamente seco

Fonte: McKee et al. (1993).

### 3.3.2 Standardized Streamflow Index (SSI)

O SSI permite a caracterização de eventos de seca hidrológica de uma bacia hidrográfica, de modo simples, mas eficaz, das condições de seca hidrológica (JUNQUEIRA et al., 2020;

LUHAIM et al., 2021), sendo considerado o método mais empregado para quantificar as secas hidrológicas baseadas em vazões (SHAMSHIRBAND et al., 2020). O SSI usa a mesma fórmula e critérios de classificação da seca do SPI (Tabela 3), mas com a vazão mensal como entrada de dados.

O SSI foi utilizado neste estudo para identificar a ocorrência e a intensidade das secas hidrológicas e sua propagação em alguns trechos do rio São Francisco ao longo da região em estudo durante os anos de 1991 a 2020. Para seu cálculo nas escalas de tempo de 3 e 12 meses (ou seja, SSI3 e SSI12).

### 3.4 Parâmetros Biofísicos com Produtos MODIS

No presente estudo, ressalta-se que o produto corrigido da refletância da superfície é utilizado para uma série de estimativas de parâmetros biofísicos à superfície, em destaque, os índices estatísticos, fornecendo um conjunto de dados geoespaciais de 20 anos para toda a região em estudo.

Os índices de vegetação NDVI, SAVI, LAI e NDMI são calculados em função das bandas multiespectrais da refletância da superfície. Estes que se apresentam como indicadores sensíveis das condições de mudanças da cobertura e uso da terra como, a biomassa vegetal, avaliação da condição hídrica, produtividade agrícola e atividade fotossintética (ALLEN et al., 2002, 2007; BARBOSA et al., 2018; FERREIRA et al., 2020; HUETE, 1988; SANTOS et al., 2020; SILVA et al., 2020b; TEIXEIRA et al., 2009).

O índice de vegetação da diferença normalizada (*Normalized Difference Vegetation Index* – NDVI) foi calculado para fins de representação da quantidade e qualidade da vegetação presente na superfície, caracterizado como um indicador de condições de umidade, calculado por meio da Equação (3).

$$\text{NDVI} = \frac{\rho_{\text{NIR}} - \rho_{\text{Red}}}{\rho_{\text{NIR}} + \rho_{\text{Red}}} \quad (3)$$

onde,  $\rho_{\text{NIR}}$  e  $\rho_{\text{Red}}$  são as refletâncias mensuradas nas bandas do infravermelho próximo e vermelho (i.e.; bandas  $r_2$  de 0,841 a 0,876  $\mu\text{m}$  e  $r_1$  de 0,620 a 0,670  $\mu\text{m}$ ), respectivamente. Apresentando variações entre  $-1$  a  $+1$ ; valores próximos a  $+1$  em escala corresponde a áreas de vegetação com intensa atividade fotossintética e, enquanto corpos d'água e superfícies estéreis fornecem valores próximos a  $-1$  (PAREKH et al., 2021).

O cálculo do índice de vegetação ajustado ao solo (*Soil Adjusted Vegetation Index – SAVI*) foi realizado com intuito de reduzir a influência/ruído do solo na observação do recobrimento vegetal da área em estudo (Equação 4).

$$SAVI = \frac{(1 + L) \cdot (\rho_{NIR} - \rho_{Red})}{(L + \rho_{NIR} + \rho_{Red})} \quad (5)$$

onde, L é o fator de ajuste ao solo, que varia entre 0 e 1. O valor 0 não atinge mudanças e se assemelha ao NDVI; em áreas com vegetação de baixa densidade se atribui o valor 1; com vegetação de densidade intermediária, valor de 0,5; e para áreas com vegetação de altas densidades atribui o valor de 0,25 (HUETE, 1988). Nesse sentido, no presente estudo, adotou-se o fator de ajuste de 0,5, devido a região de estudo indicar uma cobertura vegetal intermediária na maior parte do ano, com vegetação predominante do bioma Caatinga, no Semiárido Brasileiro (por exemplo, RODRIGUES et al., 2020b; SILVA et al., 2020a; SILVA et al., 2021).

O índice de área foliar (*Leaf Area Index – LAI*,  $m^2 m^{-2}$ ) foi calculado em função do SAVI. O LAI é uma variável biofísica fundamental para estudos de monitoramento de terras agrícolas e áreas florestais e funciona como indicador da quantidade de biomassa vegetal e demais características da cobertura vegetal, como as condições de umidade (ALLEN et al., 2002; ALLEN et al., 2007).

$$LAI = \frac{-\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{0,91} \quad (6)$$

onde, os valores numéricos representam constantes da equação.

O Índice de Umidade de Diferença Normalizada (*Normalized Difference Moisture Index – NDMI*) também ganha destaque no presente estudo por possuir forte correlação com os níveis de umidade na vegetação. O NDMI é frequentemente usado no monitoramento ambiental para avaliar a saúde da vegetação e as condições de seca, uma vez que pode detectar a ocorrência de estresse hídrico em sua fase inicial (XU, 2006; GAZNAYEE et al., 2023). Além disso, o NDMI é um melhor indicador das mudanças na cobertura vegetal e do estresse hídrico do que o NDVI, graças a uma maior capacidade de detectar perturbações mais leves (WILSON; SADER, 2002).



Proposto por Gao (1996), o NDMI é desenvolvido em função da razão entre a diferença das bandas multiespectrais da refletância do infravermelho próximo ( $\rho_{\text{NIR}}$ ) e infravermelho de onda curta ( $\rho_{\text{SWIR}}$ ) pela soma das mesmas, de acordo com a Equação 7.

$$\text{NDMI} = \frac{(\rho_{\text{NIR}} - \rho_{\text{SWIR}})}{(\rho_{\text{NIR}} + \rho_{\text{SWIR}})} \quad (7)$$

em que,  $\rho_{\text{NIR}}$  e  $\rho_{\text{SWIR}}$  – correspondem às bandas multiespectrais da refletância  $r_2$  (0,841 – 0,876  $\mu\text{m}$ ) e  $r_6$  (1628 – 1652 $\mu\text{m}$ ) (Tabela 4), respectivamente.

As bandas NIR e SWIR foram selecionadas para a equação de banda NDMI para mitigar os efeitos da iluminação e da atmosfera. A combinação do NIR com o SWIR remove as variações induzidas pela estrutura interna da folha e pelo teor de matéria seca da folha, melhorando a precisão na recuperação do teor de água da vegetação (GAO, 1996). O NDMI varia de -1 a 1, onde valores mais próximos de 1 indicam alto teor de umidade na vegetação e valores mais próximos de -1 indicam baixo teor de umidade. Em geral, a vegetação com alto teor de umidade reflete mais NIR e absorve mais SWIR, resultando em um valor de NDMI mais alto (GAO, 1996; WILSON; SADER, 2002).

A temperatura da superfície terrestre (*Land Surface Temperature* – LST) foi obtida com o produto MOD11A2 a partir das emissividades das bandas 31 e 32, com aplicação de um fator multiplicativo de 0,02 nessas imagens, transformando desse modo, a informação de temperatura em Kelvin. Após isso, a imagem será convertida em graus Celsius ( $^{\circ}\text{C}$ ).

### 3.5 Análise dos dados e índices estatísticos

#### 3.5.1 Análises estatísticas de validação dos dados CHIRPS

Os eventos de chuva e a quantidade de chuva por mês estão amplamente sujeitos a variabilidade em pequena escala e, portanto, só podem ser validados na menor escala espacial possível (XU et al., 2015). Assim foi aplicada uma análise ponto-a-pixel, onde os dados de séries temporais de chuva do CHIRPS foram extraídos do ponto de grande mais próximo à posição das estações meteorológicas localizadas em Petrolina-PE (duas estações, INMET e EMBRAPA Semiárido), Santa Maria da Boa Vista-PE (uma estação, CHESF) e Juazeiro-BA (uma estação, EMBRAPA Semiárido), no período de 2001 a 2020 (Figuras 3 e 4). o entanto, é importante salientar que nem todas as estações possuíam dados desde 2001. Afim de comparar

os dados de precipitação de cada mês, séries temporais de dados observados nas estações meteorológicas com o pixel CHIRPS correspondente.

A análise do desempenho do produto CHIRPS na estimativa da quantidade de chuva em cada estação meteorológica será avaliado de acordo com cinco parâmetros estatísticos baseados em uma comparação de pares: Coeficiente de correlação de Pearson ( $r$ ), erro médio (ME), erro quadrático médio da raiz (RMSE), erro percentual médio (PBIAS) e coeficiente de eficiência de Nash-Sutcliffe (NSE).

O coeficiente  $r$  de Pearson tem por finalidade medir a qualidade do ajuste e a associação linear entre os dados de precipitação do produto CHIRPS e os dados observados de precipitação, variando de -1 a 1 com o maior grau de correlação entre as variáveis quando  $r$  for igual a 1 e, quando as variáveis não apresentam nenhuma correlação o  $r$  é igual a 0 (BAYISSA et al., 2017; PAREDES-TREJO et al., 2017; SILVA et al., 2020a), e pode ser expresso pela Equação 8:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n \sqrt{(X_i - \bar{X})^2} \sqrt{(Y_i - \bar{Y})^2}} \quad (8)$$

em que,  $X$ : corresponde aos dados observados de precipitação;  $\bar{X}$ : média dos dados observados de precipitação;  $Y$ : dados estimados de precipitação pelo produto CHIRPS;  $\bar{Y}$ : média baseada nos dados estimados de precipitação do produto CHIRPS.

O ME fornece informações sobre a estimativa de erro. E pode assumir qualquer valor negativo ou positivo, um valor positivo indica uma superestimação da precipitação do satélite, enquanto um valor negativo indica uma subestimação em relação à precipitação observada. Zero é a pontuação perfeita (BAYISSA et al., 2017; PAREDES-TREJO et al., 2017), e é definido conforme a Equação 9:

$$ME = \frac{1}{n} \sum_{i=1}^n (Y_i - X_i) \quad (9)$$

em que,  $X$ : corresponde aos dados observados de precipitação;  $Y$ : dados estimados de precipitação pelo produto CHIRPS e  $n$ : número de pares de dados disponíveis.

O MAE é uma análise estatística menos afetada pelos outliers e fornece a magnitude média das estimativas de erro. Esta análise representa a soma cumulativa dos erros e apresenta uma estimativa robusta para indicar a habilidade dos dados estimados em reproduzir os valores observados. O MAE adquire apenas valores positivos, com pontuação perfeita de 0 (PAREDES-TREJO et al., 2017; COSTA et al., 2019), e é definido conforme a Equação 9:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n (|Y_i - X_i|) \quad (9)$$

O RMSE é utilizado para verificar a acurácia das estimativas dos dados de precipitação do produto CHIRPS em relação aos dados observados, conforme a Equação 10. Valores mais baixos significam maiores tendências centrais e pequenos erros extremos. O valor RMSE de zero indica o melhor ajuste (BAYISSA et al., 2017; COSTA et al., 2019; SILVA et al., 2020a).

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (Y_i - X_i)^2}{n}} \quad (10)$$

onde, os valores de RMSE apresentam a mesma dimensão da variável analisada ( $\text{mm.mês}^{-1}$ ).

O PBIAS mede a tendência média dos valores estimados, que podem ser maiores ou menores do que os observados. Em outras palavras, está associado à precisão do modelo, onde o melhor valor de PBIAS é 0. Os valores positivos indicam viés de superestimação, enquanto valores negativos indicam viés de subestimação do modelo em termos percentuais (PAREDES-TREJO et al., 2017; SILVA et al., 2020a).

$$\text{PBIAS} = 100 \frac{\sum_{i=1}^n (Y_i - X_i)}{\sum_{i=1}^n (X_i)} \quad (11)$$

O Coeficiente de eficiência de Nash-Sutcliffe (NSE) quantifica a precisão das estimativas dos dados de precipitação do produto CHIRPS em relação à média das observações de precipitação conforme a Equação 12. Os valores de NSE variam de menos infinito a um: valores negativos significam que a média das observações é melhor que a estimativa, zero significa que a média das observações é tão boa quanto a estimativa e 1 corresponde a um

combinação perfeita entre os dados observados e os dados estimados (TOTÉ et al., 2015; PAREDES-TREJO et al., 2017).

$$NSE = 1 - \frac{\sum_{i=1}^n (Y_i - X_i)^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (12)$$

Para monitoramento de secas e propósitos hidrológicos, valores de RMSE e ME próximos a 0 e valores de NSE próximos a 1 são requeridos juntamente com altos valores de  $r$  para minimizar tanto a superestimação quanto a subestimação das quantidades de chuva (TOTÉ et al., 2015; COSTA et al., 2019; SILVA et al., 2020a).

### 3.5.2 Efeitos da seca na cobertura e na resiliência vegetal

Neste estudo, os valores médios de NDVI, LAI, NDMI e LST derivados das imagens MODIS de 8 dias e os valores de SPI-3 e SPI-12 estimados a partir do produto CHIRPS foram usados para investigar os efeitos da seca na cobertura e na resiliência vegetal, para respostas plurianuais (longo prazo), anuais (médio prazo) e sazonais (curto prazo). Os dados provenientes das imagens MODIS e CHIRPS foram importados usando a plataforma Google Earth Engine (<https://earthengine.google.com/>).

O efeito de longo prazo da mudança das condições climáticas na cobertura vegetal foi representado por mudanças nos valores de NDVI, LAI, NDMI e LST ao longo dos anos de 2001 a 2020. Isso foi avaliado com a análise de tendência de Mann-Kendall e da inclinação de Sen para os dados de NDVI, LAI, NDMI e LST compostos de valores médios de 8 dias ao longo do período de 2001 a 2020 e comparado com a precipitação e temperatura de longo prazo da região em estudo.

A dinâmica anual (médio prazo) da cobertura vegetal e sua resposta às secas foram quantificadas separando os anos em diferentes classes com base nas condições hidrológicas. Com o uso do SPI-12 anos normais ( $SPI-12 > -1$  e  $< 1$ ), úmidos ( $SPI-12 \geq -1$ ) e secos ( $SPI-12 \leq -1$ ) foram classificados, conforme McKee et al. (1993). Adicionalmente, o ano não seco subsequente a um ano seco foi classificado como “ano de recuperação”, independentemente das condições hidrológicas desse ano (normal ou chuvoso). Os valores médios de NDVI, LAI, NDMI e LST correspondentes a cada uma dessas quatro classes foram ajustados usando regressão polinomial local (LOESS) para fornecer uma curva suave através de um conjunto de

pontos de dados. Em seguida, as respostas do NDVI, LAI, NDMI e LST ao longo do período de 2001 a 2020 foi comparada com essas quatro diferentes condições hidrológicas.

Na última análise, a resiliência da vegetação e sua resposta aos efeitos de curto prazo da seca foram avaliados comparando tendências sazonais de NDVI, LAI, NDMI e LST durante períodos secos e não secos, com o uso do SPI-3 para as estações chuvosas NDJ e FMA. A sazonalidade das chuvas regula a dinâmica do dossel da Caatinga, onde a maioria das folhas cai durante a estação seca, e os primeiros pulsos de chuva desencadeiam um rápido fluxo de folhas na estação chuvosa. Portanto, essa sazonalidade pluviométrica configura-se como a força mais dominante na tendência fenológica da vegetação da Caatinga e representa uma ameaça significativa à conservação da floresta nativa e de sua biodiversidade (DOS SANTOS et al., 2020b; SOUSA JÚNIOR et al., 2022). Tais mudanças ao longo do tempo na cobertura vegetal da caatinga são expressas em modificações nos valores de índices biofísicos (CUNHA et al., 2020; MEDEIROS et al., 2022) (por exemplo, NDVI, LAI, NDMI e LST).

O momento da seca foi caracterizado pela ocorrência de SPI-3 menor que -1 durante os meses de janeiro e abril na primeira e segunda estação chuvosa (NDJ ou FMA, respectivamente). Foram comparadas quatro situações, em que ambas as estações foram secas (duas ocorrências), a primeira ou a segunda estação foi seca (quatro ocorrências para ambas as situações) ou ambas as estações foram normais ou úmidas (treze ocorrências). Para tanto, assumiu-se que, se a vegetação tolerou as condições de estiagem, essa resistiria à seca restabelecendo suas funções vitais, assim que as condições ambientais a permitisse (SANTOS et al., 2020; VERHOEVE et al., 2021). Por conseguinte, esperava-se que os valores de NDVI, LAI, NDMI e LST da estação não seca subsequente não se desviassem substancialmente em comparação a anos nos quais a primeira e a segunda estação não foram secas.

### **3.5.2 Efeito da precipitação no uso e cobertura da terra**

Com o objetivo de avaliar o efeito da precipitação pluviométrica sobre a vegetação e o impacto que as mudanças no uso e cobertura da terra tiveram sobre os para parâmetros biofísicos, foram utilizados dados de precipitação do produto CHIRPS, dados dos parâmetros biofísicos derivados das imagens MODIS de 8 dias (NDVI, LAI, NDMI e LST) e dados de uso e cobertura da terra obtidos da plataforma MapBiomas Brasil, referente a coleção 6.0 (Projeto MapBiomas, 2021). Esses conjuntos de dados correspondem ao período de 1 de janeiro de 2001 a 31 de dezembro de 2020 e foram importados usando a plataforma Google Earth Engine (<https://earthengine.google.com/>).

Para realização das análises foram selecionados 150 pontos de dados aleatórios para cada classe de uso e cobertura da terra (Caatinga, formação vegetal não florestal, agricultura, área não vegetada), ou seja, um total de 600 pontos que foram utilizados para extração das informações das variáveis precipitação, NDVI, LAI NDMI, e LST. Os pontos aleatórios foram gerados para cada tipo de uso da terra usando uma ferramenta de pontos aleatórios (Random Points Inside Polygons) do software QGIS 3.16 (QGIS Development Team, 2021), uma ferramenta confiável e prática também utilizada em outros estudos (por exemplo, WIJESINGHA et al., 2019; FERREIRA et al., 2020; URRUTIA et al., 2020). Este procedimento forneceu uma base comum para comparação entre as classes de uso e cobertura da terra, utilizando a mesma estrutura de amostragem espacial, e seguiu a metodologia de outros estudos (por exemplo, ROBINSON et al., 2017; HOAGLAND; BEIER; LEE, 2018; FERREIRA et al., 2020). Posteriormente, as coordenadas geográficas de cada ponto foram exportadas para a plataforma Google Earth Engine onde foi realizada a amostragem dos dados.

Para caracterizar a resposta da vegetação à chuva os dados obtidos de NDVI, LAI, NDMI e LST, referentes a cada classe de uso e cobertura da terra foram correlacionados via matriz de correlação através do software R, versão 3.6.1 (R CORE TEAM, 2019), com dados de precipitação para diferentes períodos de defasagem temporal (Lag: 0, 1, 2, 3 e 4 meses anteriores ao mês de observação dos parâmetros biofísicos). Por fim, para melhor compreender o impacto que as mudanças no uso e ocupação da terra tiveram sobre magnitude da variação dos valores de NDVI, LAI NDMI, LST, a série temporal (2001-2020) foi dividida em anos secos, chuvosos, normais e ano de recuperação conforme a classificação do SPI-12, segundo McKee et al. (1993). Adicionalmente, essa classificação foi utilizada para gerar box-plots dos dados de NDVI, LAI, NDMI e LST, com base na classificação MapBiomas (<http://mapbiomas.org>).

### **3.5.3 Estatística descritiva**

Os dados de temperatura média do ar, vazão média, precipitação, SPI, SSI e parâmetros biofísicos (NDVI, LAI, NDMI e LST), foram submetidos à análise estatística descritiva, para obtenção da média, mediana, desvio padrão (DP) e coeficiente de variação (CV, %), classificado como baixo quando o  $CV < 12\%$ ; médio quando estiver  $12\% \geq CV < 24\%$  e alto quando o  $CV > 24\%$  (WARRICK; NIELSEN, 1980), posteriormente, foi aplicado o teste de normalidade de Shapiro-Wilk ( $p < 0,01$ ), onde todos os conjuntos de dados apresentaram uma distribuição não normal ao longo do período de estudo.

Contudo, destaca-se que os principais valores estatísticos descritivos foram extraídos em função do processamento digital interno na plataforma do *Google Earth Engine*, do software QGIS 3.16 (QGIS Development Team, 2021) e software R, versão 3.6.1 (R CORE TEAM, 2019), e também de dados tabulados em planilhas a partir do software Microsoft Excel®, incluído no pacote da Microsoft Office®.

### 3.5.4 Análise de tendência da seca, parâmetros biofísicos e uso e cobertura da terra (Teste de Mann-Kendall e estimador de inclinação de Sen)

As mudanças na cobertura vegetal e na saúde da vegetação e os valores de NDVI, LAI, NDMI e LST correspondentes dependem de muitos fatores antrópicos e naturais. O fator natural mais importante são a temperatura e a disponibilidade hídrica que é regulada principalmente pela precipitação e vazão dos rios e afluentes. Por conseguinte, as tendências sazonais e anuais dos parâmetros biofísicos NDVI, LAI, NDMI e LST e dos dados hidrometeorológicos (precipitação, temperatura do ar e vazão) foram determinadas ao longo do tempo para as duas estações chuvosas (NDJ e FMA) e o ano hidrológico (novembro-outubro).

Por outro lado, ao longo das últimas décadas, as mudanças no uso e cobertura da terra têm sido um dos principais agentes de transformação do ecossistema na BHSF, devido aos seus impactos na intensificação dos processos de degradação dos recursos terrestres e hídricos, redução da vegetação nativa e perda da biodiversidade (MARTINS et al., 2018a; QUEIROZ et al., 2020). Portanto, as tendências anuais foram determinadas para os diferentes tipos uso e cobertura da terra a partir da coleção 6.0 das classificações temáticas de mapas anuais da cobertura e uso da terra do MapBiomas ao longo do período de 2001 a 2020, destacando-se as seguintes classes: Caatinga, formação vegetal não florestal, agricultura, área não vegetada e corpos d'água.

O teste de tendência modificada de Mann-Kendall (MK) foi utilizado, nesta pesquisa, para determinar a direção e a significância das tendências, esse teste tem sido frequentemente usado para quantificar a significância das tendências em séries temporais de dados climáticos, ambientais ou hidrológicos (LYU et al., 2023; SUN et al., 2023; VERHOEVE et al., 2021). A estatística do teste (S) de MK (MANN, 1945; KENDALL, 1975) é descrita pela Equação 13.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{Sgn}(x_j - x_i) \quad (13)$$

onde,  $n$  – corresponde ao número de pontos de dados;  $x_i$  e  $x_j$  são os valores de dados nas séries temporais  $i$  e  $j$  ( $j > i$ ), respectivamente, e  $\text{Sgn}(x_j - x_i)$  é definido pela Equação 14. Um  $S$  positivo indica uma tendência crescente e vice-versa (MANN, 1945; KENDALL, 1975).

$$\text{Sgn}(x_j - x_i) = \begin{cases} 1, & \text{se } (x_j - x_i) > 0 \\ 0, & \text{se } (x_j - x_i) = 0 \\ -1, & \text{se } (x_j - x_i) < 0 \end{cases} \quad (14)$$

Sendo o conjunto de dados distribuído de forma idêntica e independente, a média de  $S$  é zero e a variância de  $S$  é calculada conforme a Equação 15.

$$\text{Var}(S) = \frac{[n(n-1)(2n+5) - \sum_{i=1}^p t_i(t_i-1)(2t_i+5)]}{18} \quad (15)$$

em que,  $n$  – é o número de pontos de dados;  $t_i$  – número de valores de dados no  $i$ -ésimo grupo;  $p$  – número de grupos contendo valores repetidos.

Durante a série temporal de 20 anos de dados, o valor estatístico  $S$  pode ser transformado em  $Z_S$ , de acordo com as seguintes condições dada pela Equação 16.

$$Z_S = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}}, & \text{se } S > 0 \\ 0, & \text{se } S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}}, & \text{se } S < 0 \end{cases} \quad (16)$$

em que, o valor  $Z_S$  caracteriza se há tendência no teste de Mann-Kendall. Os valores de  $Z_S$  positivos indicam tendências crescentes, enquanto os valores de  $Z_S$  negativos indicam tendências decrescentes e se o valor de  $Z_S$  for 0, não há tendência. Neste estudo, foram utilizados os níveis de significância  $\alpha = 0,01$  e  $\alpha = 0,05$ . Ao nível de significância de 5%, a hipótese nula de nenhuma tendência é rejeitada se  $|Z_S| > 1,96$  e rejeitada ao nível de significância de 1% se  $|Z_S| > 2,576$ .

Posterior à identificação das tendências pelo teste de Mann-Kendall ( $Z_S$ ), realizou-se uma análise da magnitude da tendência por meio do teste de inclinação de Sen ( $Q$ ) (SEN, 1968).



O método de Sen usa um modelo linear para estimar a inclinação da tendência, e a variância dos resíduos deve ser constante no tempo, conforme a Equação 17.

$$Q_i = \left( \frac{X_j - X_k}{j - K} \right), \text{ para } i = 1, 2, 3, \dots N \quad (17)$$

em que,  $X_j$  e  $X_k$  – são os valores dos dados nos tempos  $j$  e  $k$  ( $j > k$ ), respectivamente. Se houver apenas um dado em cada período de tempo, então  $N = n(n - 1)/2$ , onde  $n$  é o número de períodos de tempo. Se houver várias observações em um ou mais períodos de tempo,  $N < n(n - 1)/2$ . Os  $n$  valores de  $Q_i$  são classificados do menor para o maior, e a inclinação mediana ou o estimador de inclinação de Sen será calculado conforme a Equação 18 (SANTOS; NASCIMENTO; SILVA, 2020; SILVA et al., 2015).

$$Q_{\text{med}} = \begin{cases} Q\left(\frac{n+1}{2}\right), & \text{se } n \text{ for ímpar} \\ \left( \frac{Q\left(\frac{n}{2}\right) + Q\left(\frac{n+2}{2}\right)}{2} \right), & \text{se } n \text{ for par} \end{cases} \quad (18)$$

Neste estudo, a análise de tendência pelo teste de Mann-Kendall junto com o estimador de inclinação de Sen foi realizada a partir do software R, versão 3.6.1 (R CORE TEAM, 2019). E posteriormente, estatísticas de categorização foram aplicadas aos parâmetros biofísicos (NDVI, LAI, NDMI e LST) no software QGIS 3.16 (QGIS Development Team, 2021), onde a variação nas tendências de cada pixel foi efetivamente caracterizada usando a análise de tendência mediana de Theil-Sen e o teste MK para refletir as características de distribuição espacial da variação na tendência dos parâmetros biofísicos na BHSF durante o período de 2001 a 2020.

Foram consultadas técnicas de categorização de outros estudos e estabelecidas classificações de acordo com as condições da inclinação de Sen (HOU et al., 2022; LYU et al., 2023; SUN et al., 2023). Como não existem estritamente áreas com inclinação de Sen de 0, foram realizadas as seguintes classificações de acordo com as condições reais de inclinação de Sen dos parâmetros biofísicos. Áreas com inclinação de Sen de  $-0,0005$  a  $0,0005$  foram classificadas como áreas estáveis, áreas com inclinação de Sen maior que  $0,0005$  foram classificadas como áreas com tendências crescentes e áreas com inclinação de Sen menor que  $0,0005$  foram classificadas como áreas com tendências decrescentes. Além disso, o teste MK

foi usado para avaliar a significância das tendências dos parâmetros biofísicos ao nível de significância de 0,05 ( $|ZS| > 1,96$ ). Ao integrar combinar os resultados da análise de inclinação de Sen e o teste MK, a distribuição espacial das variações interanuais das tendências dos parâmetros biofísicos na escala de pixels foram obtidas e, então categorizadas em cinco categorias, conforme apresentado na Tabela 4.

Tabela 4 - Critérios de categorização estatística para tendências de variação dos parâmetros biofísicos.

Sen	Valor Z	Tendência
>0,0005	>1,96	Aumento significativo
>0,0005	-1,96-1,96	Aumento não significativo
-0,0005-0,0005	-1,96-1,96	Sem variação significativa
<-0,0005	-1,96-1,96	Redução não significativa
<-0,0005	<-1,96	Redução significativa

### 3.5.5 Análise multivariada dos dados

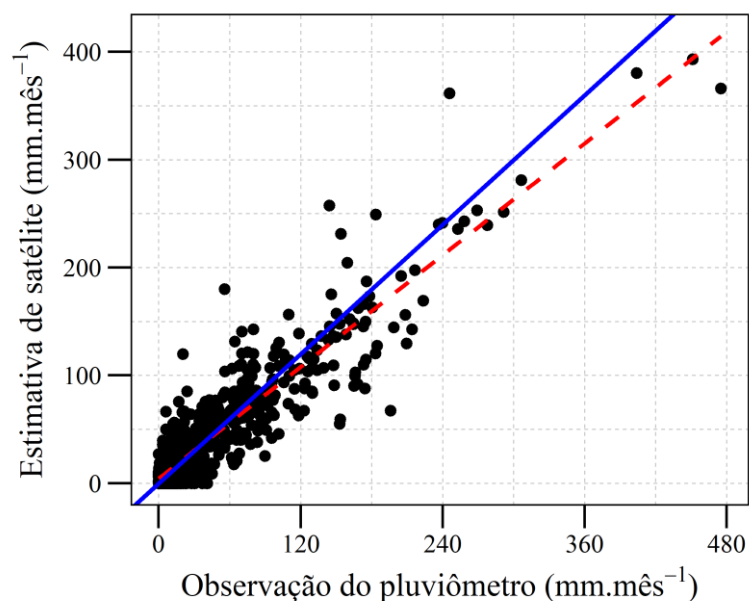
No presente estudo, a análise de componentes principais (PCA) foi empregada para analisar individualmente as classes de uso e ocupação da terra (Caatinga densa (arbórea, arbustiva e herbácea), agricultura, formação vegetal não florestal e área não vegetada); inicialmente, admitindo-se quatro variáveis preditoras sendo: os parâmetros biofísicos (ou seja, NDVI, LAI, NDMI e LST ) e as variáveis e climáticas (precipitação pluviométrica e temperatura do ar), referentes aos valores médios para cada mês do ano no período de 2001 a 2020. A análise de componentes principais foi realizada com intuito de reduzir o grande conjunto de dados, e converter a série de dados em conjuntos de valores lineares não correlacionados, sem perder informações relevantes (JARDIM et al., 2021b; SILVA et al., 2021a). Baseando-se nas componentes principais (CP), foi obtida a matriz de covariância para extração dos autovalores que originam os autovetores. Serão considerados apenas os autovalores ( $\lambda$ ) acima de 1 ( $\lambda > 1$ ), devido os mesmos apresentarem expressivas informações do novo conjunto de dados criado (KAISER, 1958). As cargas geradas indicam a importância relativa de uma determinada variável bruta da amostra dos dados no componente principal (PC).

## 4 RESULTADOS E DISCUSSÃO

### 4.1 Validação dados CHIRPS

A precipitação média anual para o produto CHIRPS durante o período de teste foi de 398,87 mm, enquanto o valor correspondente para os dados observados foi de 402,33 mm. Em geral, as observações das estações meteorológicas e as estimativas de precipitação baseadas no produto CHIRPS em escala mensal para o período de 1991 a 2020 (Figura 6), permitem observar que o produto CHIRPS apresenta uma subestimativa dos altos valores e uma superestimativa dos baixos valores de precipitação.

Figura 6 - Observações de precipitação terrestres e estimativas de precipitação baseadas em CHIRPS para o período 1991-2020. A linha azul indica a correspondência 1:1 e a linha vermelha tracejada fornece o melhor ajuste da regressão linear.



Em geral, há boa concordância entre os dados estimados de precipitação (CHIRPS) e os observados (estações meteorológicas) de acordo com a análise estatística, (Figura 6 e Tabela 5). A comparação entre os dados mensais estimados e observados, considerando todas as estações meteorológicas selecionadas, apresento coeficiente de correlação de Pearson ( $r$ ) igual a 0,926 (Tabela 5), indicando uma forte correlação entre os dois conjuntos de dados na região de estudo da BHSF. Paredes-Trejo et al. (2017) validaram o produto CHIRPS para a região Nordeste do Brasil (NEB), com base em 21 estações do INMET, e obtiveram  $r = 0,93$ .

Além disso, o desempenho do CHIRPS é relativamente bom porque o ME, Pbias e NSE obtidos estão próximos da pontuação perfeita, com baixos valores de MAE e RMSE (Tabela

5). Isso é consistente com estudos anteriores que confirmam a aplicabilidade do produto de precipitação CHIRPS em uma escala de tempo mensal em regiões com escassez de dados observados no solo (PAREDES-TREJO et al., 2017; BAYISSA et al., 2017; COSTA et al., 2019; SILVA et al., 2020c; HORDOFA et al., 2021).

Tabela 5 - Métricas estatísticas de desempenho do produto CHIRPS que levam em consideração estações dentro da área de estudo.

Métricas de desempenho	Estações Meteorológicas				
	Santa Maria da Boa vista (CHESF)	Juazeiro (EMBRAPA Semiárido)	Petrolina (EMBRAPA Semiárido)	Petrolina (INMET)	Dados Acumulados
r	0,947	0,922	0,892	0,902	0,926
ME (mm)	-0,078	-3,817	0,874	0,310	-0,310
MAE (mm)	11,282	14,290	15,484	7,917	11,894
RMSE (mm)	17,234	25,634	24,930	24,943	20,879
Pbias (%)	-0,239	-10,453	2,532	0,952	-0,917
NSE	0,896	0,835	0,795	0,812	0,857

Coefficiente de correlação de Pearson (r), erro médio (ME), erro quadrático médio da raiz (RMSE), erro percentual médio (PBIAS) e coeficiente de eficiência de Nash-Sutcliffe (NSE).

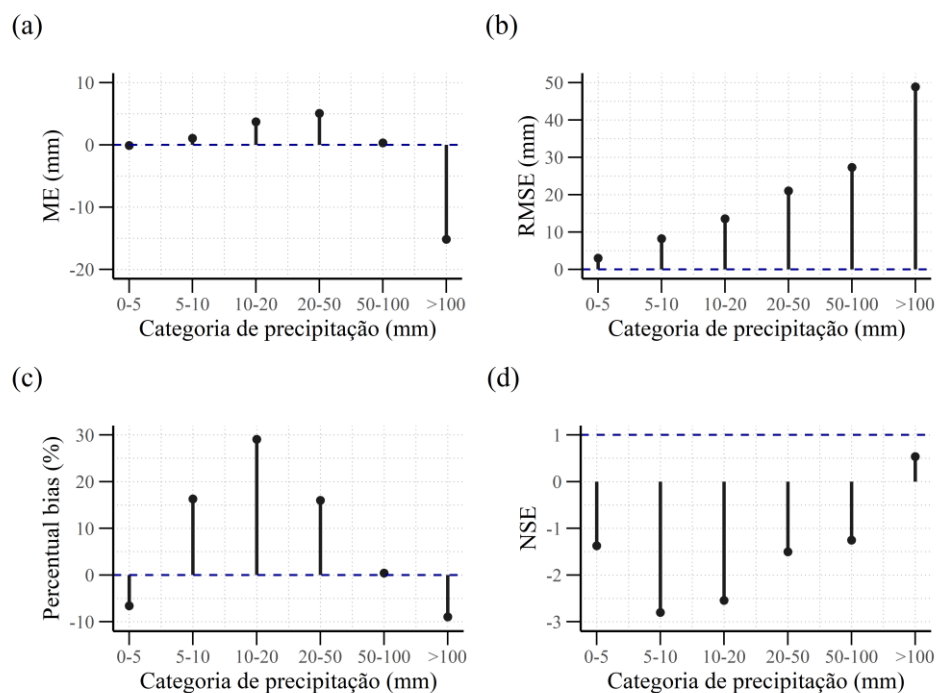
A Tabela 5 resume os resultados da validação cruzada entre os dados estimados de precipitação e os observados em escala de tempo mensal no período de janeiro de 1991 a dezembro de 2020, para cada estação meteorológica utilizada no presente estudo. Com exceção da estação meteorológica da EMBRAPA-Petrolina todas as demais estações utilizadas neste estudo apresentam coeficientes de correlação superiores a 0,9 (Tabela 5). Todavia, as estações com melhores escores estatísticos, especificamente maiores valores de r, NSE e menores valores de ME, MAE, RMSE e Pbias, e por este motivo as que apresentaram melhor desempenho dos dados estimados em relação aos dados observados, foram as estações da CHESF e do INMET (Tabela 5).

Os resultados das métricas ME e Pbias indicam uma subestimativa dos dados estimados em relação às estações de Santa Maria da Boa Vista e Juazeiro, com viés positivo mais alto na estação de Juazeiro, cerca de 10%. Por outro lado, em ambas as estações localizadas na cidade de Petrolina, verifica-se uma superestimativa dos dados estimados em relação aos dados observados, com viés negativo mais baixo na estação da EMBRAPA, cerca de 2,5% (Tabela 5). De maneira geral, as métricas ME e Pbias apresentaram valores próximos da pontuação perfeita. Baixos valores de Pbias indicam que há uma boa concordância entre os valores cumulativos das estimativas de precipitação e os valores cumulativos das estações meteorológicas (BAYISSA et al., 2017; GOSHIME; ABSI; LEDÉSERT, 2019).

Para melhor explorar as características do desempenho do produto CHIRPS, as métricas estatísticas foram calculadas para diferentes categorias de precipitação pluviométrica apoiadas por observações mensais de precipitação: 0-5 mm (n = 344); 5-10 mm (n = 108); 10-20 mm (n = 102); 20-50 mm (n = 149); 50-100 mm (n = 122); e >100 mm (n = 87) (n - indica o número de casos pareados analisados por categoria) (Figura 7). Similar às observações feitas na Figura 6, os resultados de ME e Pbias para as categorias de precipitação indicam que o produto CHIRPS apresentam uma superestimativa da quantidade observada de precipitação entre 5 mm  $\text{mês}^{-1}$  e 100 mm. $\text{mês}^{-1}$ , enquanto tende a subestimar esses valores abaixo de 5 mm  $\text{mês}^{-1}$  e acima de 100 mm. $\text{mês}^{-1}$  (Figura 7b, c).

Notavelmente, a maioria das métricas revela o pior desempenho para as categorias de precipitação entre 5 e 50 mm, com menores valores de RMSE e NSE, acompanhados de maiores valores de ME e Pbias (Figura 7). Por outro lado, os resultados indicam uma melhor relação dos dados estimados com os dados observados na categoria acima de 100 mm. $\text{mês}^{-1}$ , com baixo Pbias (-8,96) e alto NSE (0,54) ( Figura 7 c, d). Neste estudo, a categoria de precipitação 0-5 mm apresentou um desempenho moderadamente satisfatório com baixos valores de ME, Pbias e RMSE.

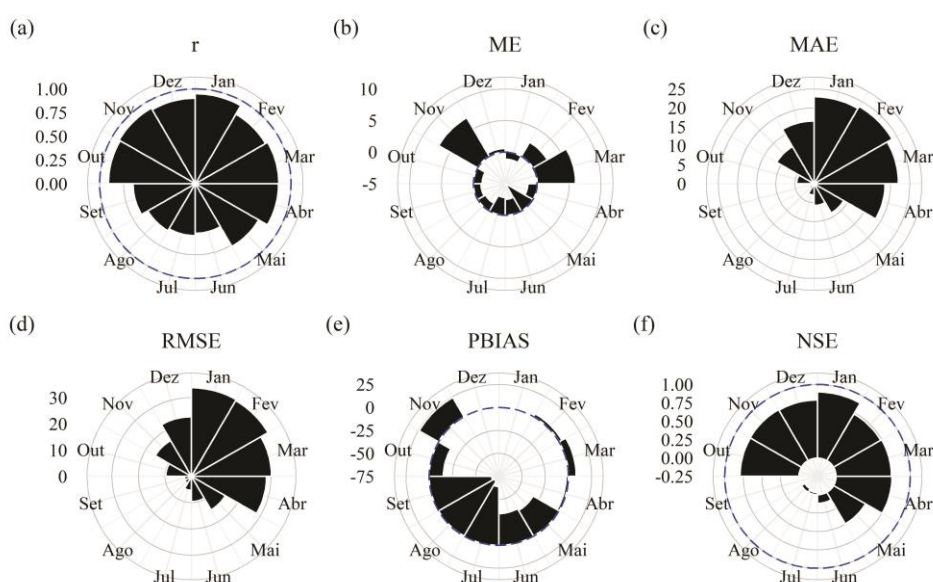
Figura 7 – Métricas estatísticas de desempenho agrupadas por categorias de precipitação pluviométrica para contraste das observações de precipitação nos pluviômetros das estações meteorológicas e estimativas de precipitação baseadas no produto CHIRPS. A linha azul tracejada indica a pontuação perfeita para cada métrica.



Os resultados demonstram que os dados do produto CHIRPS possuem boa capacidade de representar os valores máximos e mínimos mensais observados sem comprometer o padrão dos eventos de precipitação. Em um estudo sobre o desempenho de diversos conjuntos de dados de precipitação derivados de satélite sobre a bacia do lago Ziway, Etiópia, Hordofa et al. (2021) constataram que o produto CHIRPS apresentou o melhor desempenho para capturar o padrão temporal da precipitação mensal.

A Figura 8 mostra as métricas estatísticas de desempenho agrupadas por mês, obtidas para as estações meteorológicas em relação as estimativas do produto CHIRPS. Em geral, os resultados apresentaram correlações positivas entre as estações meteorológicas e as estimativas do produto CHIRPS em todos os meses. Contudo, o desempenho dos dados estimados de precipitação em relação aos observados indicou uma melhora correspondência durante os meses mais chuvosos, com maiores valores de  $r$  e NSE em janeiro (0,950 e 0,899), respectivamente, enquanto os meses mais secos tiveram um menor desempenho em termos de ajuste, com menores valores de  $r$  e NSE em junho (0,523 e 0,116), respectivamente (Figura 8 a, f). No contexto da análise do clima, muitos pesquisadores sugeriram que um coeficiente de correlação de 0,5 a 0,6 é aceitável (ZHANG et al., 2011; MEKANIK et al., 2013; BAYISSA et al., 2017).

Figura 8 – Métricas estatísticas de desempenho agrupadas por mês para contraste das observações de chuva observadas nos pluviômetros das estações meteorológicas e estimativas de chuva baseadas no produto CHIRPS. A linha azul tracejada indica a pontuação perfeita para cada métrica.



De maneira geral, os resultados das métricas estatísticas ME e Pbias indicam uma superestimativa dos dados do produto CHIRPS durante a estação chuvosa (novembro-abril) e

uma subestimava durante a estação seca (maio-outubro) (Figura 8 b, e). Isso confirma os resultados de estudos anteriores que analisaram o desempenho do produto CHIRPS nas regiões Nordeste (PAREDES-TREJO et al., 2017), Norte (SILVA et al., 2020c) e Centro-Oeste (OLIVEIRA-JÚNIOR et al., 2021) do Brasil. Durante a estação seca, os menores valores de ME e Pbias foram observados entre julho e setembro meses que apresentam em sua maioria eventos de precipitação menores que 5 mm. Por outro lado, durante a estação chuvosa os maiores valores de ME e Pbias foram verificados em novembro, fevereiro e março, meses que apresentam eventos de precipitação entre 20 e 100 mm. Por conseguinte, esses resultados seguem o comportamento verificado nas Figuras 6 e 7.

As métricas MAE e RMSE indicam que o erro aumentou nos meses que apresentam maior variabilidade interanual (Figura 8c, d). Além disso, valores maiores de magnitude de erro MAE e RMSE foram observados de janeiro a março, com 22,85 mm e 32,44 mm, respectivamente. Por outro lado, os menores valores de MAE e RMSE foram observados de julho a setembro, com 1,89 mm e 3,70 mm, respectivamente. Esses resultados indicam que os dados de precipitação estimados exibem maior flutuação nos meses mais chuvosos, sendo os meses secos mais estáveis.

## 4.2 Precipitação pluviométrica, temperatura do ar e vazão

A variação sazonal da precipitação na região em estudo da BHSF é caracterizada por uma estação chuvosa, que compreende os meses de novembro a abril, e por uma estação seca com ocorrência entre os meses de maio e outubro. Isso posto, a análise da precipitação pluviométrica mensal via boxplot evidenciou alta variabilidade interanual, com aumento dos valores de precipitação durante os meses de novembro a março (período chuvoso) e redução de março a novembro (período seco).

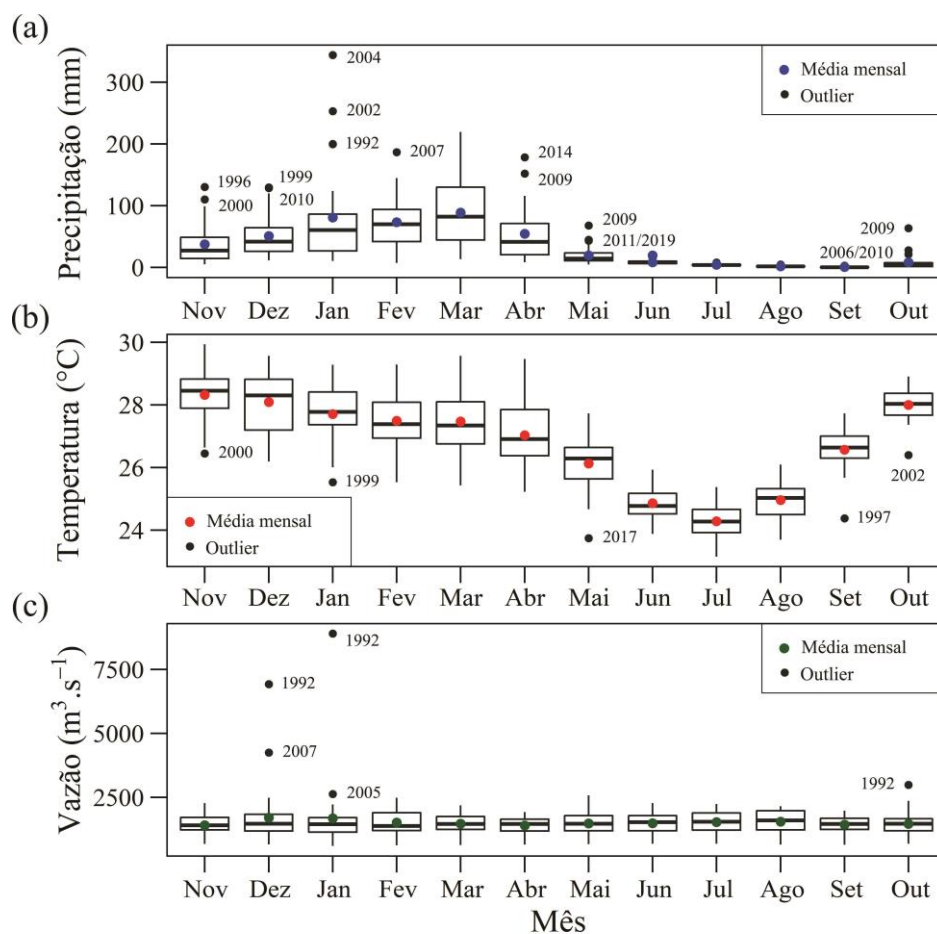
Os meses mais chuvosos foram de janeiro a março, neste período a precipitação esteve acima de  $70 \text{ mm.mês}^{-1}$ , com máximo de  $89,04 \text{ mm.mês}^{-1} \pm 55,37 \text{ mm.mês}^{-1}$  em março. Enquanto os meses mais secos foram de julho a setembro com precipitações menores que  $5 \text{ mm.mês}^{-1}$ , com mínimo de  $0,741 \text{ mm.mês}^{-1} \pm 0,768 \text{ mm.mês}^{-1}$  em setembro (Figura 9a). Estas variações são coerentes com a distribuição regional da precipitação para a região do submédio São Francisco (FERREIRA et al., 2012; CABRAL JÚNIOR et al., 2019; JARDIM et al., 2022).

Vale ressaltar que, a presença de *outliers* mensais está associada a ocorrência de anomalias de precipitação pluviométrica acima da média climatológica (1991 a 2020), conforme dados CHIRPES (Figura 9a). Tais anomalias fizeram com que as médias fossem

maiores que as medianas. Por conseguinte, a ocorrência de anomalias máximas de precipitação não esteve diretamente relacionada ao modo de variabilidade climática El Niño-Oscilação Sul (ENOS), pois os outliers mensais ocorreram em anos de El Niño (1992, 2007 e 2010), La Niña (1999, 2000, 2011) e neutro (1996, 2004, 2006, 2009, 2014 e 2019) (anos ENOS listados em [https://psl.noaa.gov/enso/past\\_events.html](https://psl.noaa.gov/enso/past_events.html)). Estes resultados sugerem que a precipitação da região em estudo da BHSF não é influenciada apenas pela ocorrência de eventos de ENOS, mas pela soma de vários aspectos climáticos e sinóticos.

Diversos estudos mostraram que a variabilidade pluviométrica na região Nordeste do Brasil é uma combinação dos efeitos dos ENOS no Atlântico Norte tropical e Atlântico Sul equatorial e tropical e anomalias da temperatura da superfície do mar do Atlântico devido à variabilidade interna intrínseca do Atlântico (GIANNINI; SARAVANAN; CHANG, 2004; RODRIGUES et al., 2011; TEDESCHI; CAVALCANTI; GRIMM, 2013; RODRIGUES; MCPHADEN, 2014).

Figura 9 - Avaliação da variabilidade interanual da precipitação pluviométrica (a), temperatura média do ar (b) e vazão média, com a identificação dos respectivos anos com outliers, de 2001 a 2020.





Conforme o levantamento realizado no banco de dados do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), disponível na plataforma Climanálise (CLIMANÁLISE, 2023), as anomalias de precipitação observadas através dos outliers mensais (Figura 9a) estão em sua maioria relacionadas à atuação da zona de convergência intertropical (ZCIT) e de vórtices ciclônicos de altos níveis (VCAN) que influenciaram, isoladamente ou em conjunto com outras perturbações atmosféricas, na ocorrência de 12 das 16 anomalias. Além disso, verificou-se à atuação da zona de convergência do atlântico sul (ZCAS), distúrbios ondulatórios de leste (DOL), sistemas frontais (FS), cavados em altos níveis e linhas de instabilidade (LI's) (CLIMANÁLISE, 2023).

Muitos estudos relatam que a porção norte da região semiárida do Brasil é influenciada pela modulação da ZCIT (UTIDA et al., 2019; MEDEIROS et al., 2020; MOURA et al., 2020; GOMES; LIMA, 2021), enquanto a porção sul é influenciada pela ZCAS (MARENGO et al., 2018; CORREIA FILHO et al., 2019), além dos DOL (COSTA et al., 2018; LIMA et al., 2019; RODRIGUES et al., 2020a), FS (MOLION; BERNADO, 2002), LI's (TREJO et al., 2016) e VCAN (WIEGAND et al., 2021).

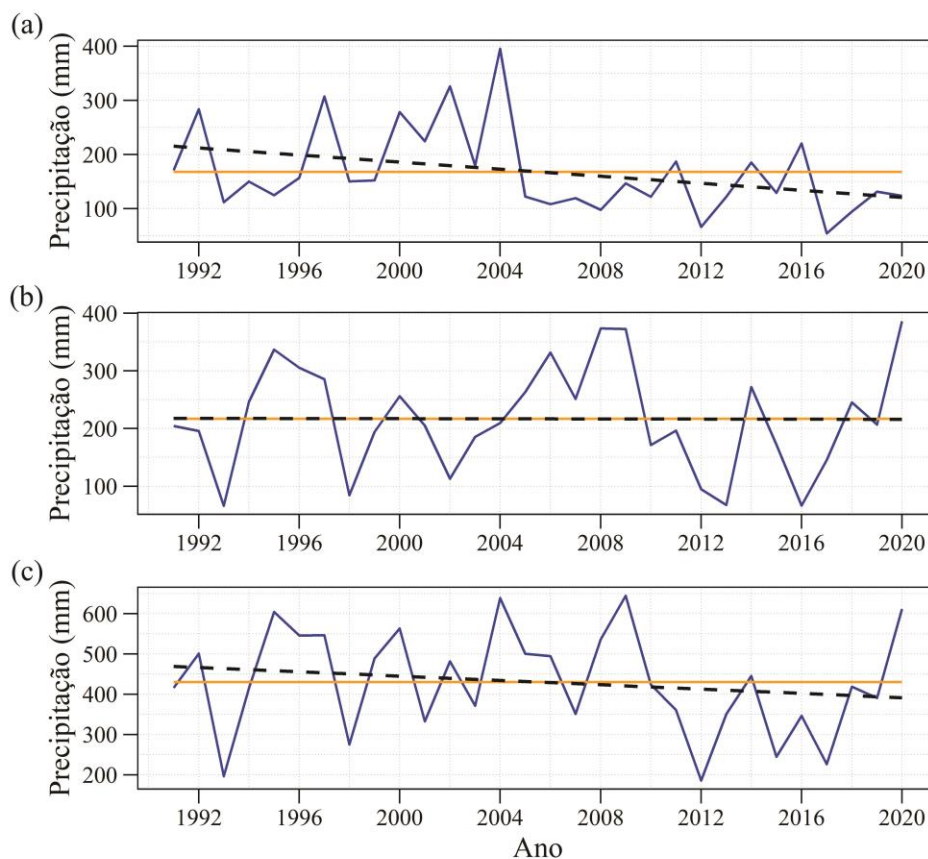
Em relação à temperatura do ar, os valores aumentaram ao longo dos meses de julho a dezembro e diminuíram entre dezembro e julho. Os meses mais quentes foram novembro e dezembro com valores médios de  $28,21 \text{ }^\circ\text{C} \pm 0,90 \text{ }^\circ\text{C}$ , enquanto os meses mais frios foram de junho a agosto com valores médios de  $24,70 \text{ }^\circ\text{C} \pm 0,60 \text{ }^\circ\text{C}$  (Figura 9b). A ocorrência de outliers mensais de temperatura estão associados a aumentos mensais da precipitação no período em questão.

A vazão, por outro lado, apresentou variabilidade interanual mais uniforme. No entanto, a presença de outliers e de elevados valores de vazão na década de 90, moldou sucessivos ciclos de oscilação, com redução nos meses de janeiro a abril e agosto a novembro, enquanto se observa aumento nos meses de abril a agosto e novembro a janeiro. De maneira geral, os maiores valores ocorreram nos meses de janeiro, dezembro e agosto e os menores em abril, setembro e novembro (Figura 9c). A implantação e operação de reservatórios são ações antrópicas que modificam as distribuições espacial e temporal das vazões naturais, afim de atender os usos múltiplos da água e garantir a geração de energia do sistema ao qual a usina está conectada (GENZ; LUZ, 2012; VASCO et al., 2017).

As variações ocorridas na precipitação pluviométrica durante as estações chuvosas de novembro-dezembro-janeiro (NDJ) e fevereiro-março-abril (FMA), bem como no ano hidrológico novembro-outubro, são apresentadas na Figura 10. De maneira geral, a precipitação na região em estudo da BHSF é caracterizada por uma alta variabilidade anual e sazonal, com

média anual de  $430,31 \text{ mm} \pm 129,01 \text{ mm}$  (Tabela 6). Analogamente, a estação NDJ apresenta uma maior variação em relação à estação FMA ( $CV \text{ NDJ} = 47,58\%$ ;  $CV \text{ FMA} = 42,85\%$ ), mas uma média sazonal menor em comparação com a estação FMA (168,09 mm e 216,91 mm, respectivamente) (Tabela 6). Isto posto, em média as duas estações representam aproximadamente 90% da precipitação pluviométrica ocorrida ao longo do ano hidrológico ( $\text{NDJ} = 39,09\%$ ;  $\text{FMA} = 50,57\%$ ).

Figura 10 - Precipitação total para a região em estudo da BHSF durante o período de 1991–2020, com base no conjunto de dados CHIRPS. (a) A estação chuvosa de NDJ (novembro, dezembro e janeiro), (b) a estação chuvosa de FMA (fevereiro, março e abril) e (c) o ano hidrológico (novembro-outubro). As linhas de tendência linear (pretas) são baseadas na inclinação de Sen. Insignificativa em  $\alpha = 0,05$  para o ano hidrológico e a estação chuvosa de FMA e, significativa para a estação chuvosa de NDJ. As linhas laranjas representam as médias climatológicas.



A análise das tendências de precipitação de longo prazo usando o teste MK e o método de inclinação de Sen evidenciou tendências decrescentes de  $-2,350 \text{ mm.ano}^{-1}$ ,  $-0,107 \text{ mm.ano}^{-1}$  e  $-1,105 \text{ mm.ano}^{-1}$  nas estações chuvosas NDJ e FMA e na precipitação anual, respectivamente (Tabela 6). Desvios dessa tendência na forma de anos relativamente chuvosos (por exemplo, 1995, 2004, 2009 e 2020) também são visíveis. Contudo, estas oscilações não foram estatisticamente significativas em  $\alpha = 0,05$  ( $|Z_S| > 1,96$ ), o que significa que não se pode concluir

que ocorreu alteração no padrão de oscilação da precipitação, ao longo da série temporal (1991-2020) (Tabela 6).

Os padrões de precipitação na região em estudo, no decorrer da série temporal (1991-2020), apresentaram ciclos anuais bem definidos, como 1995-1997, 2000-2002, 2004-2006 e 2008-2009 ambos acima da média climatológica. Por outro lado, os anos de 1993-1994, 2010-2013 e 2015-2019, ficaram abaixo da média (Figura 10c). Estudos anteriores sugerem que esses ciclos com reduções contrastantes nos padrões de chuva na região em estudo estejam relacionados a ocorrência de ENOS (PAREDES-TREJO et al., 2021; MARENGO et al., 2018), que historicamente influencia as condições de chuva e temperatura em grande parte do semiárido brasileiro (MARENGO; TORRES; ALVES, 2017; CORREIA FILHO et al., 2019; JARDIM et al., 2021a; FREITAS et al., 2022).

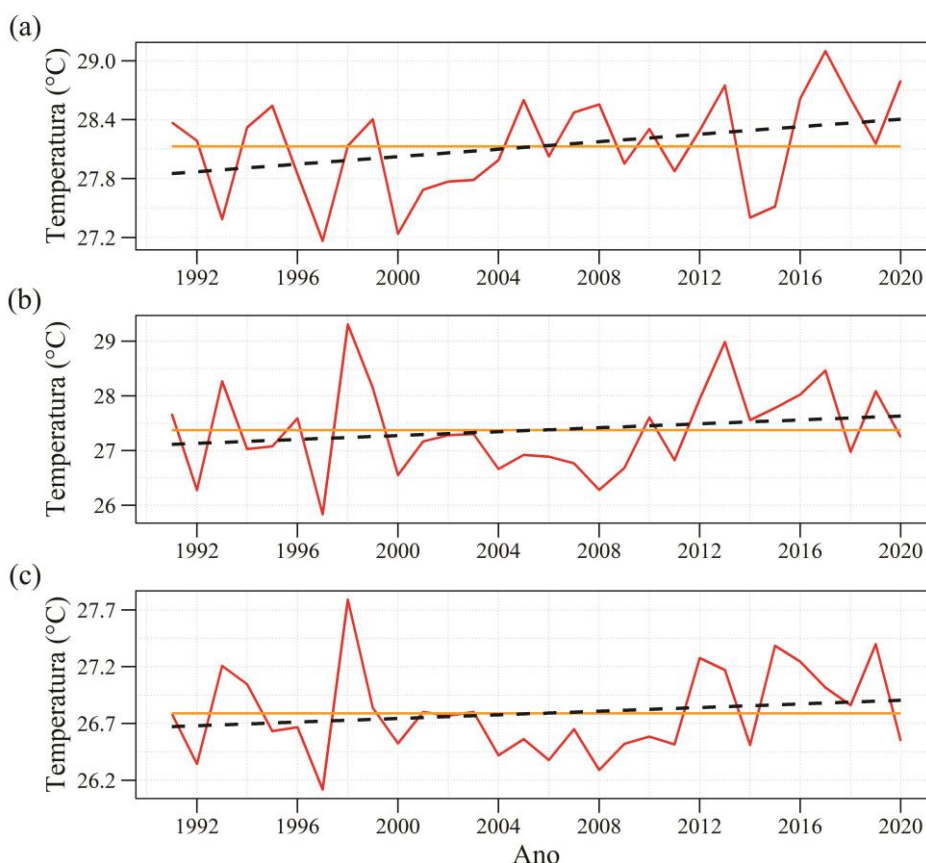
Tabela 6 - Análises de mudanças sazonais e anuais e tendências da precipitação pluviométrica, temperatura média do ar e vazão média utilizando os testes estatísticos de Mann-Kendall ( $Z_s$ ) e de tendência baseada na inclinação de Sen ( $Q$ ), durante o período de 1991-2020 na região em estudo da BHSF.

<b>Precipitação pluviométrica</b>					
<b>Período</b>	<b>Média</b> (mm)	<b>CV</b> (%)	<b><math>Z_s</math></b>	<b>p-valor</b>	<b>Q</b> (mm.ano <sup>-1</sup> )
NDJ	168,09	47,58	-1,855	0,062	-2,350
FMA	216,91	42,85	-0,107	0,915	-0,301
Anual (nov-out)	430,31	29,98	-1,105	0,269	-3,185
<b>Temperatura média do ar</b>					
<b>Período</b>	<b>Média</b> (°C)	<b>CV</b> (%)	<b><math>Z_s</math></b>	<b>p-valor</b>	<b>Q</b> (°C.ano <sup>-1</sup> )
NDJ	28,13	1,75	1,962	0,049	0,019
FMA	27,37	2,92	1,142	0,253	0,027
Anual (nov-out)	26,79	1,43	0,66	0,509	0,006
<b>Vazão média</b>					
<b>Período</b>	<b>Média</b> (m <sup>3</sup> .s <sup>-1</sup> )	<b>CV</b> (%)	<b><math>Z_s</math></b>	<b>p-valor</b>	<b>Q</b> (m <sup>3</sup> .s <sup>-1</sup> .ano <sup>-1</sup> )
NDJ	1435,20	26,50	-3,461	0,0005	-24,421
FMA	1633,20	59,55	-3,033	0,0024	-33,565
Anual (nov-out)	1511,2	30,43	-3,103	0,0019	-31,167

Os valores médios anuais da temperatura do ar para as estações chuvosas NDJ e FMA, foram de 28,13 °C e 27,37 °C, respectivamente. Os coeficientes de variação foram iguais a 1,75% (NDJ) e 2,92% (FMA), enquanto a temperatura média para o ano hidrológico (nov-out) teve variação entre (26,79 °C ± 0,382 °C) (Tabela 6). O teste estatístico de tendência MK indicou uma oscilação ligeiramente crescente nas estações NDJ e FMA e na temperatura média anual. Entretanto, apenas na estação NDJ essa oscilação foi significativa em  $\alpha = 0,05$  ( $|Z_s| > 1,96$ ), com aumento de 0,019 °C.ano<sup>-1</sup> de acordo com a inclinação de Sen, o que significa que a temperatura média para a estação NDJ aumentou 0,57 °C entre 1991 e 2020. (Tabela 6 e

Figura 11). Diversos estudos apontam aumentos significativos da temperatura média no semiárido brasileiro (TOMASELLA et al., 2018; MARENGO et al., 2020).

Figura 11 - Temperatura média do ar para a estação NDJ na região em estudo da BHSF durante o período de 1991–2020. (a) A estação chuvosa de NDJ (novembro, dezembro e janeiro), (b) a estação chuvosa de FMA (fevereiro, março e abril) e (c) o ano hidrológico (novembro-outubro). A linha de tendência linear (preta) é baseada na inclinação de Sen, significativa em  $\alpha = 0,05$ . A linha laranja representa a média climatológica.



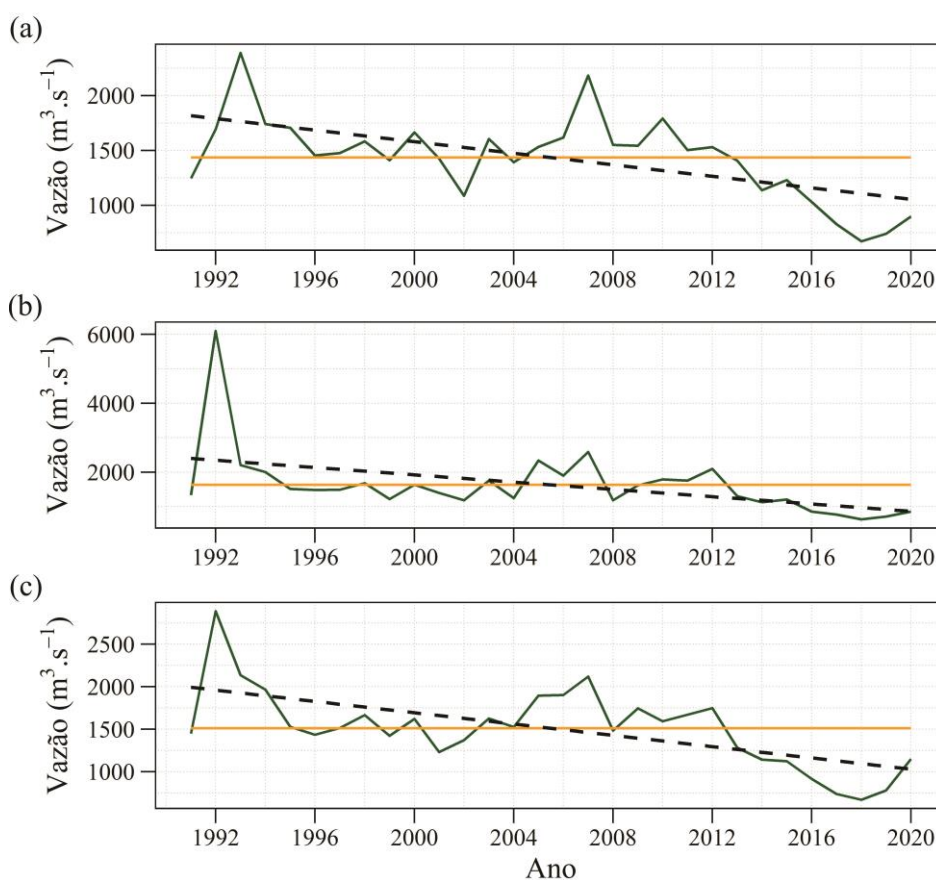
A análise da variabilidade das vazões médias anuais do rio São Francisco na sua sub-região, usando o teste MK e o método de inclinação de Sen mostrou uma tendência de redução significativa ( $\alpha = 0,05$ ) nos anos de 1991–2020 (Figura 12). Essa tendência negativa foi observada tanto para a vazão média anual quanto para as vazões médias sazonais (NDJ e FMA) (Tabela 6).

No geral, a vazão média anual reduziu  $935 \text{ m}^3 \cdot \text{s}^{-1}$  entre 1991 e 2020. Vale ressaltar que, a partir de 2012 a vazão anual do reservatório começou a diminuir até 2019, permanecendo a baixo da média entre 2012 e 2020 (Figura 12). Além disso, a vazão apresenta ocorrência de dois picos de anomalias positivas, ocorridos nos anos de 1992 e 2007 (Figura 12c); com destaque para o ano de 1992, que durante a estação FMA apresentou vazão média de  $6100,50 \text{ m}^3 \cdot \text{s}^{-1}$  (Figura 12b). Estudos realizados por Vasco et al. (2017) analisaram os impactos das

usinas hidrelétricas na disponibilidade hídrica do Nordeste brasileiro, e constataram redução dos picos de vazão do rio São Francisco após a construção dos reservatórios de Sobradinho e Xingó nos anos de 1980 e 1993, respectivamente.

A redução das vazões deve estar associada a tendência decrescente da precipitação, mas também com a tendência de aumento da temperatura do ar (Tabela 6), com ênfase nos anos de 2012 a 2017 (Figura 9 e 12). A persistência de elevados valores de temperatura do ar intensifica o processo de evaporação de grandes espelhos d'água, como o lago artificial de Sobradinho que é um dos maiores do mundo (4214 km<sup>2</sup> em sua fase normal) (GENZ; LUZ, 2012; MARTINS et al., 2018b). Segundo Vasco et al. (2019), à evaporação devido aos reservatórios de acumulação implantados ao longo do rio São Francisco, é responsável por grande parte das alterações no regime de vazões.

Figura 12 - Vazão média anual do rio São Francisco na sua sub-região durante o período de 1991–2020 com base nos dados médios mensais das estações fluviométricas da ANA. (a) A estação chuvosa de NDJ (novembro, dezembro e janeiro), (b) a estação chuvosa de FMA (fevereiro, março e abril) e (c) o ano hidrológico (novembro-outubro). Tendência linear (preto) com base na inclinação de Sen. Significativa em  $\alpha = 0,05$ .



Segundo Sun et al. (2016), reduções prolongadas nas chuvas afetam drasticamente a disponibilidade hídrica da BHSF. Medeiros et al. (2018) mostraram que alguns reservatórios da região Nordeste do Brasil (NEB) são afetados pela variabilidade anual das chuvas em anos

extremos. Vale ressaltar, a influência da regulação do represamento de água pelas barragens das hidrelétricas na redução das vazões, principalmente durante períodos de seca, a fim de assegurar a produção de energia elétrica.

Aliadas, as mudanças no clima, a má gestão dos recursos naturais e os distúrbios exacerbados no uso da terra contribuem maciçamente para o declínio das vazões do rio São Francisco. Devido, principalmente, à retirada da cobertura vegetal, impulsionada pela alta demanda por alimentos, crescimento urbano, exploração e expansão de áreas de pastagens, mineração e pela constante extração de madeira (ARNAN et al., 2018; ANTONGIOVANNI et al., 2020; CUNHA et al., 2020; SANTOS; NASCIMENTO; SILVA, 2020; TEIXEIRA et al., 2021b).

A retirada da vegetação nativa contribui para menor interceptação de chuvas, redução da taxa de infiltração de água no solo, aumento do fluxo superficial e, conseqüentemente, redução do armazenamento subterrâneo e aumento da suscetibilidade do solo aos processos erosivos. Esses aspectos, diminuem a capacidade e a vazão das nascentes, cursos d'água e reservatórios, agravando os problemas de disponibilidade hídrica e assoreamento do rio São Francisco (FRANCISCO et al., 2013; CANTALICE et al., 2019; SANTOS et al., 2020; MELO; ARAÚJO FILHO; CARVALHO, 2020).

### **4.3 Ocorrência de eventos de seca para o período 1991-2020**

As características de mudança da seca meteorológica e hidrológica são comparadas por meio dos índices SPI e SSI (Figura 13). O SPI e SSI foram calculados para períodos de 3 meses (SPI-3 e SSI-3), representando estações secas ou chuvosas de curto prazo, e 12 meses (SPI-12 e SSI-12), representando anos secos ou chuvosos de longo prazo.

O teste MK e o método de inclinação de Sen indicam tendências significativas ( $\alpha = 0,05$ ) de aumento da frequência e severidade das secas meteorológicas de longo prazo entre os anos de 1991 e 2020 ( $Z_s = -3,688$ ,  $Q = -0,0017$  unidades de  $\text{SPI.mês}^{-1}$ ), que resultou em uma redução de 0,612 unidades de SPI-12 (de 0,352 para  $-0,260$ ) durante os anos de 2001-2020 (Tabela 7). Estudos recente realizados na BHSF, apontam uma tendência de intensificação da severidade, duração e frequência das secas meteorológicas de longo prazo (JONG et al., 2018; TOMASELLA et al., 2018; MARTINS et al., 2018b; PAREDES-TREJO et al., 2021). Essa tendência de aumento dos eventos de seca na região de estudo, deve estar relacionada principalmente ao efeito da redução da precipitação no período de 2012 a 2018 e ao aumento da temperatura do ar na estação chuvosa NDJ.

Por outro lado, embora a série temporal de SPI-3 tenha apresentado tendência similar ( $Q = -0,0002$  unidades de  $\text{SPI.mês}^{-1}$ ), foi insignificativa em  $\alpha = 0,05$  ( $|Z_s| > 1,96$ ) (Tabela 7). Portanto, mesmo que não se possa concluir se houve intensificação dos eventos de seca meteorológica de curto prazo de 1991 a 2020, estes resultados indicam que esses eventos ocorrem com certa frequência na região em estudo. Brito et al. (2018) relatam que a inclinação de Sen aumenta com o aumento da escala de tempo de agregação.

Tabela 7 - Análise de tendência dos parâmetros biofísicos dos índices de seca (SPI e SSI) utilizando os testes estatísticos de Mann-Kendall ( $Z_s$ ) e de tendência baseada na inclinação de Sen ( $Q$ ), durante o período de 1991-2020 na região em estudo da BHSF.

Índices	Média	Desvio padrão	$Z_s$	p-valor	$Q$ (unidades.mes <sup>-1</sup> )
SPI-3	0,049	1,02	-3,688	$2,2*10^{-4}$	-0,0017
SPI-12	0,022	1,01	-10,740	$2,2*10^{-16}$	-0,0059
SSI-3	0,004	1,01	-0,314	$7,4*10^{-1}$	-0,0002
SSI-12	0,013	1,00	-10,745	$2,2*10^{-16}$	-0,0054

Em relação ao SSI, o teste MK e método de inclinação Sen indicam tendências significativas ( $\alpha = 0,05$ ) de intensificação da severidade e duração das secas hidrológicas a curto e longo prazo, o que permite aferir que existe uma tendência de redução de  $-1,93$  e  $-2,13$  unidades de SSI-3 (de 1,06 para  $-0,87$ ) e SSI-12 (de 1,11 para  $-1,02$ ), respectivamente, ao longo do período de 1991 a 2020.

As secas meteorológicas e hidrológicas tiveram características de mudança diferentes, com baixa relação de propagação entre o SPI e o SSI. Os valores dos coeficientes de correlação foram 0,12 (SPI-12/SSI-12) e 0,03 (SPI-3/SSI-3). Em geral, as séries temporais do SPI apresentaram constantes oscilações entre estações úmidas e secas de 1991 a 2020. No entanto, em geral, as séries temporais do SSI apresentaram um comportamento mais estável de 1991 a 2020 (Figura 13). Os valores de SSI começam a reduzir em média 8,9 meses após o início da redução dos valores de SPI. Contudo, a propagação da seca meteorológica para seca hidrológica ocorreu em uma escala de tempo de 48 meses.

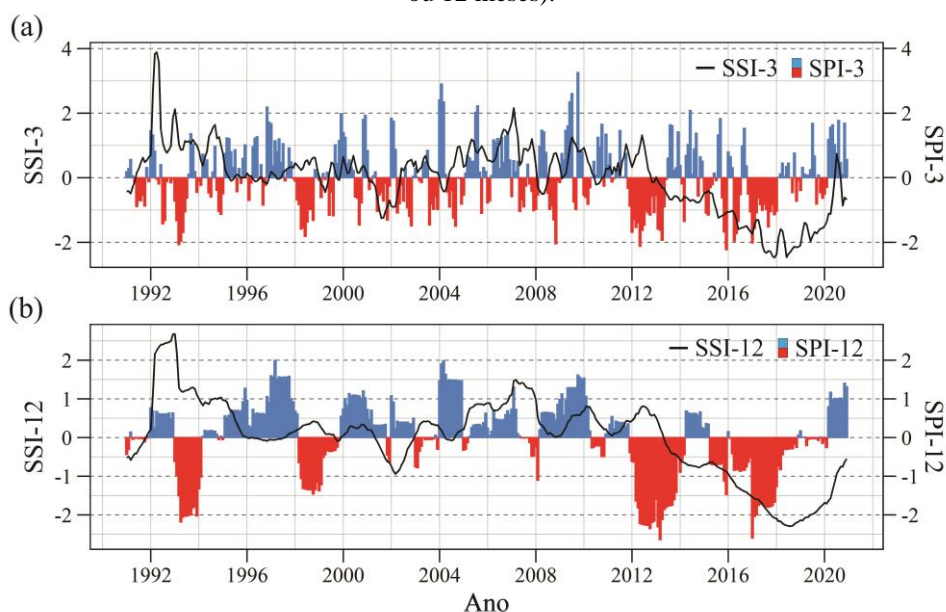
A vazão do rio São Francisco na região em estudo é profundamente afetada em termos de magnitude e regime temporal pela gestão operacional do reservatório de Sobradinho. Neste caso, é importante destacar que, o reservatório armazena água para geração de energia durante a estação chuvosa, de modo, a diminuir a magnitude das vazões a jusante do reservatório, em seguida, durante a estação seca, o volume armazenado é gradualmente liberado promovendo aumento da magnitude das vazões (GENZ; LUZ, 2012; JONG et al., 2018); condição observável em alguns eventos onde o SPI e SSI apresentam oscilações opostas, principalmente em escala de tempo de curto prazo (SPI-3/SSI-3) (Figura 13).



Essa situação, por sua vez, atrasa o processo de propagação da seca meteorológica para a seca hidrológica, característica essa que explica a fraca correlação entre o SPI e o SSI, principalmente em uma escala de tempo de curto prazo (VAN LOON; LAAHA, 2015; PAREDES-TREJO et al., 2021). Além disso, mesmo após o fim dos eventos de seca os reservatórios levam algum tempo para atingirem níveis normais de armazenamento, refletindo em atrasos no aumento das vazões.

De acordo com o Operador Nacional do Sistema Elétrico do Brasil (ONS) (<https://www.ons.org.br>) os sucessivos eventos de seca meteorológica ocorridos entre os anos de 2012 e 2018 afetaram o armazenamento de água do reservatório de Sobradinho que atingiu o menor nível de armazenamento em novembro de 2015 com 1,11% (ANA, 2023). Portanto, aumentos expressivos das vazões do rio São Francisco, a jusante do reservatório de Sobradinho, só foram verificados a partir de março de 2018, após o fim dos eventos de seca meteorológica.

Figura 13 - Valores SSI-3 e SPI-3 (a) e SSI-12 e SPI-12 (b) de 1991–2020. Azul indica condições relativamente úmidas, enquanto vermelho indica condições relativamente secas no período de tempo antecedente indicado (3 ou 12 meses).



Comparando os índices SPI e SSI, a frequência do SPI foi a maior entre eles, sendo de 5 a 7 vezes a do SSI. No entanto, a duração média do SPI foi mais curta enquanto a do SSI foi mais longa (Tabela 8 e 9). Quando comparadas em diferentes escalas de tempo, a frequência de eventos de seca meteorológica (SPI) e hidrológica (SSI) diminuiu com o aumento da escala de tempo, mas a duração de ambos os eventos de seca aumentou (Figura 13). Por conseguinte, o SPI-3 e SSI-3 foram capazes de detectar mais eventos de seca (15 e 2, respectivamente) em comparação com o SPI-12 e SSI-12 (5 e 1, respectivamente). Segundo Verhoeve et al. (2021),



pequenos eventos de seca identificados em escala de curto prazo podem ser simplificados ou acumulados em um evento de seca em escala de longo prazo.

A série temporal de SPI-3 mostra que a região em estudo apresenta uma constante ocorrência de pequenos eventos de seca de curto prazo. No entanto, na última década a frequência e duração desses eventos se intensificou (Figura 13a e Tabela 8). A frequência de secas meteorológicas de curto prazo durante o período de 1991 a 2010 foi de 0,35 vezes por ano, com duração média de 3,14 meses e severidade média de 4,48. Por outro lado, no período de 2011 a 2020 a frequência de secas meteorológicas de curto prazo foi 0,80 vezes por ano, com duração e severidade de 3,50 meses e 4,87 em média, respectivamente.

A frequência de secas meteorológicas de longo prazo para a região em estudo durante o período de 1991 a 2020 foi de 0,17 vezes por ano, com duração média de 11,80 meses e severidade média de 20,86 (Tabela 8). Com base no SPI-12, houve um total de 5 eventos de secas meteorológicas no período histórico estudado, sendo que 3 eventos ocorreram de 2011 a 2020 e os demais de 1991 a 2000. Dois desses eventos corresponderam a secas moderadas ( $1,00 < \text{SPI} < -1,49$ ) e três eventos foram classificados como seca extrema ( $\text{SPI} < -2,00$ ) (Tabela 7).

Tabela 8 - Características dos principais eventos de seca meteorológica identificados na região em estudo da BHSF durante 1991 a 2020.

Escala de Tempo (Meses)	Evento	Início (Data)	Fim (Data)	Duração (Meses)	Intensidade (-)	Área Seca (%)	Severidade (-)
SPI3	E1	fevereiro-93	junho-93	5	2,08	95,14	8,13
	E2	abril-98	outubro-98	7	1,82	88,50	9,62
	E3	janeiro-12	outubro-12	10	2,12	97,71	14,41
	E4	fevereiro-13	abril-13	3	1,94	98,51	5,16
	E5	novembro-15	dezembro-15	2	2,23	93,64	3,91
	E6	dezembro-16	março-17	4	2,02	97,43	5,74
	E7	setembro-17	outubro-17	2	1,52	76,38	2,58
	E8	dezembro-17	janeiro-18	2	1,14	77,70	2,17
Escala de Tempo (Meses)	Evento	Início (Data)	Fim (Data)	Duração (Meses)	Intensidade (-)	Área Seca (%)	Severidade (-)
SPI12	E1	março-93	fevereiro-94	12	2,18	99,60	21,74
	E2	abril-98	fevereiro-99	11	1,46	91,34	14,29
	E3	março-12	novembro-13	21	2,63	100,00	42
	E4	novembro-15	dezembro-15	2	1,47	89,71	2,59
	E5	janeiro-17	janeiro-18	13	2,63	95,40	23,66

O evento de seca meteorológica mais severa para cada escala de tempo ocorreu de janeiro de 2012 a outubro de 2012 (SPI-3) e de março de 2012 a novembro de 2013 (SPI-12). Este último evento foi o pior evento de seca extrema em termos de severidade (42), duração (21 meses) e abrangência espacial de 100% registrado na região em estudo ao longo de 1991-2020 (Tabela 8).

É importante salientar que, a recorrência média entre os eventos de longo prazo (SPI-12) E3, E4 e E5 foi de 17 meses. Conforme mostrado em estudos anteriores, a BHSF apresentou intensa redução da umidade do solo e dos recursos hídricos a partir do final de 2011, persistindo até 2019 (SUN et al., 2016; PAREDES-TREJO et al., 2021) coincidindo com a ocorrência dos eventos de seca meteorológica de longo prazo (SPI-12) E3, E4 e E5 (Tabela 8). Os eventos recorrentes de seca registrados no Nordeste brasileiro entre 2011 e 2019 foram considerados os mais graves em termos de extensão, duração, gravidade e recorrência nos últimos 30 anos (CUNHA et al., 2018; CUNHA et al., 2019).

Dos eventos de seca ocorridos em 1993-1994, 1998-1999 e 2012-2013 e 2015-2018, apenas os eventos de 1998 e 2015-2016 ocorreram como consequência do El Niño, com abrangência de grande parte do semiárido brasileiro (CUNHA et al., 2019; MARENGO et al., 2018). Enquanto, os eventos de seca registrados em 1993-1994 ocorreram durante a fase neutra do ENSO (NOAA/CPC, 2020).

Apesar dos anos 1993-1994 serem anos de fase neutra do ENSO, a redução dos volumes de chuva foi influenciada pela ocorrência de El Niño no ano de 1992 (CAVALCANTI, 2015). Por outro lado, em 2012 a seca ocorreu durante um evento de La Niña (Anos de ENSOs listados em: [https://psl.noaa.gov/enso/past\\_events.html](https://psl.noaa.gov/enso/past_events.html)), esse evento de seca esteve associado ao posicionamento mais ao norte da ZCIT e a formação de vórtices ciclônicos e cavados em altos níveis próximos sobre a costa leste da Região Nordeste, juntamente com o posicionamento mais ao sul dos eventos de ZCAS, esses eventos estiveram relacionados a anomalias no gradiente meridional de TSM no Atlântico Tropical (CLIMANÁLISE, 2023).

Os resultados obtidos no presente estudo, sugerem que nem todos os anos de El Niño provocam eventos de secas na região em estudo da BHSF, ou que nem todas as secas na região em estudo da BHSF estão relacionadas a ocorrência de El Niño.

A tendência de intensificação da frequência e severidade dos eventos de seca hidrológica baseada no SSI-12 tendeu a aumentar a partir de 2012 até junho de 2020, atingindo seu pico entre os anos de 2017 e 2018 (Figura 13b). Ao analisar os parâmetros de gravidade e duração, esse evento de seca hidrológica foi o pior evento de seca extrema em termos de gravidade (94,99) e duração (53 meses) ocorrido no período de 1991-2020 (Tabela 9). Vale ressaltar que esse episódio atingiu picos de SSI superiores a 2 no período entre novembro de 2017 e junho de 2019 (Figura 13 b), enquadrando-se na categoria de seca extrema.

Tabela 9 – Características dos principais eventos de seca hidrológica identificados na região em estudo da BHSF durante 1991 a 2020.

Escala de Tempo (Meses)	Evento	Início (Data)	Fim (Data)	Duração (Meses)	Intensidade (-)	Gravidade (-)
SSI3	E1	agosto-15	abril-2020	57	-2,46	96,48
SSI12		fevereiro-16	junho-2020	53	-2,29	94,99

Os resultados do SSI obtidos no presente estudo, evidenciam que as mudanças hidrológicas ocorridas no Submédio São Francisco não estão atreladas somente a escassez de chuvas na região, mas aos efeitos dos grandes reservatórios, principalmente a barragem de Sobradinho, e dos perímetros irrigados que além da redução das vazões podem aumentar o déficit hídrico em alguns períodos do ano, corroborando com resultados obtidos em estudos anteriores (TEIXEIRA et al., 2009; GENZ; LUZ, 2012; VASCO et al., 2017; VASCO et al., 2019).

#### 4.4 Cobertura Vegetal e Resiliência

Os efeitos das secas e chuvas sazonais no comportamento temporal inter e intra-anual da dinâmica da cobertura vegetal foram avaliados comparando os valores médios de 8 dias das imagens MODIS ao longo da série temporal de 2001-2020 com os valores de SPI-3 e SPI-12. Em geral, a dinâmica interanual da cobertura vegetal mostrou mudanças significativas na linha de tendência para os quatro parâmetros biofísicos (NDVI, LAI, NDMI e LST) (Tabela 9 e Figura 14).

Tabela 10 – Análise de tendência dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) utilizando os testes estatísticos de Mann-Kendall (ZS) e de tendência baseada na inclinação de Sen (Q), durante o período de 2001-2020 na região em estudo da BHSF.

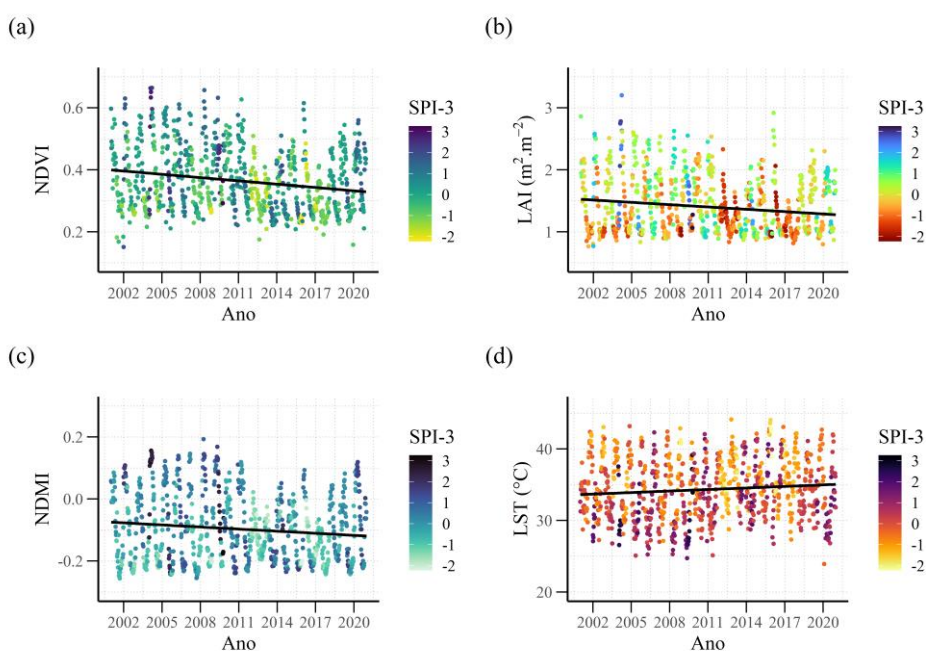
Parâmetros biofísicos	Média	CV (%)	Zs	p-valor	Q (ano)
NDVI	0,363	27,818	-6,132	0,062	-0,0021
LAI (m <sup>2</sup> .m <sup>-2</sup> )	1,399	32,449	-3,980	0,915	-0,0044
NDMI	-0,097	111,516	-2,910	0,915	-0,0010
LST (°C)	34,330	12,083	3,1282	0,269	0,0531

Há uma semelhança esperada entre as observações de NDVI, LAI e NDMI tanto na série temporal, quanto na análise de tendência, com uma indicação clara dos efeitos dos eventos de seca no período de 2001-2020. A análise das tendências de NDVI, LAI e NDMI de longo prazo usando o teste MK e o método de inclinação de Sen indicaram variações significativas decrescentes (Tabela 10), que resultaram em reduções de 0,063 unidades de NDVI (de 0,400 para 0,337), 0,132 m<sup>2</sup>.m<sup>-2</sup> de LAI (de 1,525 para 1,393) e 0,030 unidades de NDMI (de -0,075

para  $-0,105$ ) durante os anos de 2001-2020 (Tabela 10 e Figura 14). Portanto, a linha de tendência ajustada indica que, ao longo do período de análise, em média, os valores de NDVI, LAI e NDMI diminuíram 15,75%, 8,6% e 28,56%, respectivamente (Figura 14).

Por outro lado, a LST apresentou tendência significativa crescente (Tabela 10), que resultou em um aumento de 4,74% dos valores de LST (de 33,619 para 35,212) durante os anos de 2001-2020, ou seja, 1,593 °C. Ressalta-se que, tendências de longo prazo da LST podem fornecer informações sobre as mudanças climáticas, uma vez que existe uma forte concordância nas tendências de longo prazo entre a LST e a temperatura do ar (REINERS et al., 2023).

Figura 14 - Séries interanuais compostas por valores médios derivados das imagens MODIS de 8 dias (a) NDVI, (b) LAI, (c) NDMI e (d) LST. Os valores dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) foram classificados de acordo com os valores de SPI-3, que indicam condições de seca ( $SPI-3 < -1$ ) ou úmidas ( $SPI-3 > 1$ ). Uma linha de tendência (preta) foi ajustada em todos os dados com base na inclinação de Sen (significativa em  $\alpha = 0,05$ ).



Os valores SPI-3 nas séries temporais de NDVI, LAI, NDMI e LST ao longo dos anos 2001-2020 indicam um comportamento sazonal da cobertura vegetal, com menores valores médios de NDVI ( $0,333 \pm 0,085$ ), LAI ( $1,198 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,333 \text{ m}^2 \cdot \text{m}^{-2}$ ), NDMI ( $-0,148 \pm 0,084$ ) e LST ( $33,890 \text{ }^\circ\text{C} \pm 4,078 \text{ }^\circ\text{C}$ ) durante a estação seca (maio-outubro) e expressivo aumento dos valores de NDVI ( $0,396 \pm 0,104$ ), LAI ( $1,603 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,468 \text{ m}^2 \cdot \text{m}^{-2}$ ), NDMI ( $-0,045 \pm 0,104$ ) e LST ( $34,74 \text{ }^\circ\text{C} \pm 4,175 \text{ }^\circ\text{C}$ ), durante a estação chuvosa (novembro-abril) (Figura 14). É importante destacar que, o aumento da LST durante a estação chuvosa reflete o aumento da  $T_{\text{air}}$ , conforme observado na Figura 9b.

Conforme indicado pelos valores de SPI-3 nas séries temporais de NDVI, LAI, NDMI e LST ao longo dos anos 2001-2020, é possível observar que a cobertura vegetal respondeu drasticamente aos eventos de seca ocorridos de 2012 a 2018 (Figura 14). Os valores médios de NDVI, LAI e NDMI para a estação chuvosa NDJ reduziram em média 28,64%, 30,96% e 84,78% entre os anos de 2011 e 2018, respectivamente. No mesmo período durante a estação chuvosa FMA os valores médios de NDVI, LAI e NDMI reduziram em média 18,21%, 18,40% e 40,35%, respectivamente (Figura 14 a, b, c). Por outro lado, os valores médios de LST para as estações chuvosas NDJ e FMA aumentaram em média 9,63% e 13,25% entre os anos de 2012 e 2018, respectivamente (Figura 14 d). Estes resultados coincidem com a ocorrência de um forte evento de El Niño entre os anos de 2012 e 2019 (CUNHA et al., 2019; PAREDES-TREJO et al., 2021).

Outra característica que merece destaque é a ocorrência de um forte pico, que atingiu valores de NDVI, NDMI, LAI e LST de 0,664, 0,156, 3,202  $m^2.m^{-2}$  e 28,014  $^{\circ}C$ , respectivamente, durante a estação chuvosa FMA de 2004 (Figura 14), com padrão semelhante entre os anos de 2008 e 2009. Os picos fortes que foram observados durante 2004, 2008 e 2009 correspondem ao esverdeamento da vegetação na região em estudo que foi produzido por fortes chuvas decorrentes da atuação da Zona de Convergência Intertropical (ZCIT) e da presença de Vórtices Ciclônicos em Altos Níveis (VCAN) sobre o Oceano Atlântico. Contudo, é importante ressaltar a atuação conjunta das Linhas de Instabilidade (LI's) e de dois episódios de Distúrbios Ondulatórios de Leste (DOL's) que ocorreram durante o mês de abril de 2009 (CLIMANÁLISE, 2023)

Os resultados indicam uma redução da cobertura vegetal na região em estudo da BHSF nas últimas décadas. As principais causas para esse declínio da cobertura vegetal podem estar relacionadas a influência das atividades humanas, principalmente, o desmatamento da Caatinga e degradação da pastagem. A segunda causa está relacionada as mudanças climáticas, que na região em estudo tem provocado o aumento da temperatura do ar (Figura 11) e da frequência e duração das secas, conforme exemplificado pelos valores do SPI (Figura 14).

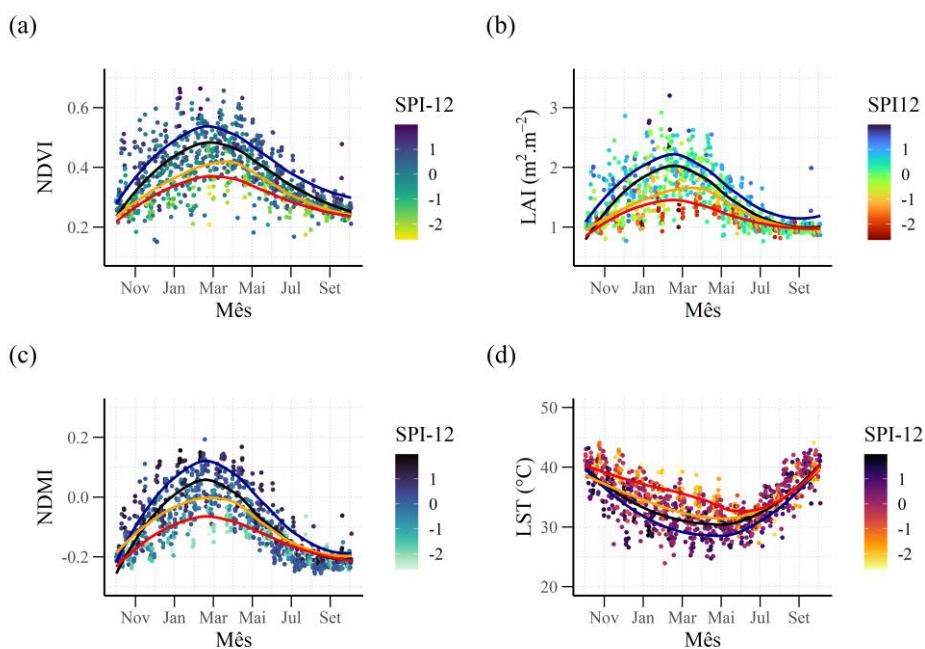
Conforme estudos anteriores, o bioma Caatinga tem sido afetado pelo aumento da intensidade do uso da terra, decorrente de atividades humanas, sem o manejo adequado (por exemplo: agricultura de baixa tecnologia, pecuária extensiva e extrativismo vegetal (ANTONGIOVANNI; VENTICINQUE; FONSECA, 2018). Segundo Santos, Nascimento e Silva (2020) durante o período de 2000 a 2018 o semiárido brasileiro perdeu cerca 26,96% da cobertura de vegetação florestal nativa, equivalente a 60.769,39  $km^2$ . É importante destacar que, a pecuária extensiva no bioma Caatinga também se desenvolve em áreas de vegetação

nativa, desse modo, o sobrepastoreio e pisoteio degradam não somente as áreas de pastagem, mas também as áreas de vegetação nativa afetando a estrutura, diversidade e composição das comunidades vegetais (TAVARES et al., 2016; ANTONGIOVANNI et al., 2020).

Em geral, os ecossistemas da Caatinga são geralmente frágeis e mais sensíveis a eventos de seca, sendo a cobertura vegetal da Caatinga altamente dependente da variabilidade intra-anual e interanual das chuvas. Portanto, as condições climáticas quando aliadas a intensificação de atividades antrópicas podem causar sérios danos aos serviços ecossistêmicos (JARDIM et al., 2022; SILVA et al., 2023).

Na Figura 15 os valores dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) foram plotados em função do ano hidrológico (novembro-dezembro). Adicionalmente, foram plotadas linhas de regressão polinomial dos valores dos parâmetros biofísicos durante anos secos (vermelho;  $SPI-12 < -1$ ), úmidos (azul;  $SPI-12 > 1$ ) e normais (preto;  $-1 < SPI-12 < 1$ ), juntamente com uma linha adicional (cor amarela) que representa os valores dos parâmetros biofísicos em um ano subsequente a um ano seco (ano de recuperação).

Figura 15 - Série interanual baseada em valores de NDVI (a), LAI (b), NDMI (c) e LST (d) derivados das imagens MODIS de 8 dias para o período de 2001 a 2020. Com base no SPI-12 do ano hidrológico, as linhas representam os valores de NDVI (a), LAI (b), NDMI (c) e LST (d) pertencentes a anos normais (preto), secos (vermelho), chuvosos (azul) ou a um ano subsequente a um ano hidrológico seco (amarelo) com o uso de suavização de gráfico de dispersão estimado localmente (LOESS).



Aparentemente, os anos classificados como normais no período de 2000-2020 apresentaram boa distribuição das chuvas durante o período chuvoso novembro-abril,

proporcionando boas condições para o crescimento e desenvolvimento da vegetação, expressas pelos elevados valores de NDVI, LAI, NDMI e baixos valores de LST durante o período chuvoso. Em geral, os anos chuvosos apresentam maiores valores de NDVI, LAI e NDMI e menores valores de LST em relação aos anos normais, devido ao aumento da cobertura vegetal e maior biomassa.

Por outro lado, em anos secos os valores de NDVI, LAI e NDMI apresentam expressiva redução em relação aos anos normais, seguida de aumento dos valores de LST, principalmente entre os meses de dezembro a abril, indicando um declínio da cobertura vegetal devido as condições estressantes de seca, que comprometeram a saúde e vitalidade da vegetação (Figura 15). Por conseguinte, nos anos seguintes a um ano de seca, os valores de NDVI, LAI e NDMI continuaram próximos dos valores de um ano seco, o que indica uma baixa capacidade de recuperação da vegetação encontrada na região em estudo. Ao que se pode observar, os efeitos da seca têm afetado a cobertura vegetal a curto e longo prazo.

A baixa resiliência da vegetação observado neste estudo pode ser resultado de diferentes causas. Na região em estudo, grande parte da área de vegetação primária foi convertida em áreas de vegetação de pastagem, terras agrícolas e áreas não vegetadas (FERREIRA et al., 2020; JARDIM et al., 2022; SALAZAR et al., 2021), que em geral são constituídas por vegetação rala ou aberta com dossel menor e mais baixo, promovendo um menor recobrimento do solo. Além disso, a degradação da vegetação decorrente das mudanças da cobertura da terra, tornaram a região em estudo mais vulnerável as mudanças climáticas. Isso confirma os resultados de estudos anteriores que analisaram as tendências de desertificação no Nordeste do Brasil (VIEIRA et al., 2015; MARENGO et al., 2017 ; TOMASELLA et al., 2018; MARIANO et al., 2018).

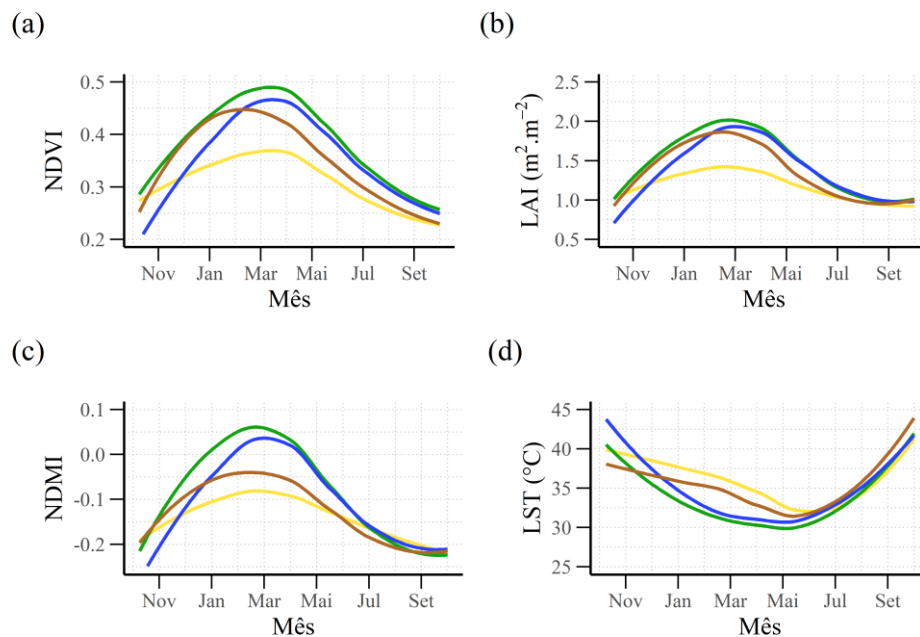
Finalmente, o aumento da duração, intensidade e frequência dos eventos de seca (Figura 13) tem fragilizado a cobertura vegetal. A seca não apenas reduz a umidade da vegetação, mas reduz o crescimento e desenvolvimento, e conseqüentemente a quantidade de vegetação verde. Além disso, os efeitos da variabilidade pluviométrica e da seca podem causar a mortalidade de diversas espécies vegetais, o que se reflete em menores valores de NDVI, LAI, NDMI e maiores valores de LST (BARBOSA et al., 2018; DOS SANTOS et al., 2020a; SILVA et al., 2023).

A ocorrência de anomalias de precipitação pode representar um desafio para compreender a dinâmica e produtividade do ecossistema. Assim, a caracterização das alterações ocorridas durante a estação chuvosa é essencial para estudos que buscam estudar as respostas da vegetação as mudanças climáticas. O momento da seca durante o ano hidrológico influenciou no padrão e na magnitude dos valores dos parâmetros biofísicos. Durante um ano em que as

estações chuvosas NDJ e FMA são normais (linha verde na Figura 16), o NDVI atingiu seu pico (0,48) no início de maio (Figura 16 a), enquanto os índices LAI e NDMI atingiram seus picos (2,12 e 0,07, respectivamente) no final e início de abril, respectivamente (Figura 16 b, c).

O NDMI por ser um índice que detecta os níveis de umidade na vegetação, é o primeiro entre os índices utilizados neste estudo a sinalizar a redução da disponibilidade hídrica no ambiente, desse modo o NDMI possibilita detectar o estresse hídrico numa fase antecipada, antes que o problema venha afetar o funcionamento morfofisiológico da vegetação, transparecendo em posteriores reduções nos valores de NDVI (pigmentos fotossintéticos) e LAI (área foliar), conforme observado na Figura 16. Diversos estudos relatam a eficiência do NDMI em detectar a ocorrência de estresse hídrico em sua fase inicial (GAZNAYEE et al., 2023; GHAZARYAN et al., 2020; JI et al., 2011; LI et al., 2022).

Figura 16 - Resposta sazonal dos índices NDVI (a), LAI (b), NDMI (c) e LST (d) em diferentes regimes de seca entre 2001 e 2020. A linha amarela representa a resposta dos índices em uma estação seca tanto durante o NDJ quanto em FMA, a linha verde representa que as duas estações foram normais e/ou chuvosas, a linha azul representa uma estação NDJ normal seguida por uma estação FMA seca e o marrom representa uma estação NDJ seca seguida por uma estação MAM normal.



Em geral, a ocorrência de seca durante a estação NDJ, FMA ou ambas as estações, impacta o desenvolvimento dos parâmetros biofísicos ao longo do tempo. Quando a estação chuvosa de NDJ foi normal, os índices NDVI, LAI e NDMI apresentaram inicialmente tendência similar aos anos com duas estações normais. No entanto, diminuiram rapidamente com a ocorrência de eventos de seca durante a estação de FMA (linha marrom), seus picos



foram verificados na segunda metade de março ( $\text{NDVI} = 0,46$ ,  $\text{LAI} = 2,16 \text{ m}^2 \cdot \text{m}^{-2}$  e  $\text{NDMI} = -0,022$ ) (Figura 16 a, b, c).

Durante um ano com a estação NDJ seca, mas com estação FMA normal, houve um atraso no desenvolvimento dos índices NDVI, LAI e NDMI, que posteriormente retornaram a níveis quase semelhantes aos de um ano normal (linha verde). Entretanto, os valores de pico dos índices NDVI, LAI e NDMI foram com cerca de 7 a 15 dias em relação a um ano com as duas estações chuvosas normais. Esses resultados indicam que a ocorrência de chuvas após pequenos eventos de seca possibilita a recuperação da vegetação da região em estudo, no entanto, a vegetação requer algum tempo para se recuperar. É importante destacar que as ocorrências sucessivas de eventos de seca podem vir a comprometer a resiliência se da vegetação.

Em relação LST, a ocorrência de estações de NDJ e FMA normais ou de apenas FMA normal, atenuou o aquecimento da superfície terrestre, através do aumento da cobertura vegetal, induzindo menores valores de LST, que atingiu valores mínimos no mês de junho ( $29,93 \text{ }^\circ\text{C}$ ) (Figura 16 d). Por outro, lado a ocorrência de seca durante as estações NDJ e FMA ou apenas FMA, promoveu maiores valores de LST, com valores mínimos observados durante o mês de julho ( $31,12 \text{ }^\circ\text{C}$ ), como resultado da menor incidência de radiação solar nesse período, esse atraso em relação aos anos com as duas estações chuvosas normais, está relacionado a menor recobrimento da superfície terrestre pela vegetação. Segundo Reiners et al. (2023) mudanças na cobertura vegetal da terra levam a mudanças de LST em um curto espaço de tempo.

#### **4.5 Análise multivariada das variáveis meteorológicas e parâmetros biofísicos**

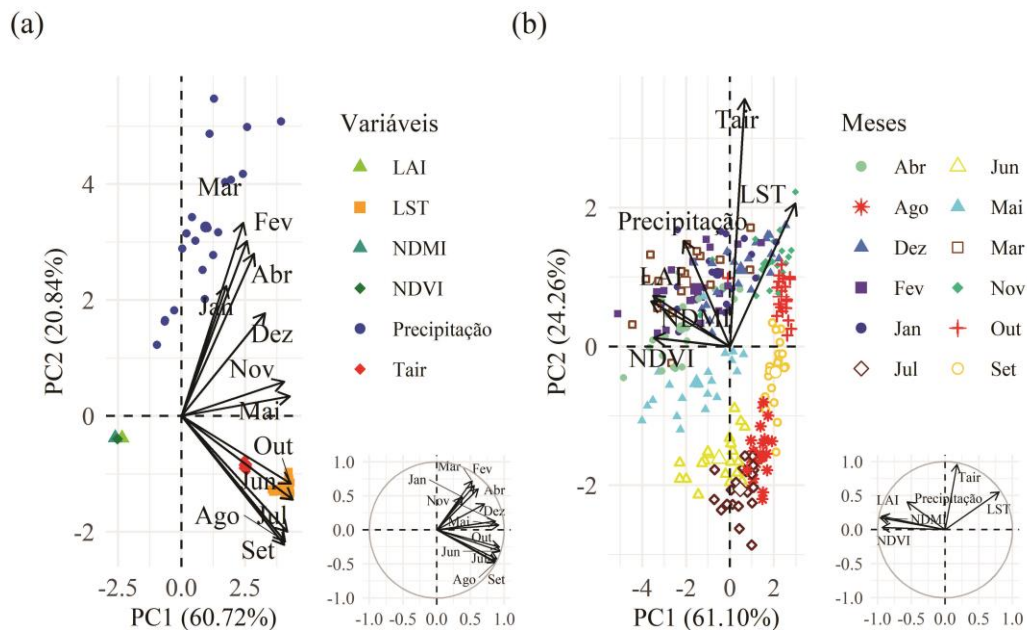
Neste estudo, foi realizada uma análise de componentes principais (PCA) que incluiu como variáveis os parâmetros biofísicos (NDVI, LAI, NDMI e LST), variáveis climáticas (precipitação e temperatura do ar) e os meses (Figura 17). Portanto, foram extraídos os dois primeiros componentes que atenderam o critério estabelecido por Kaiser (1958), com autovalores superiores a 1,0. Quando somados, os dois componentes principais explicaram em média 83,46% da variação total, sendo 60,91% no componente principal 1 (PC1) e 22,55% no componente principal 2 (PC2).

Na primeira PCA (Figura 17a) é possível observar a formação de três grupos bem distintos (dezembro-abril, junho-outubro, maio e novembro), governados pelas variáveis precipitação e temperatura do ar. O primeiro grupo é composto por meses com elevados valores de precipitação e temperatura do ar ( $T_{\text{air}}$ ), o segundo grupo por meses com menores valores

dessas variáveis e o terceiro grupo é composto por meses de transição entre a estação chuvosa e estação seca, com valores intermediários de precipitação e temperatura do ar.

De maneira geral, na segunda PCA (Figura 17b) o PC1 está relacionado a resposta das variáveis durante a estação chuvosa, enquanto o PC2 está relacionado a resposta das variáveis durante a estação seca. Além disso, os parâmetros biofísicos NDVI, NDMI e LAI apresentaram uma forte correlação positiva entre si, enquanto apresentaram forte correlação negativa com a LST. Por conseguinte, essas foram as variáveis com maior influência no PC1 com autovetores positivos e negativos, NDMI (0,95), LAI (0,94), NDVI (0,92) e LST (-0,79). Ao mesmo tempo que apresentou uma correlação negativa com os demais parâmetros biofísicos a LST apresentou correlação positiva com a Tair, sendo essas as variáveis com maior influência na PC2, com autovetores iguais a 0,55 e 0,95, respectivamente (Figura 17b).

Figura 17 - Pontuações obtidas pela análise de componentes principais (PCA), PC1 e PC2 são a primeira e a segunda dimensões dos dados da PCA, respectivamente, (a) análise de componentes principais dos meses em função das variáveis biofísicas (NDVI, LAI, NDMI e LST) e variáveis climáticas (precipitação e temperatura do ar); (b) análise de componentes principais das variáveis biofísicas e variáveis climáticas em função dos meses no período de 2001-2020 na região em estudo da BHSF.



Os resultados obtidos neste estudo, evidenciam que embora a LST esteja relacionada com fatores climáticos como Tair e disponibilidade de radiação solar, fatores ambientais como disponibilidade hídrica e cobertura vegetal interferem diretamente na resposta da LST. Segundo Cabral Júnior (2019), as variáveis biofísicas podem ser modificadas por efeitos climáticos locais devido aos impactos das atividades antrópicas na BHSF, como expansão da área de

agricultura irrigada, criação do Lago de Sobradinho e mudanças na cobertura da terra. Alguns estudos relatam que a LST fornece informações valiosas sobre as mudanças no uso e cobertura da terra e quando combinada com índices de vegetação torna-se um bom indicador do teor de umidade do solo, podendo ser utilizada como variável chave em estudos ambientais e climáticos (CUNHA et al., 2015; ELEFThERIOU et al., 2018; PANDEY et al., 2022).

Notavelmente, a precipitação influenciou na resposta dos parâmetros biofísicos (NDVI, LAI e NDMI), confirmando a importância da precipitação como propulsor da cobertura vegetal no bioma Caatinga. No entanto, tanto na PC1 (0,55), quanto na PC2 (0,41) a precipitação mensal não apresentou forte correlação com esses parâmetros (Figura 17b). Essa baixa correlação indica que a cobertura vegetal da região em estudo possui um atraso na resposta a ocorrência de chuvas.

#### 4.6 Variações espaço-temporais no uso e cobertura da terra

O uso e cobertura da terra em 2001 consistia em 10374,34 km<sup>2</sup> de Caatinga densa (arbórea e arbustiva) (46,00%), 10793,26 km<sup>2</sup> de formação vegetal não florestal (Caatinga herbácea, pastagem e agricultura de sequeiro) (47,86%), 708,06 km<sup>2</sup> de agricultura irrigada (3,14%), 405,39 km<sup>2</sup> de área não vegetada (infraestrutura urbana e solo exposto) (1,80%) e 270,89 km<sup>2</sup> de corpos hídricos (1,20%) (Figura 18a e Figura 19a). No entanto, conforme a análise de tendência e de transição (Tabelas 11 e 12), até o ano de 2020, a região em estudo da BHSF sofreu alterações temporais e espaciais, indicadas por tendências significativas e elevadas percentagens de transição entre as diferentes classes de uso e cobertura da terra.

Tabela 11 - Análises das mudanças anuais e tendências do uso e cobertura da terra utilizando os testes estatísticos de Mann-Kendall ( $Z_s$ ) e estimador de Sen ( $Q$ ), durante o período de 2001 a 2020 na região em estudo da BHSF.

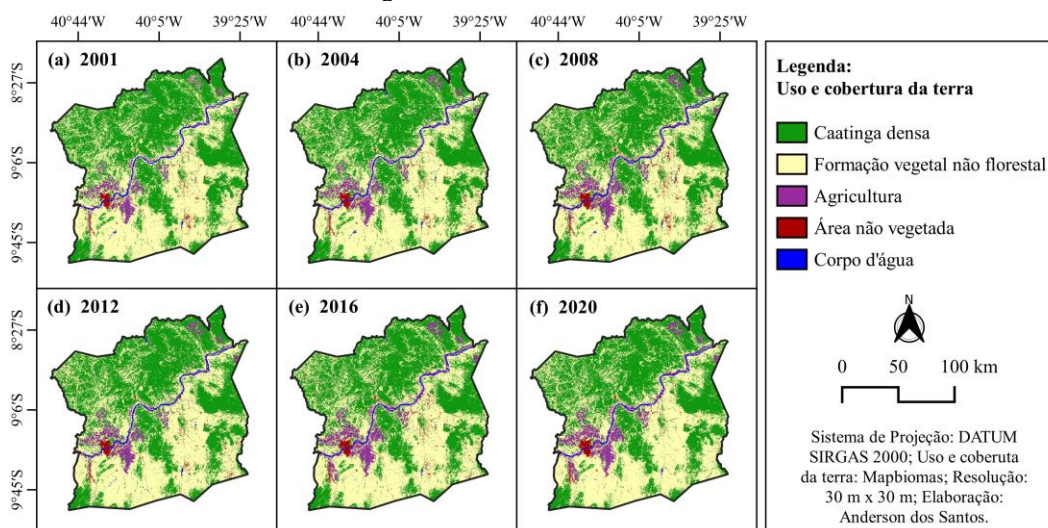
Mann-Kendall e inclinação de Sen	Classes de uso e Cobertura da terra				
	Caatinga densa	Formação vegetal não florestal	Agricultura	Áreas não vegetadas	Corpos hídricos
Média (km <sup>2</sup> )	10131	10767	943,4	449,5	254,6
CV (%)	1,559	0,425	15,384	14,581	9,333
$Z_s$	-4,380	1,006	5,871	1,394	-4,964
p-valor	$1,19 \times 10^{-5}$	0,314	$4,3 \times 10^{-9}$	0,163	$6,9 \times 10^{-7}$
$Q$ (km <sup>2</sup> .ano <sup>-1</sup> )	-24,876	2,106	24,527	4,551	-4,009

De maneira geral, entre os anos de 2001 e 2020 as áreas com vegetação nativa mais preservada, correspondentes a classe Caatinga densa, cobriram maior proporção de terras ao sul, entre os municípios de Petrolina e Orocó (cerca de 60,50%) no estado de Pernambuco. Por outro lado, as áreas que apresentam algum grau de possível degradação, correspondentes as

classes de área não vegetada e formação vegetal não florestal (Caatinga herbácea, pastagem e mosaico agricultura pastagem), cobriram maior proporção de terras ao norte, nos municípios de Juazeiro e Curaçá (cerca de 62,20%) no estado da Bahia (Figura 18).

A análise das tendências anuais do uso e ocupação da terra usando o teste MK e o método de inclinação de Sen mostrou uma oscilação decrescente significativa em  $\alpha = 0,05$  ( $|Z_S| > 1,96$ ) da classe Caatinga densa, com redução de  $24,876 \text{ km}^2 \cdot \text{ano}^{-1}$  (Figura 19a e Tabela 11). Além disso, é possível observar que no período de 2011 a 2015 a classe Caatinga densa apresentou intensificação da redução de sua área, representando uma cobertura de  $9908,6 \text{ km}^2$  em 2015, uma redução de 4,49% em relação a sua área total em 2001 (Figura 19a). Ressalta-se que, no presente estudo a classe Caatinga densa é composta por vegetação nativa arbórea e arbustiva.

Figura 18 - Classificação temática do uso e cobertura da terra do MapBiomás, entre os anos de 2001 a 2020, para a região em estudo da BHSF, Brasil.

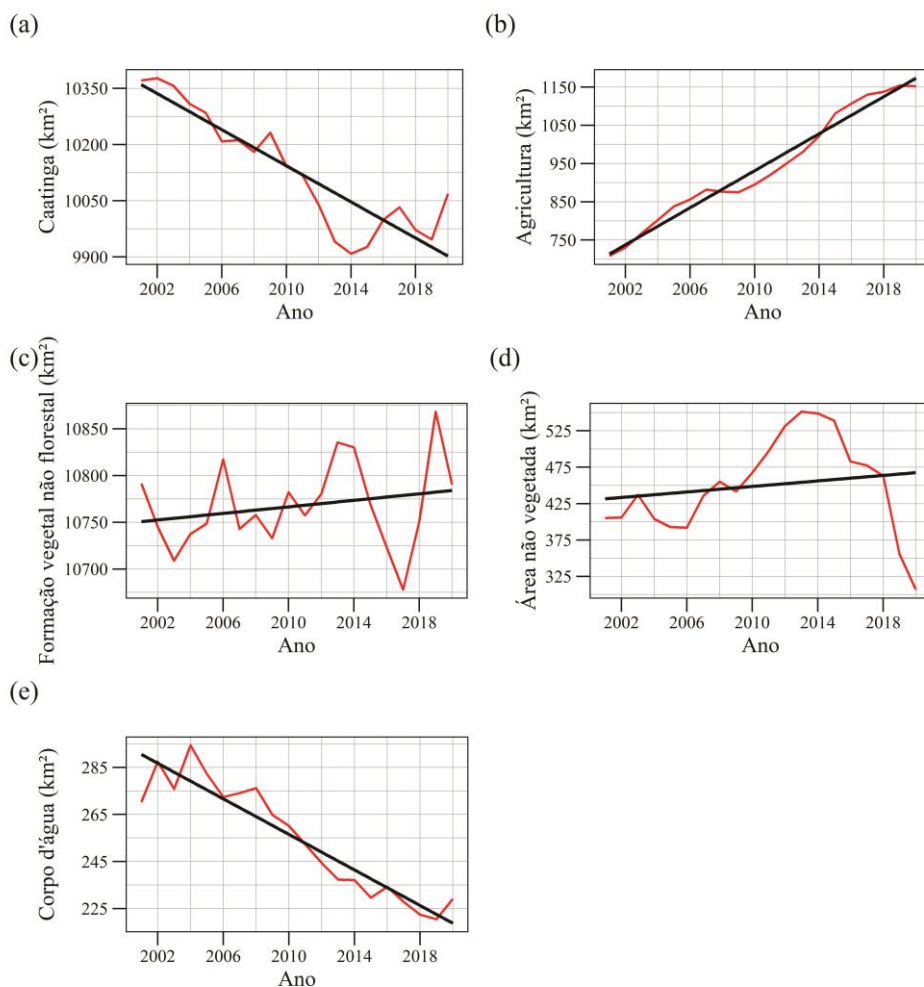


Conforme a matriz de transição do uso e cobertura da terra de 2001 a 2020 (Tabela 12), 94,01% da área de Caatinga densa ( $9.752,88 \text{ km}^2$ ) permaneceu inalterado; 1,05% da área de Caatinga densa ( $109,96 \text{ km}^2$ ) foi convertido em áreas destinadas à agricultura irrigada; e 4,81% da área de Caatinga densa ( $500,20 \text{ km}^2$ ) foi convertido em formação vegetal não florestal, representando a maior área de caatinga densa convertida em outros usos da terra.

A expansão de áreas de formação vegetal não florestal sobre a Caatinga densa, pode significar que atividades como a extração de madeira, queimadas e o pastejo extensivo continuam a aumentar na região em estudo da BHSF. Além disso, 0,08% da área de Caatinga densa ( $8,75 \text{ km}^2$ ) foi convertido em áreas não vegetadas. Estudos recentes realizados na região

semiárida do Brasil relatam a substituição da vegetação nativa da Caatinga por áreas de pastagens e agricultura, causando descontinuidade e isolamento dos remanescentes florestais (FERNANDES et al., 2020; JARDIM et al., 2022; SILVA et al., 2022; REFATI et al., 2023).

Figura 19 - Análise de tendência de Mann-Kendall e estimador de Sen para o quantitativo anual do uso e cobertura da terra na região em estudo da BHSF. (a) Caatinga densa, (b) formação vegetal não florestal, (c) agricultura (d) área não vegetada e (e) corpos hídricos.



É importante destacar que, 318,82 km<sup>2</sup> de outras classes de uso e cobertura da terra foram convertidos em Caatinga densa, dos quais 291,85 km<sup>2</sup> eram de formação vegetal não florestal (Caatinga herbácea, pastagem e mosaico agricultura pastagem) (Tabela 12). Estudos realizados no bioma Caatinga apontam que a expansão das áreas de Caatinga densa ocorre principalmente em áreas antes ocupadas por atividades agropecuárias ou em áreas de vegetação herbácea nativa degradada através do processo de sucessão ecológica (SILVA et al., 2020a; JARDIM et al., 2022), reforçando os resultados obtidos no presente estudo. No entanto, a perda

de áreas de Caatinga densa foi maior que o ganho, resultando em uma redução de 302,65 km<sup>2</sup> de vegetação de Caatinga densa no período de 2001 a 2020, ou seja, 2,92% (Tabela 12).

A área de agricultura (irrigada) cresceu continuamente ao longo da série temporal (Figura 19b), o que resultou em tendências crescentes significativas ( $\alpha = 0,05$ ), com incremento de 24,527 km<sup>2</sup>.ano<sup>-1</sup> (Tabela 11), aumentando sua porcentagem de cobertura em 62,70% no período de 2001-2020, o que equivale ao maior crescimento percentual entre as classes de uso e cobertura da terra (Figura 19b). A expansão da atividade agrícola, em sua grande maioria, ocorre sobre áreas anteriormente ocupadas por Caatinga densa e Caatinga herbácea (formação vegetal não florestal) (Tabela 12), se estabelecendo, principalmente, nas vizinhanças do rio São Francisco (Figura 18 e Figura 20), com predomínio da fruticultura irrigada sendo as mais comuns uvas, manga, goiaba, banana e coco, resultando em alterações nas propriedades físicas, químicas e biológicas do solo (PRESTON et al., 2017; CABRAL JÚNIOR et al., 2019; TEIXEIRA et al., 2021a)

Tabela 12 - Matriz de transição entre as classes de uso e cobertura da terra da região em estudo da BHSF de 2001 a 2020. As áreas de transição estão em km<sup>2</sup>. A área total é a soma das classes: Caatinga densa (CAA), formação vegetal não florestal (FVNF), Agricultura (AGR), área não vegetada (ANV) e corpos hídricos (CH).

Tipos de uso da terra	2020						
	CAA	FVNF	AGR	ANV	CH	Total	
2001	CAA	9752,88	500,30	109,97	8,75	2,44	10374,34
	FVNF	291,85	10011,89	393,22	85,73	10,57	10793,26
	AGR	11,95	75,80	616,83	2,78	0,70	708,06
	ANV	2,49	181,36	13,27	207,48	0,80	405,39
	CH	12,53	22,39	18,83	1,95	215,19	270,89
	Total	10071,69	10791,75	1152,12	306,69	229,70	22551,94

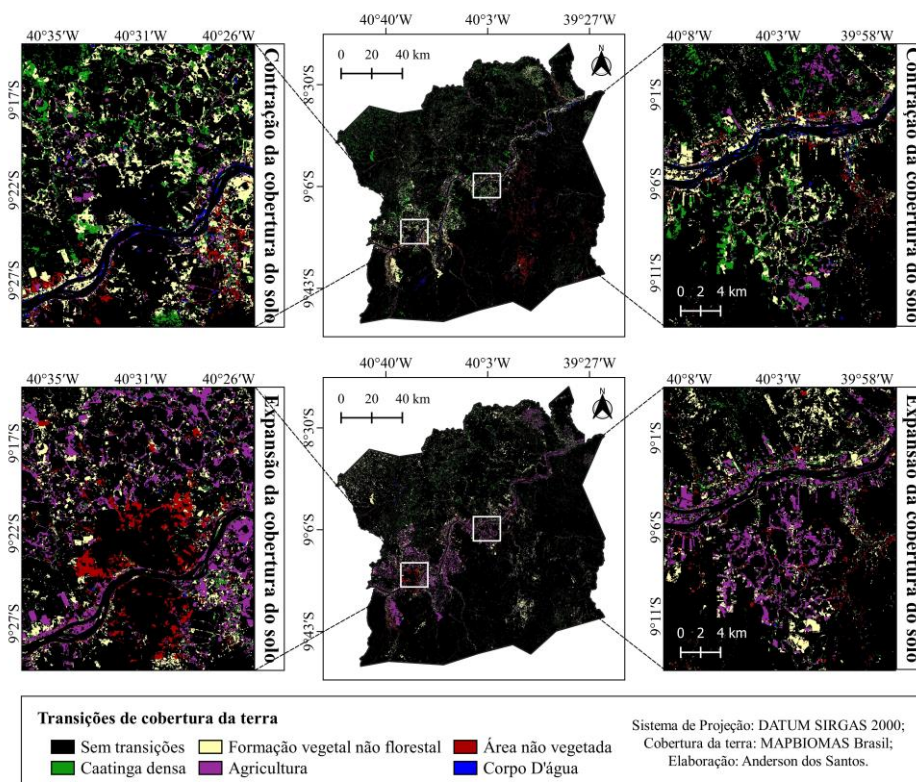
A análise de tendência das classes formação vegetal não florestal e área não vegetada usando o teste MK e o método de inclinação de Sen evidenciou tendências crescentes, no entanto, essas não foram estatisticamente significativas em  $\alpha = 0,05$  ( $|Z_s| > 1,96$ ) (Tabela 11). Por outro lado, embora, as classes formação vegetal não florestal e área não vegetada não tenham apresentado tendências significativas, ressalta-se que durante o período de 2011 a 2013 foi observado um expressivo crescimento dessas classes (Figura 19c, d).

Conforme observado pela matriz de transição (Tabela 12 e Figura 20), a expansão das áreas de solo exposto em sua maioria ocorreu em substituição a áreas antes ocupadas por agricultura de sequeiro, pastagem e Caatinga herbácea (formação vegetal não florestal), principalmente durante o período de 2012-2017 (Figura 19c, d). Tal fenômeno é efeito dos eventos de secas que ocorreram nesse período, provocando déficit hídrico na vegetação que culminou em aumento das áreas de solo exposto. Uma vez que, possuem vegetação com raízes



superficiais que só conseguem acessar a água disponível nas camadas superficiais do solo, as áreas de pastagem e Caatinga herbácea se tornam mais vulneráveis a seca e, conseqüentemente, a degradação da vegetação e do solo (JARDIM et al., 2022; FERREIRA et al., 2020; MARENGO et al., 2018; MARENGO et al., 2017).

Figura 20 - Mudanças no uso e cobertura da terra que ocorreram na região em estudo da BHSF entre 2001 e 2020.



Outro fator importante para o aumento das áreas não vegetadas, é o abandono de áreas antes ocupadas por pastagem e agricultura de sequeiro, em decorrência dos intensos eventos de secas ocorridos entre 2012-2017. Segundo Aquino et al. (2021), na região semiárida do Brasil a pecuária extensiva e agricultura itinerante desenvolvida pelo pequeno produtor com culturas de subsistência, são estritamente dependentes de eventos frequentes e regulares de precipitação. Além disso, a alteração na cobertura da terra por meio do uso e manejo inadequado da terra, com práticas intensivas de agricultura, pecuária, desmatamento e queimadas tornam a cobertura vegetal mais suscetível as mudanças climáticas e favorecem o processo de desertificação (SALAZAR et al., 2021; VIEIRA et al., 2015).

Em geral, as áreas de Caatinga herbácea e pastagem estão em constante processo de transição entre si, de modo que as áreas de pastagem avançam sobre a Caatinga herbácea, enquanto a Caatinga herbácea se desenvolve em áreas de pastagem degradada. Além disso,

essas classes estão estreitamente relacionadas na região em estudo, devido a presença de bovinocultura e ovinocaprinocultura extensiva em áreas de estrato herbáceo e lenhoso da Caatinga (SALAZAR et al., 2021). Segundo Antongiovanni et al. (2020), como a maioria das fazendas não é cercada por cercas os animais domesticados alimentam-se majoritariamente ou totalmente de vegetação nativa.

A presença de áreas não vegetadas ocorre, principalmente, nas proximidades do rio São Francisco e ao sul da região em estudo (Figura 18 e Figura 20), e está relacionada as atividades antrópicas, como urbanização, mudanças no uso da terra, construção de projetos hidrelétricos e ao processo de degradação de áreas de pastagem. A construção da barragem de Sobradinho impulsionou a exploração e a mudança no uso da terra, que promoveram crescimento econômico e intensificação do processo de expansão urbana nas vizinhanças do rio São Francisco. Vários estudos indicaram que a alta densidade populacional e a exploração intensiva na BHSF podem afetar a cobertura vegetal e levar a perdas severas de solo e água, culminando em aumento das áreas não vegetadas (Correia et al., 2006; Cabral Júnior et al., 2019, Jardim et al 2022).

A classe corpos hídricos mostra uma tendência de redução significativa em  $\alpha = 0,05$ . Por conseguinte, a área superficial de corpus hídricos reduziu 15,19% entre 2001 e 2020, o equivalente a 80,18 km<sup>2</sup> (Tabela 11 e Figura 19e). Em geral, após o ano de 2009 ocorreu uma acentuada redução das áreas de corpos hídricos, decorrente dos eventos de seca que ocorreram entre 2012 e 2019. Segundo Martins et al. (2018b), esses eventos de seca reduzem a área superficial dos corpos hídricos através do déficit pluviométrico e do aquecimento da superfície que eleva as taxas de evaporação. Durante os eventos de seca de 2012 a 2019 a barragem hidrelétrica de Sobradinho atingiu o nível mais baixo de sua história, 10% de sua capacidade total de armazenamento, operando com vazões de segurança ( $\sim 550 \text{ m}^3 \cdot \text{s}^{-1}$ ) para garantir os usos múltiplos da água (ANA, 2023).

Conforme a matriz transição de uso e cobertura da terra de 2001 a 2020 (Tabela 12), 79,62% dos corpos hídricos (215,18 km<sup>2</sup>) permaneceu inalterado; 8,28% dos corpos hídricos (22,38 km<sup>2</sup>) foi convertido em formação vegetal não florestal e 6,97% dos corpos hídricos (18,82 km<sup>2</sup>) foi convertido em área agrícola, este último resultado expõe o avanço da agricultura às margens do rio São Francisco e suas ilhas, situação que pode vir a agravar os problemas de assoreamento e qualidade da água.



#### 4.7 Variação espacial e temporal da Precipitação pluviométrica

Os dados pluviométricos derivados do produto CHIRPS permitiram caracterizar o padrão espacial-temporal da precipitação anual na região em estudo da BHSF (Figura 21). Embora, a medição *in situ* seja o método mais utilizado e preciso de quantificar a precipitação pluviométrica, os dados de precipitação do CHIRPS são indicados para pesquisas científicas, devido à sua série histórica (1991-2023), apresentar resolução temporal diária e possibilitar uma maior cobertura espacial em relação as redes de dados pluviométricos obtidos *in situ* (FUNK et al., 2015).

A média anual da precipitação pluviométrica da região em estudo da BHSF para a série histórica de 2001-2020 é de 406,45 mm, com oscilações entre episódios úmidos e secos. Diante disso, a análise dos valores anuais da precipitação pluviométrica em períodos específicos mostra que em média o período plurianual de 2001-2010 ( $477,52 \text{ mm} \pm 41,73 \text{ mm}$ ) foi mais chuvoso do que o período plurianual 2011-2020 ( $357,46 \text{ mm} \pm 42,79 \text{ mm}$ ) e que os eventos de precipitação acima da média histórica abrangeram uma área muito maior nesse período (Figura 21).

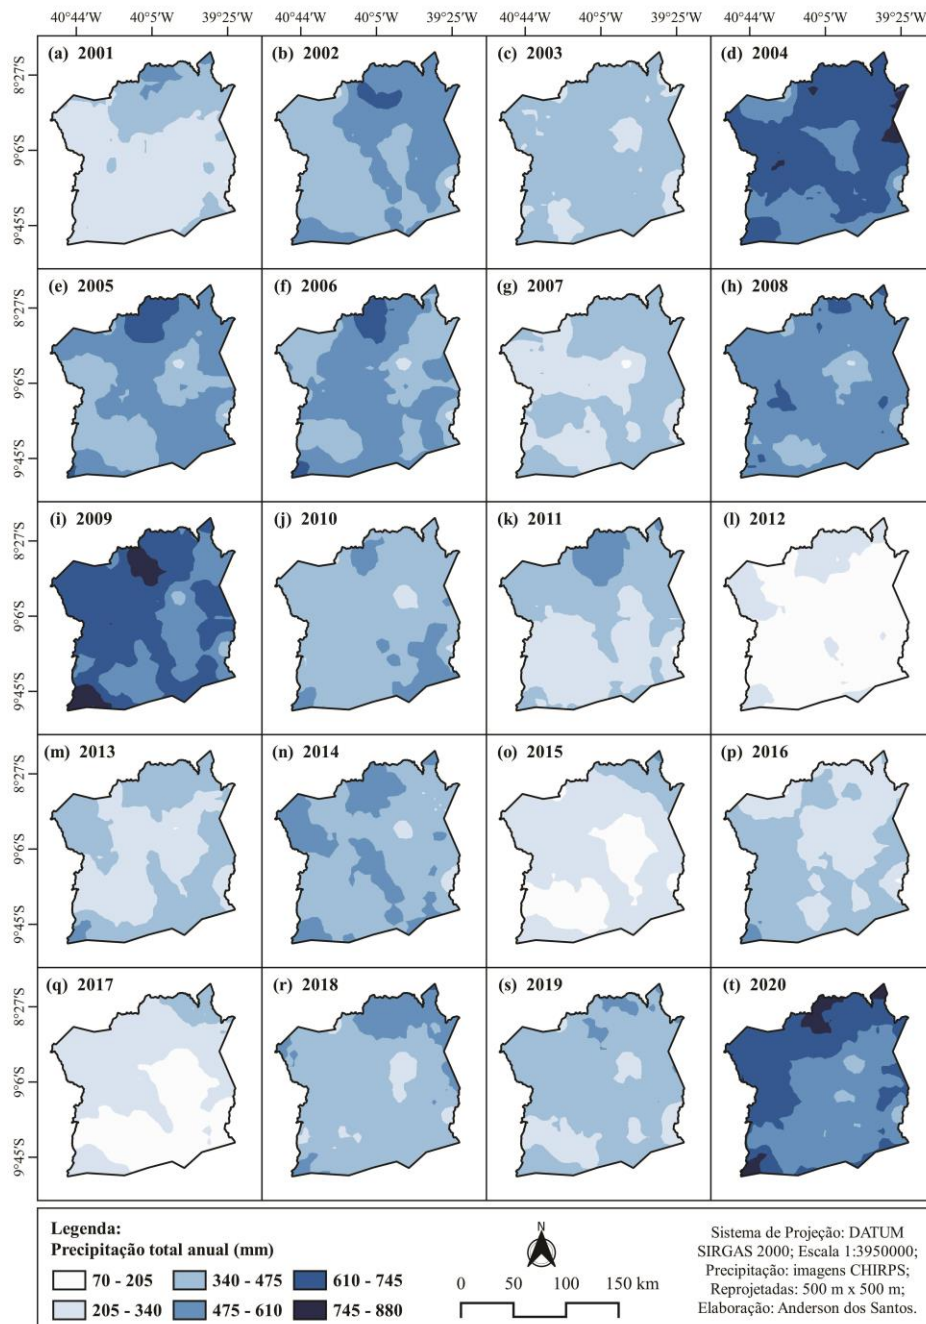
Variações na precipitação podem ter profundas influências na dinâmica da cobertura vegetal na BHSF, uma vez que a umidade do solo é geralmente escassa na região semiárida. Atualmente, numerosos estudos relataram tendências de redução dos valores de chuva e variações espaciais e temporais na precipitação no semiárido brasileiro (CUNHA et al., 2015; MARENGO et al., 2017, 2018; COSTA et al., 2020). Além disso, a redução das chuvas em decorrência do aumento da duração, frequência e intensidade dos eventos de seca tem provocado modificações na cobertura vegetal e aumento das áreas suscetíveis a desertificação (TOMASELLA et al., 2018; MARENGO et al., 2018, 2020; COSTA et al., 2020).

Durante todo o período plurianual analisado de 2001-2020, os maiores volumes anuais de precipitação foram registrados em 2004, 2009 e 2020, com ocorrência de valores acumulados acima de 610 mm, em cerca de 69,92%, 67,98% e 46,53% da região em estudo, respectivamente (Figura 21 d, i, t).

Em contraste, os menores volumes anuais de precipitação foram registrados em 2012, 2015 e 2017, com ocorrência de valores inferiores a 340 mm em 100%, 91,95% e 94,50% da região em estudo, respectivamente (Figura 21 l, o, q). Cunha et al. (2019) e Paredes-Trejo et al. (2021) analisaram a ocorrência de eventos de seca extrema na BHSF a partir de índices baseados em dados meteorológicos e de sensoriamento remoto orbital. Os autores relataram

que o período de 2012 a 2018 apresentou o evento de seca mais extremo em termos de extensão, intensidade, gravidade, duração e recorrência nas últimas décadas, influenciado pela ocorrência do El Niño no período de 2015-2016.

Figura 21 - Distribuição espaço-temporal da precipitação pluviométrica, na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020.

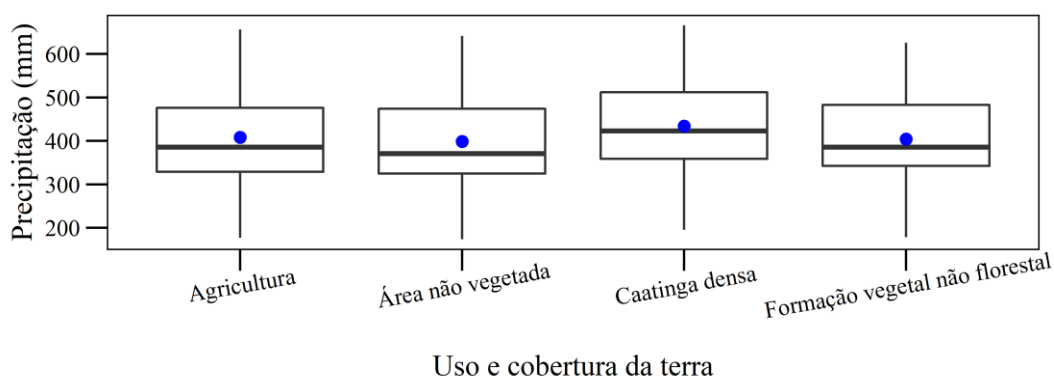


Ao observar a figura 21 fica evidente que o padrão espacial de distribuição da precipitação pluviométrica na região em estudo da BHSF é heterogêneo. Com os maiores

valores médios observados na porção norte, entres os municípios de Petrolina e Orocó ( $443,78 \text{ mm} \pm 31,27 \text{ mm}$ ), enquanto os menores valores médios são observados na porção sul, entre os municípios de Juazeiro e Curaçá ( $401,85 \text{ mm} \pm 37,80 \text{ mm}$ ). A variabilidade das chuvas na região semiárida do Brasil está associada a fatores como uso e ocupação da terra, condições de altitude e relevo. Portanto, quando associados aos efeitos das mudanças climáticas, esses fatores alteraram os padrões pluviométricos e favorecem a ocorrência de eventos de seca (SILVA et al., 2023).

Em geral, as modificações da vegetação nativa influenciam na variabilidade da precipitação anual. Os valores da média  $\pm$  desvio padrão mostram que as áreas de Caatinga densa apresentam os maiores volumes pluviométricos ( $434,31 \text{ mm} \pm 131,01 \text{ mm}$ ). Por outro lado, os menores volumes são observados nas áreas não vegetadas e de formação vegetal não florestal ( $398,75 \text{ mm} \pm 135,32 \text{ mm}$  e  $404,09 \text{ mm} \pm 127,27 \text{ mm}$ , respectivamente). Além disso nas áreas de agricultura a precipitação anual foi de  $408,06 \text{ mm} \pm 133,15 \text{ mm}$  (Figura 22).

Figura 22 - Diagrama boxplot da precipitação pluviométrica anual para as classes de uso e cobertura da terra, na região em estudo da BHSF, entre 2001 e 2020.



Alguns estudos sugerem que o desmatamento é capaz de aumentar a duração da estação seca (BUTT; DE OLIVEIRA; COSTA, 2011; FU et al., 2013; SILVÉRIO et al., 2015). Nobre et al.(2009) em estudo sobre o desmatamento e mudanças climáticas na floresta amazônica, observaram que quanto maior a proporção de desmatamento em uma área maiores são às reduções na precipitação. Os autores relatam que a quantidade e continuidade das áreas florestais influenciam nos processos de convecção favorecendo a ocorrência de chuvas. Lawrence e Vandecar (2015), relatam que em escala climática local os danos causados pelas mudanças na cobertura da terra atingem níveis semelhantes aos causados pelas emissões de gases de efeito estufa.

#### 4.8 Variação espacial e temporal dos índices de cobertura vegetal

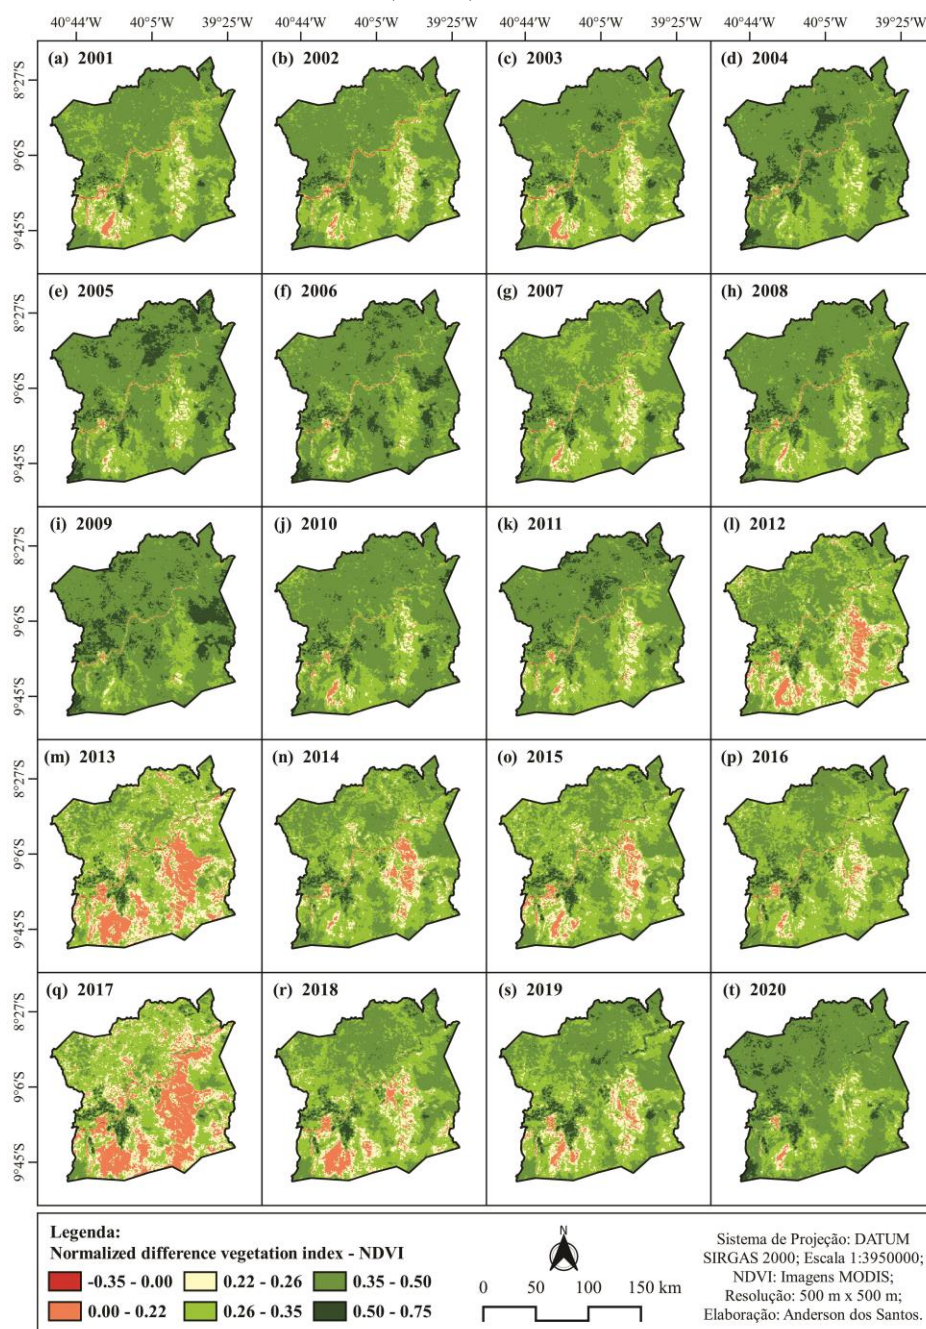
O presente estudo constatou que o NDVI na região em estudo da BHSF apresenta diferenças espaciais significativas, onde a distribuição espacial dos valores do NDVI é influenciada pelo padrão de distribuição espacial da precipitação (Figura 23). Portanto, as áreas com os maiores valores médios de NDVI estão localizadas a norte, entre os municípios de Petrolina e Orocó no estado de Pernambuco, enquanto os menores valores médios são observados a sul, nos municípios de Juazeiro e Curaçá no estado da Bahia. Esses resultados mostram que existe uma influência direta da precipitação na vegetação da região em estudo.

A variabilidade espacial e temporal do NDVI no semiárido nordestino é influenciada pelos padrões de precipitação, pois a vegetação é extremamente sensível as variações pluviométricas. Durante o período seco a vegetação nativa da Caatinga reduz a fotossíntese e muitas vezes apresenta queda de folhas (por caducifolia), culminando em redução dos valores do NDVI; enquanto no período chuvoso a vegetação reestabelece sua folhagem com crescimento acelerado da rebrota e aumento dos processos metabólicos, promovendo o aumento dos valores do NDVI (CUNHA et al., 2012; SILVA FILHO et al., 2020; SANTOS et al., 2020; MEDEIROS et al., 2022).

Em geral, os valores médios do NDVI variaram de -0,35 a 0,75, com média anual de 0,363. Durante o período de 2001 a 2010 houve maior homogeneidade da cobertura vegetal, conforme observado pelos valores médios de NDVI (Figura 23a-j). Este cenário está relacionado a ocorrência de anomalias de precipitação, principalmente nos anos de 2004, 2008 e 2009, em virtude da atuação da Zona de Convergência Intertropical (ZCIT) sobre a região Nordeste do Brasil e da presença de Vórtices Ciclônicos em Altos Níveis (VCAN) sobre o Oceano Atlântico (CLIMANÁLISE, 2023), que promoveram a ocorrência de chuvas com distribuição espacial mais uniforme e maiores volumes precipitados, conforme observado na Figura 21.

O período de 2011 a 2020 é marcado por maior heterogeneidade da cobertura vegetal (Figura 23k-t), decorrente dos fortes eventos de seca ocorridos no período de 2012 a 2018 que provocaram reduções substanciais no verde da vegetação (Figura 23 l-r). Essas observações são consistentes com um estudo de Silva et al. (2023), que avaliaram a degradação ambiental da cobertura vegetal na região semiárida do Nordeste brasileiro, entre os anos de 2000 e 2019, a partir de índices de vegetação.

Figura 23 - Distribuição espaço-temporal do índice de vegetação por diferença normalizada (NDVI), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020.



Em seu estudo, Silva et al. (2023) verificaram um declínio significativo dos valores de NDVI em função do impacto severo dos eventos de seca ocorridos de 2012-2018. Rodrigues et al. (2020b), em estudo no semiárido brasileiro, mostraram que durante anos chuvosos, as diferenças de NDVI entre as classes de cobertura da terra foram menos perceptíveis devido ao aumento da umidade do solo. Contudo, em um ano seco, as diferenças foram mais evidentes.

A extensão das áreas com valores médios de NDVI entre 0~0,26 ao longo do período de 2012 a 2018, evidencia o impacto dos eventos de seca na cobertura vegetal, principalmente nos anos de 2013 e 2017 (Figura 23m, q). À vista disso, as classes de NDVI entre 0~0,26, atingiram taxa de ocorrência de 34,70% e 44,47% nos anos de 2013 e 2017, respectivamente (Figura 23m, q). Tomasella et al. (2018) ao correlacionarem dados de campo da vegetação do bioma Caatinga com dados de NDVI derivados de imagem MODIS, verificaram que devido a resolução espacial valores de NDVI entre 0~0,26 indicam a presença de solo exposto e vegetação subarbustiva e arbustiva muito esparsa, com índice de cobertura inferior a 20%. Francisco et al. (2013) em estudo sobre a vulnerabilidade das terras em uma bacia hidrográfica do bioma Caatinga relataram que esse tipo de vegetação apresenta alta vulnerabilidade a degradação das terras.

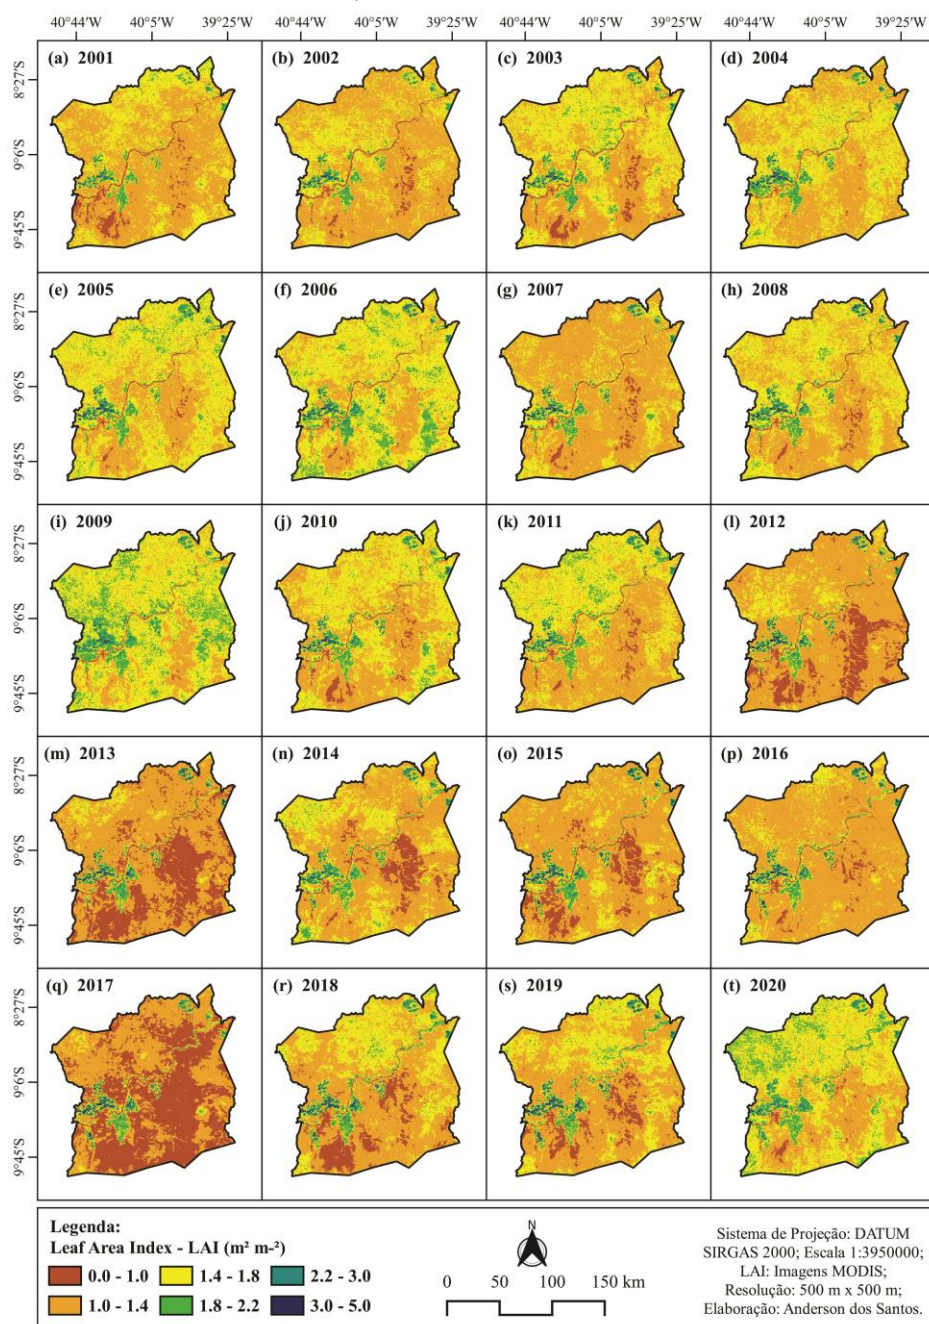
Em termos de tipos de cobertura da terra, os maiores valores de NDVI médio anual foram observados nas áreas com agricultura irrigada ( $0,458 \pm 0,077$ ) e Caatinga Densa ( $0,401 \pm 0,065$ ). Em contrapartida, os menores valores do NDVI médio anual foram medidos nas áreas não vegetadas ( $0,287 \pm 0,080$ ) e áreas com formação vegetal não florestal ( $0,324 \pm 0,069$ ). Resultados semelhantes foram observados em outras regiões do semiárido brasileiro onde as atividades antrópicas são predominantes (REFATI et al., 2023; SILVA et al., 2022).

As mudanças espaço-temporais do LAI médio anual na região em estudo da BHSF são mostradas na Figura 24. Os valores mínimo, máximo e médio do LAI ao longo da série temporal foram entre  $0,0 \text{ m}^2 \cdot \text{m}^{-2}$ ,  $5,0 \text{ m}^2 \cdot \text{m}^{-2}$  e  $\sim 1,5 \text{ m}^2 \cdot \text{m}^{-2}$ , respectivamente. No entanto, durante anos normais de precipitação cerca de 55% da região em estudo apresenta valores do LAI inferiores à média, essa proporção aumenta para ~80% durante anos secos e reduz para ~35% em anos chuvosos. Naturalmente, o bioma Caatinga é caracterizado por apresentar baixos valores de LAI, devido as características de sua vegetação (por exemplo, presença de arbustos, vegetação rasteira, esparsa e com caducifolia nos períodos secos) (SANTOS et al., 2020; SILVA et al., 2022; REFATI et al., 2023).

Em termos de valores de LAI em diferentes tipos de vegetação, os maiores valores médios de LAI ocorreram em áreas agrícolas ( $2,07 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,51 \text{ m}^2 \cdot \text{m}^{-2}$ ) e Caatinga densa ( $1,43 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,12 \text{ m}^2 \cdot \text{m}^{-2}$ ). Jardim et al., (2022) em estudo realizado na BHSF, observaram que os maiores valores de LAI estão associados às áreas agrícolas irrigadas, com o aumento da produção de biomassa. Por outro lado, os menores valores médios ocorreram em áreas com corpo hídricos ( $0,89 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,32 \text{ m}^2 \cdot \text{m}^{-2}$ ), áreas não vegetadas ( $1,19 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,30 \text{ m}^2 \cdot \text{m}^{-2}$ ) e com formação vegetal não florestal ( $1,27 \text{ m}^2 \cdot \text{m}^{-2} \pm 0,18 \text{ m}^2 \cdot \text{m}^{-2}$ ), sucessivamente.



Figura 24 - Distribuição espaço-temporal do índice de área foliar (LAI,  $m^2 m^{-2}$ ), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020.



Embora mais flutuante, o LAI apresenta forte relação com o NDVI, por suas tendências semelhantes ao longo da série temporal, que estão associadas às mudanças no uso e cobertura da terra e a variabilidade interanual da precipitação, com uma indicação clara do efeito dos eventos de seca no período de 2012-2018 (Figura 24 l-r). Corroborando com estudos realizados anteriormente, que relatam a eficiência do NDVI e LAI como indicadores das características biológicas da vegetação afetada pelas mudanças climáticas e atividades antrópicas, variando

suas respostas conforme o tipo de cobertura vegetal (XIAO et al., 2022; JARDIM et al., 2022; SILVA et al., 2022; LYU et al., 2023; SUN et al., 2023; SILVA et al., 2023).

Durante os anos secos fica evidente a maior fragilidade das áreas não vegetadas e com formação vegetal não florestal, que apresentam drásticas reduções do LAI, principalmente nos anos de 2012, 2013 e 2017 que apresentaram ocorrência de valores de LAI entre  $0\sim 1\text{ m}^2\cdot\text{m}^{-2}$  em 13,85%, 28,13% e 46,16% da região em estudo da BHSF, respectivamente.

É importante destacar que, embora o ano de 2013 tenha apresentado maior acumulado de precipitação em relação a 2012 (Figura 21 l, m), cerca de 35% da precipitação anual ocorreu durante o mês de dezembro, estando a precipitação dos demais meses abaixo da média histórica mensal. Desta forma, a persistência e intensidade da seca ocorrida entre 2012-2013, afetou a resiliência da vegetação e intensificou a degradação da cobertura vegetal, refletindo em baixos valores de NDVI e LAI que se estenderam ao longo da região em estudo. Padrão que se repete em 2017, sendo agravado pela ocorrência de 5 anos consecutivos com precipitação pluviométrica anual abaixo ou próxima da média histórica (2001-2020).

Os ecossistemas da Caatinga são geralmente frágeis e mais sensíveis a eventos de seca, sendo a cobertura vegetal da Caatinga altamente dependente da variabilidade interanual do clima. Diversos estudos apontam aumento do processo de degradação do solo sobre áreas de Caatinga e pastagem, e tendência de substituição da vegetação do bioma Caatinga (cobertura vegetal do semiárido brasileiro), por vegetação típica de condições áridas (MARENGO et al., 2020; TOMASELLA et al., 2018). Bai et al. (2020) em estudo realizado em regiões áridas do sudoeste e nordeste da China, verificaram que alterações na precipitação podem levar a mudanças na estrutura da vegetação, modificando a distribuição e o tipo de espécies vegetais dominantes devido a diferenças na vulnerabilidade à seca entre as espécies.

Com o aumento da precipitação pluviométrica anual após o forte evento de seca ocorrido em 2017, verifica-se um aumento progressivo dos valores médio do NDVI e LAI (Figura 23 e 24), principalmente nas áreas com Caatinga densa. Indicando que, as áreas de Caatinga densa apresentaram maior resistência, recuperação e resiliência as variações de precipitação ocorridas ao longo do período em estudo. Segundo Sousa Júnior et al. (2022), a precipitação é um dos mais importantes impulsionadores da dinâmica e produtividade dos ecossistemas semiáridos, e as anomalia de precipitação representam um desafio para monitorar as mudanças no uso e cobertura da terra.

É notável que a expansão das classes de NDVI ( $0\sim 0,26$ ) e de LAI ( $0\sim 1\text{ m}^2\cdot\text{m}^{-2}$ ) durante o período de 2012 a 2018, foi maior nos municípios de Juazeiro e Curaçá (Figura 23 e Figura 24), onde no ano de 2017 foi possível verificar taxa de ocorrência média de 59,81% e 61,53%



das classes de NDVI (0~0,26) e de LAI (0~1 m<sup>2</sup>.m<sup>-2</sup>), respectivamente. Esses resultados expõem a maior suscetibilidade da cobertura vegetal desses municípios as variações anuais de precipitação. Isto ocorre, presumivelmente, porque a cobertura vegetal nesses municípios é composta, essencialmente, por áreas de pastagem e Caatinga herbácea (ver Figura 16), vegetações que se acredita serem mais suscetíveis às mudanças climáticas, particularmente à variabilidade pluviométrica.

Em contraste, existem áreas onde não houve associação dos períodos com precipitação elevada com melhoria da vegetação ou aumento do NDVI e LAI. Portanto, esses resultados indicam que os impactos das atividades antrópicas agravaram o processo de degradação da cobertura vegetal, bem como a resiliência da vegetação.

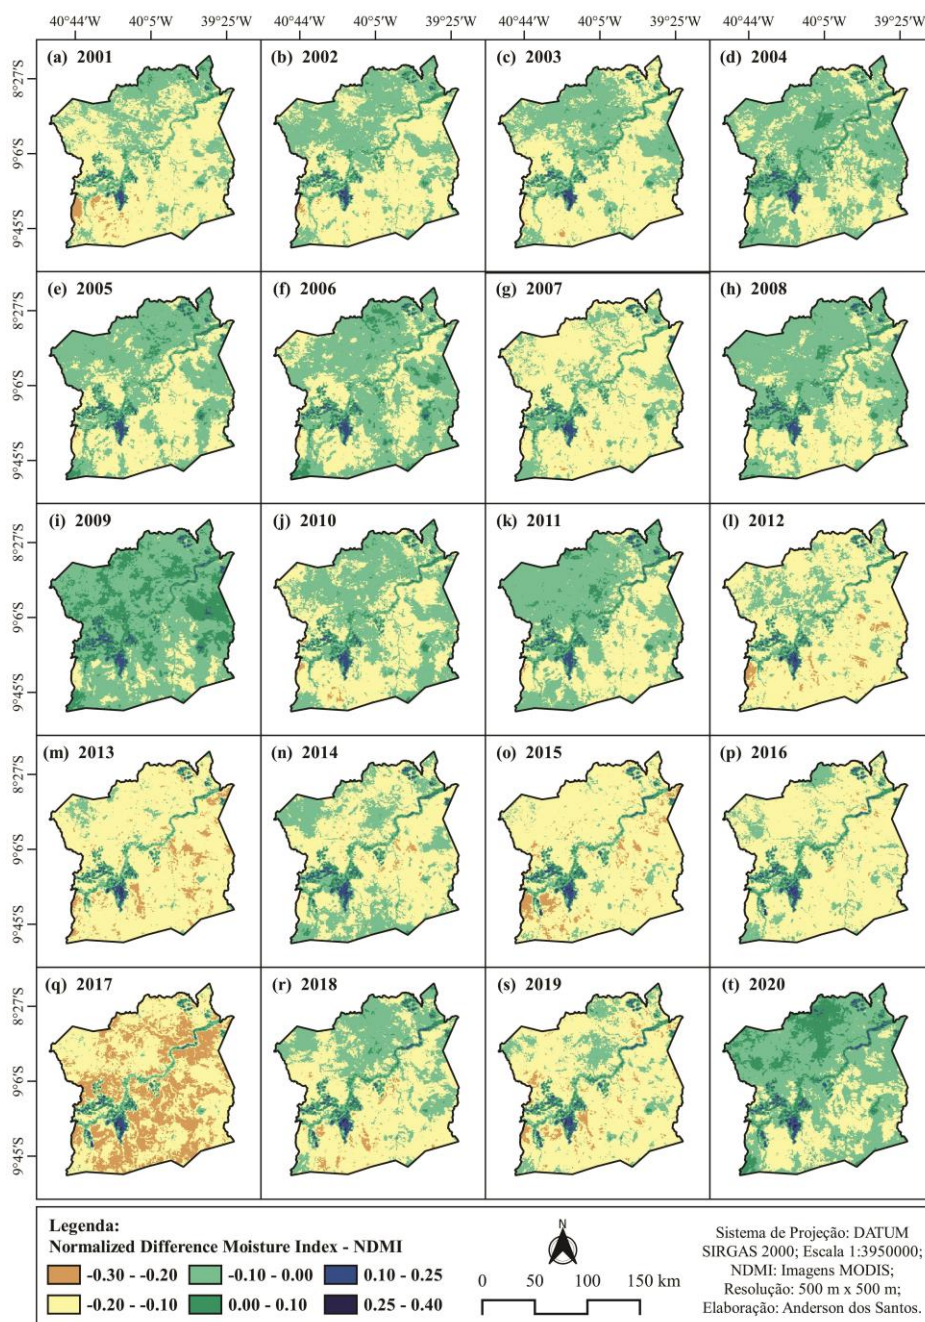
Diversos estudos relatam que áreas com baixa cobertura vegetal tendem a serem mais afetadas por eventos de seca do que áreas com alta cobertura vegetal, que apresentam baixa variabilidade interanual das respostas da vegetação aos eventos de chuva (BARBOSA et al., 2018; TOMASELLA et al., 2018; SILVA et al., 2019; SANTOS et al., 2020 ;MOURA NETO et al., 2022).

#### **4.9 Variação espacial e temporal do Índice de Umidade por Diferença Normalizada (NDMI)**

Os resultados da análise espaço-temporal do NDMI para a série histórica 2001-2020 variam de -0,30 a 0,40. A Figura 25 mostra que os valores de NDMI foram muito menores para o período plurianual de 2011-2020 ( $-0,11 \pm 0,005$ ) do que para o período de 2001-2010 ( $-0,05 \pm 0,02$ ), particularmente para anos de 2012, 2013, 2015 e 2017. Consistente com as reduções dos valores de NDVI e LAI, a diminuição dos valores médios anuais de NDMI durante o período 2011-2020 pode estar relacionada a ocorrência dos eventos de seca no período de 2012-2018; o que ilustra o potencial desses índices no monitoramento dos impactos dos eventos de seca em grandes áreas. Por exemplo, vários estudos utilizaram índices de vegetação e de umidade, para avaliar os efeitos da seca na região Nordeste do Brasil e verificaram que a região tem experimentado frequentes secas sazonais e anuais (REFATI et al., 2023; SILVA et al., 2023; MOURA NETO et al., 2022; SILVA et al., 2022; BARBOSA et al., 2018).

Da mesma forma, o NDMI pode ser utilizado no monitoramento da resposta da cobertura vegetal a anomalias de elevada precipitação pluviométrica como nos anos de 2004, 2009 e 2020 que apresentaram os maiores teores de umidade (Figura 25).

Figura 25 - Distribuição espaço-temporal do índice de umidade por diferença normalizada (NDMI), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020.



Diante da detecção dos padrões de mudanças das condições de umidade da cobertura vegetal, pode-se observar que o aumento da persistência e intensidade dos eventos de seca afetaram drasticamente a disponibilidade hídrica da região em estudo, com isso, passou-se a ter um déficit hídrico anual acentuado, alcançando condições extremas no ano de 2017, que atingiu valores médios de NDMI inferiores a  $-0,20$  em cerca de 33,05% da região em estudo, valor que configura a existência de vegetação baixa, esparsa e seca (EOS, 2023). Esse resultado evidencia

que a redução da disponibilidade hídrica em detrimento dos eventos de seca afetou a resiliência da vegetação e a quantidade de biomassa vegetal da região.

Pode ser visto nos mapas temáticos resultantes da análise espaço-temporal do NDMI (Figura 25) que as áreas de corpos hídricos ( $0,087 \pm 0,045$ ) e agricultura irrigada ( $0,049 \pm 0,074$ ) apresentaram alto teor de umidade em comparação com as áreas ocupadas por formação vegetal não florestal ( $-0,129 \pm 0,038$ ) e áreas não vegetadas ( $-0,103 \pm 0,046$ ) que apresentam menor teor de umidade, pois possuem pouca ou nenhuma cobertura vegetal e escassa presença de corpos hídricos, estando condicionadas a estresse hídrico elevado (EOS, 2023). Além disso, sem a redistribuição hidráulica para as camadas mais rasas do solo por grandes árvores, outros tipos de vegetação com raízes superficiais não conseguem acessar a água, limitando a atividade fotossintética, o crescimento e a transpiração durante a estação seca (URIBE; DUKES, 2021; OLIVEIRA et al., 2005).

Por outro lado, as áreas de Caatinga densa apresentaram valores intermediários ( $-0,089 \pm 0,029$ ). Vale ressaltar que, a caatinga é um tipo de cobertura do solo que apresenta valores de evapotranspiração mais baixos em comparação com os tipos de cobertura vegetal (por exemplo plantas cultivadas, pastagens e solo exposto) (JARDIM et al., 2022; TEIXEIRA et al., 2021a; TEIXEIRA et al., 2020; SANTOS et al., 2017). Assim, a vegetação de caatinga deve ser preservada para manutenção da umidade do solo, sobretudo durante períodos de seca

Valores de NDMI próximos a 0 indicam cobertura vegetal de porte médio e com baixo estresse hídrico (TAIWO et al., 2023). Em áreas com maior cobertura vegetal, a exposição do solo a radiação solar se torna menor, fazendo com que haja uma manutenção da umidade do solo e, conseqüentemente, favoreça a disponibilidade hídrica do ambiente para a vegetação (SANTIAGO et al., 2019). O NDMI tem sido comumente utilizado no monitoramento do estresse hídrico na agricultura irrigada, bem como para avaliar a saúde geral e a produtividade da vegetação (DAS et al., 2023; TAIWO et al., 2023; TALOOR et al., 2021). SANTIAGO et al. (2019), destaca que o NDMI é mais sensível à água do que o NDVI, podendo detectar a umidade na vegetação e no solo, de acordo com o tipo de vegetação, refletindo melhor as mudanças de biomassa.

#### **4.10 Variação espacial e temporal da Temperatura da superfície (LST)**

Os valores médios anuais da temperatura da superfície terrestre (LST) da região em estudo da BHSF para a série histórica de 2001-2020 (Figura 26), em geral, variaram de 27 °C a 42 °C, com valor médio de 34,66 °C. Durante a série temporal analisada, o período plurianual

de 2001-2010 ( $34,15\text{ °C} \pm 1,83\text{ °C}$ ) foi mais frio em comparação com o período 2011-2020 ( $35,17\text{ °C} \pm 1,68\text{ °C}$ ). Portanto, os maiores valores médios de LST foram obtidos nos anos de 2012, 2013, 2015 e 2017, nos quais foi verificada ocorrência de valores entre  $37\text{ °C}$  e  $42\text{ °C}$  em 27,35%, 32,58%, 37,61% e 37,55% da região em estudo da BHSF, respectivamente (Figura 26).

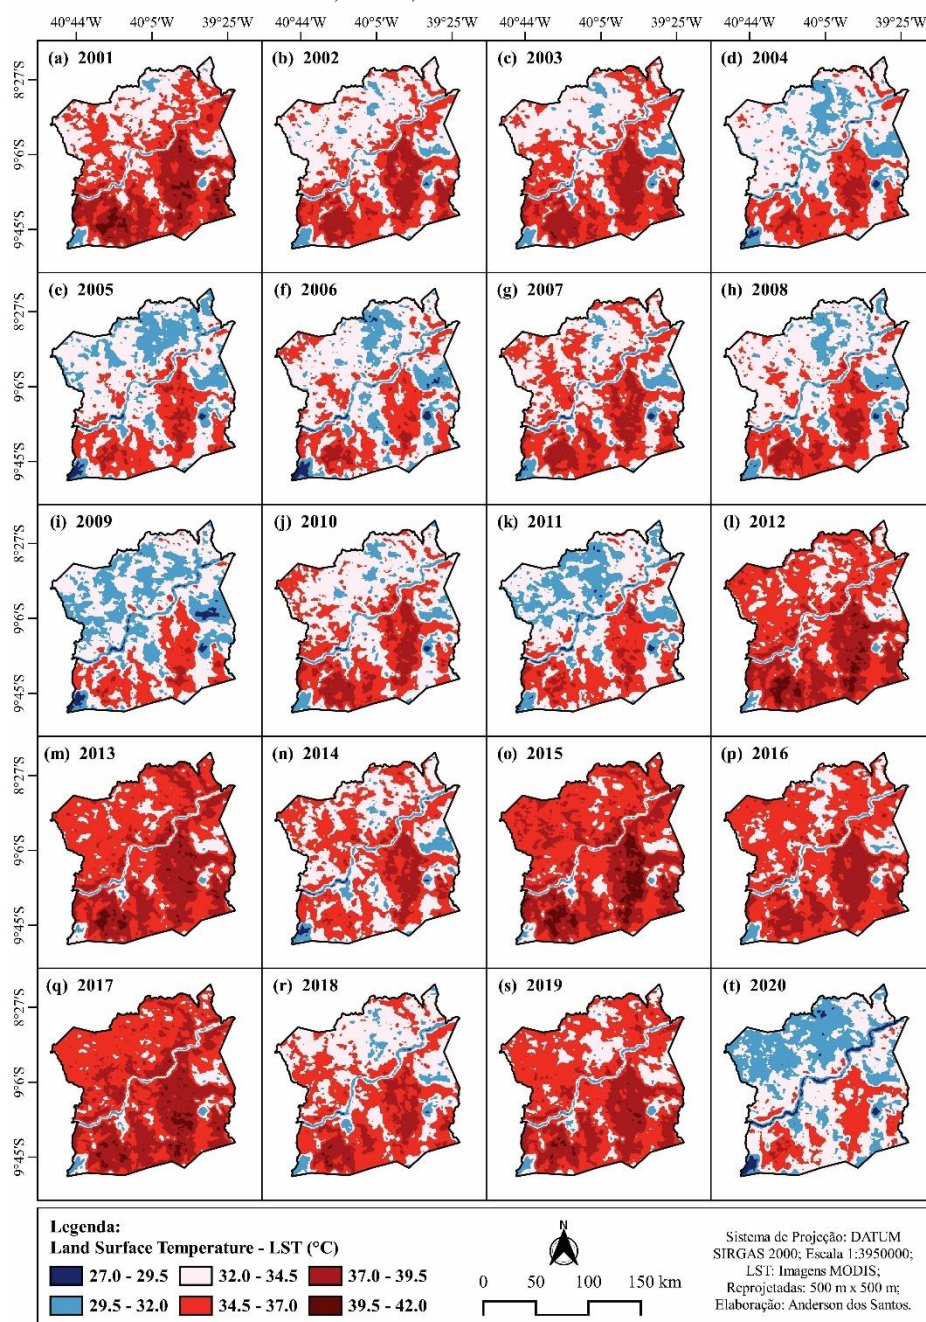
O aumento da LST, principalmente no período de 2012 a 2019 (Figura 26 l-s), destaca que a região em estudo da BHSF está enfrentando distúrbios induzidos pelo clima, como por exemplo os eventos de seca ocorridos entre 2012-2018, que agravaram as condições de umidade da vegetação, de modo a reduzir a resiliência da cobertura vegetal ao longo do tempo, culminando em elevados valores de LST. Segundo Reiners et al. (2023), as variabilidades climáticas interanuais, como a Oscilação El-Nino-Sul (ENOS) são refletidas na série temporal LST. Marengo et al. (2020) observaram uma influência significativa dos eventos de secas nas anomalias da LST e projetaram um aumento de temperatura de  $4\text{ °C}$  nos solos do semiárido brasileiro com probabilidade superior a 50% entre 2070 e 2120.

O aumento da LST, principalmente no período de 2012 a 2019 (Figura 26 l-s), destaca que a região em estudo da BHSF está enfrentando distúrbios induzidos pelo clima, como por exemplo os eventos de seca ocorridos entre 2012-2018, que agravaram as condições de umidade da vegetação, de modo a reduzir a resiliência da cobertura vegetal ao longo do tempo, culminando em elevados valores de LST. Segundo Reiners et al. (2023), as variabilidades climáticas interanuais, como a Oscilação El-Nino-Sul (ENOS) são refletidas na série temporal LST. Marengo et al. (2020) observaram uma influência significativa dos eventos de secas nas anomalias da LST e projetaram um aumento de temperatura de  $4\text{ °C}$  nos solos do semiárido brasileiro com probabilidade superior a 50% entre 2070 e 2120.

Os resultados da LST média anual ao longo da série temporal 2001-2020 (Figura 26), mostraram que os perfis anuais de LST variaram conforme o uso e cobertura da terra ao longo de toda a região em estudo da BHSF. Isso posto, os menores valores médios anuais de LST, foram verificados em áreas de corpos hídricos ( $31,35 \pm 1,09\text{ °C}$ ), agricultura irrigada ( $33,68 \pm 1,38\text{ °C}$ ) e Caatinga Densa ( $33,70 \pm 1,21\text{ °C}$ ), sucessivamente. Enquanto, os maiores valores médios anuais de LST foram verificados em áreas com formação vegetal não florestal ( $35,72 \pm 1,53\text{ °C}$ ) e áreas não vegetadas ( $35,43 \pm 1,78\text{ °C}$ ), correspondendo a áreas degradadas de pastagem e Caatinga herbácea, áreas de agricultura de sequeiro e infraestrutura urbana (Figura 26).



Figura 26 - Distribuição espaço-temporal da temperatura da superfície terrestre (LST, °C), na região em estudo da BHSF, Brasil, entre os anos de 2001 a 2020.



Outros estudos realizados no semiárido brasileiro também observaram que a conversão de vegetação nativa para outras classes de uso da terra, como infraestrutura urbana, pastagens e terras aráveis, resultou em aumento na LST. Por exemplo, um estudo no município de Petrolina-PE, na BHSF, durante a estação seca descobriu que as áreas de agricultura irrigada e Caatinga densa eram até 2,9 °C mais frias do que as áreas não vegetadas e até 4,5 °C mais frias do que as áreas de pastagem e Caatinga herbácea (JARDIM et al., 2022). Marengo et al. (2020) sugerem que as áreas de pastagem e Caatinga herbácea que atualmente cobrem a região

semiárida do Brasil podem apresentar baixa atividade fotossintética nos períodos de seca, podendo se tornar um solo descoberto, elevando os valores de LST. Na Amazônia, aumentos na LST máxima devido à perda de floresta foram notados mesmo dentro de uma distância de 50 km (COHN et al., 2019).

A diferença nas propriedades térmicas nas superfícies das áreas de pastagem, Caatinga herbácea e não vegetadas em comparação com as superfícies das áreas de agricultura irrigada e Caatinga densa pode ser atribuída a três fatores: primeiro, as áreas de pastagem, Caatinga herbácea e não vegetadas têm um albedo mais alto do que as áreas de Agricultura irrigada e Caatinga densa que possuem maior percentagem de cobertura vegetal do solo e maior altura do dossel da vegetação, o que significa que uma porção maior da radiação de ondas curtas atingirá o solo e, portanto, aquecerá a superfície terrestre (URIBE; DUKES, 2021; JARDIM et al., 2022; ULLAH et al., 2023). O segundo fator relaciona-se com a menor rugosidade da superfície da terra em áreas menos vegetadas, aumentando a resistência aerodinâmica e impedindo a troca turbulenta com a atmosfera, isso diminui a inércia térmica e a energia térmica da superfície, levando a zonas de LST altas (SOBRINO et al., 2001; COHN et al., 2019; FERREIRA et al., 2020; REINERS et al., 2023).

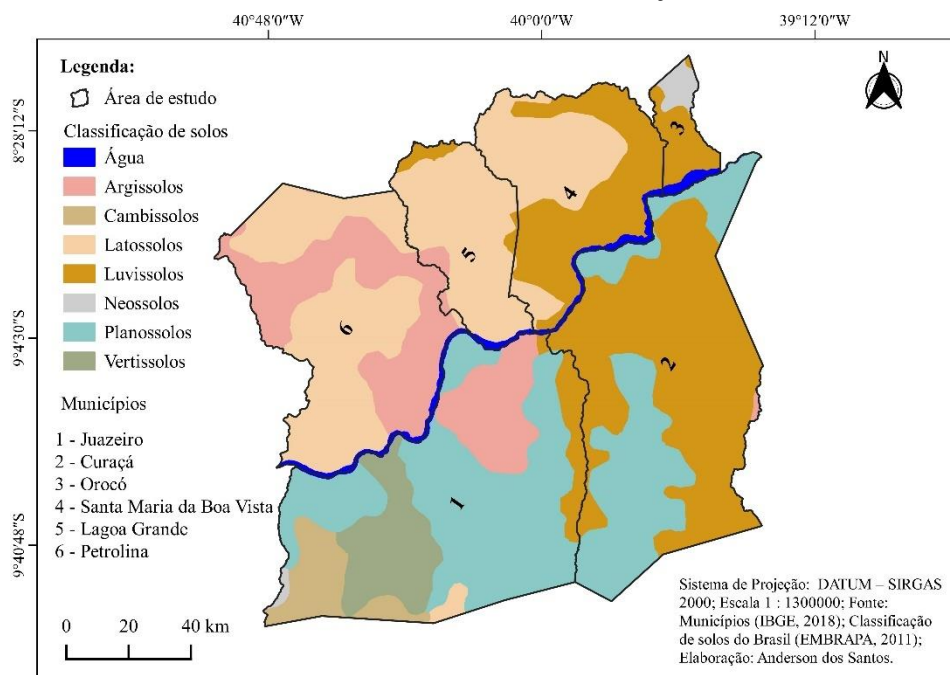
O terceiro fator é a redução das taxas de fluxos evaporativos de resfriamento em áreas menos vegetadas, pois as plantas herbáceas nativas e pastagens têm raízes rasas em relação às árvores da Caatinga densa e plantas arbóreas cultivadas na agricultura irrigada praticada na BHSF, limitando o acesso das plantas às reservas de umidade do solo e reduzindo a transpiração, principalmente durante os eventos de seca ou na estação seca. A transpiração mais baixa resulta em maior fluxo de calor sensível e, portanto, no aquecimento da superfície terrestre (OLIVEIRA et al., 2005; FERREIRA et al., 2020; REINERS et al., 2023; JARDIM et al., 2023).

É importante ressaltar que, os baixos valores de NDVI, LAI e NDMI e elevados valores de LST observados no presente estudo, principalmente nos municípios de Juazeiro e Curaçá, estão relacionados não apenas a variabilidade pluviométrica e ao uso e cobertura da terra, mas também, as características de seus solos. Isto posto, segundo a classificação de solos realizada pela Embrapa de acordo com Sistema Brasileiro de Classificação de Solos (SANTOS et al., 2011), o município de Curaçá é constituído majoritariamente por Luvisolos e Planossolos, enquanto no município de Juazeiro prevalece a ocorrência de Planossolos, Vertissolos, Cambissolos e Argissolos (Figura 27).

Tendo em vista, os resultados dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) e o tipo de solo, é possível observar a existência de duas áreas com baixa resiliência da vegetação,

onde predomina a ocorrência de pastagem e Caatinga herbácea. A primeira área está localizada a sudoeste do município de Juazeiro sobre uma mancha de Vertissolos, e a segunda área está localizada entre os municípios de Juazeiro e Curaçá em uma zona de transição entre Luvisolos e Planossolos (Figuras 23, 24, 25, 26 e 27).

Figura 27 - Distribuição geográfica dos solos da região em estudo da BHSF, no primeiro nível categórico, de acordo com Sistema Brasileiro de Classificação de Solos.



Os Planossolos, geralmente, são solos pouco profundos e adensados que mostram mudança abrupta de textura entre os horizontes superficial e subsuperficial, o que os tornam pouco permeáveis dificultando a drenagem desses solos (CÂMARA et al., 2021; SANTOS et al., 2018; SOUSA et al., 2020). As áreas naturais de Planossolos suportam uma vegetação esparsa de gramíneas, muitas vezes com arbustos e árvores dispersos que possuem sistemas radiculares rasos (FAO, 2015). Alguns estudo realizados na região semiárida do Brasil, relatam a existência de Planossolos em estágios avançados de degradação, devido aos efeitos das ações antrópicas e das mudanças climáticas, estando sujeitos ao processo de desertificação (CÂMARA et al., 2021; NEVES et al., 2021).

Enquanto, os Vertissolos são solos com séria restrição à percolação de água, com 30% ou mais de argila ao longo do perfil, o que restringe a sua drenagem. Esses solos formam fendas de retração profundas e largas quando secam, o que acontece na maioria dos anos (KOVDA, 2020; SANTOS et al., 2018). Nas regiões semiáridas as áreas de Vertissolos são, predominantemente, utilizadas para pastagem extensiva, corte de madeira e afins. A presença

de vegetação arbórea nesses solos é restrita porque as raízes das árvores têm dificuldade em se estabelecer no subsolo e são danificadas pelo processo de contração e expansão do solo (FAO, 2015).

Por fim, os Luvisolos possuem profundidade efetiva rasa e apresentam revestimento pedregoso na superfície. Além de apresentarem forte gradiente textural entre os horizontes A e Bt. Contudo, tais características quando associadas a pouca cobertura vegetal e intensificação das atividades antrópicas tornam os Luvisolos altamente propensos aos processos erosivos, salinização, alcalinização e desertificação (CÂMARA et al., 2021; LINS et al., 2023; OLIVEIRA et al., 2009; SANTOS et al., 2018; SOUSA et al., 2021). Portanto, as características de cada tipo de solo mencionadas acima levam a um ambiente de crescimento pobre para a vegetação, que aliado a fatores antrópicos de sobrepastoreio, conversão da cobertura da terra, queima de biomassa e baixa resiliência de alguns tipos de vegetação a variabilidade pluviométrica resulta em valores mais baixos de NDVI, LAI e NDMI e elevados valores de LST para a região em estudo.

#### **4.11 Efeito da variabilidade pluviométrica e das mudanças no uso da terra nos parâmetros biofísicos da superfície da terra**

A Figura 28 apresenta os diagramas boxplot para os parâmetros biofísicos NDVI, LAI, NDMI e LST (derivados das imagens MODIS de 8 dias), gerados para os quatro tipos de uso e cobertura da terra contrastantes (a partir da amostragem de 150 pontos aleatórios extraídos para cada tipo de uso e cobertura da terra) durante anos normais, chuvosos, secos e subsequentes a um ano seco.

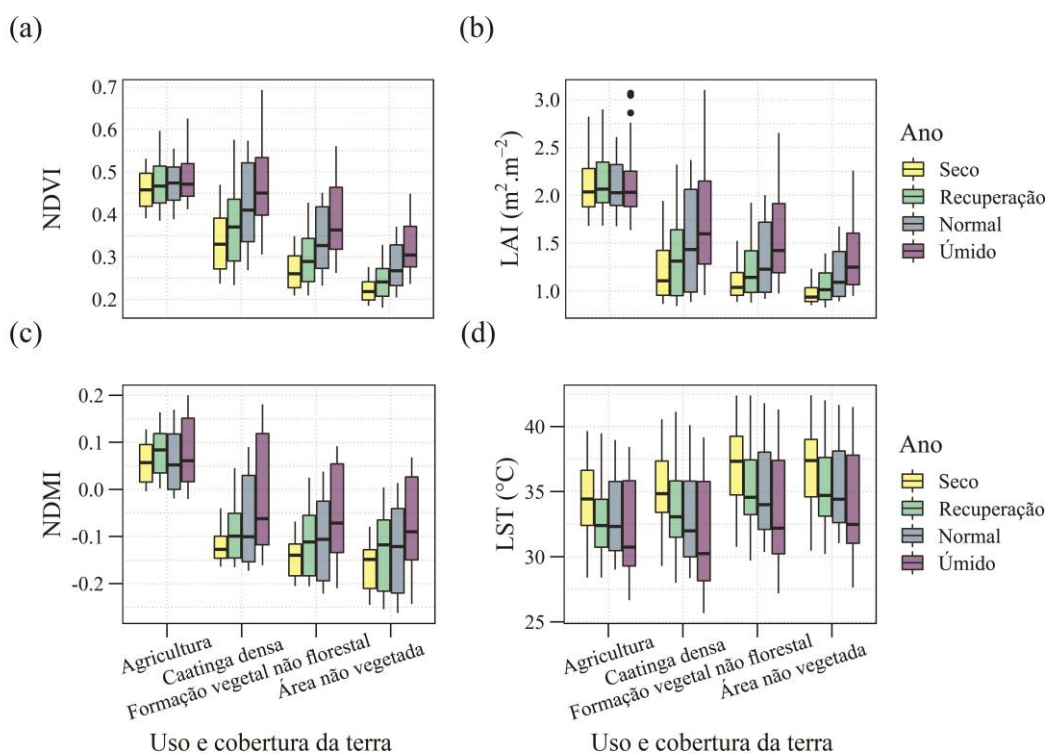
A classe agricultura (irrigada) apresentou menor oscilação interanual dos parâmetros biofísicos e baixa variabilidade intra-anual (indicada pelo intervalo interquartil) dos parâmetros biofísicos durante os diferentes regimes de precipitação. Além disso, a classe agricultura apresentou os maiores valores de NDVI, LAI e NDMI e menores valores de LST em relação as demais classes, independente do regime pluviométrico (Figura 28); indicando baixa suscetibilidade as variações de precipitação, visto que a irrigação tende a suprir total ou parcialmente as necessidades hídricas das diferentes espécies vegetais cultivadas, minimizando os efeitos estressores.

De maneira geral, a classe Caatinga densa apresentou a maior oscilação interanual e maior variabilidade intra-anual (conforme indicado pelo intervalo interquartil) dos parâmetros biofísicos em relação as outras classes (Figura 28), como resultado de um declínio da cobertura



vegetal no período seco e de uma rápida recuperação da vegetação durante o período chuvoso, indicando a existência de uma grande diversidade de espécies vegetais nativas com capacidade adaptativa que fornece maior resistência, recuperação e resiliência, e possibilita suportarem às condições estressoras decorrentes das variações climáticas.

Figura 28 - Diagramas boxplot de (a) NDVI, (b) LAI ( $\text{m}^2 \text{m}^{-2}$ ), (c) NDMI e (d) LST ( $^{\circ}\text{C}$ ) para as classes de uso e cobertura da terra: Caatinga densa, agricultura (irrigada), formação vegetal não florestal e área não vegetada. Em anos secos, normais, subsequentes a um ano hidrológico seco (ano de recuperação) e chuvosos.



Notavelmente, a classe Caatinga densa apresentou os maiores valores de NDVI, LAI e NDMI e menores valores de LST em relação as classes formação vegetal não florestal e área não vegetada, independente do regime de precipitação (Figura 28), além de apresentar uma maior amplitude de resposta após um ano de seca. Diversos estudos relatam que, a vegetação arbórea e a vegetação arbustiva da caatinga são menos suscetíveis às variações climáticas do que outros tipos de vegetação, pois possuem raízes mais profundas que acessam a água nas camadas mais inferiores do solo e podem, portanto, manter a transpiração, conferindo maior resistência aos eventos de seca (BARBOSA et al., 2018; SANTOS et al., 2020; SALAZAR et al., 2021).

Em geral, as áreas não vegetadas e com formação vegetal não florestal (Caatinga herbácea, pastagem e agricultura de sequeiro) apresentaram maior suscetibilidade as variações

anuais de precipitação fato observado pelos menores valores de NDVI, LAI e NDMI e maiores valores de LST (Figura 28). Santos et al. (2020a) destacam que áreas com vegetação herbácea são mais suscetíveis as variações climáticas em relação as áreas com vegetação arbórea e arbustiva, tornando as reduções da cobertura vegetal mais drásticas durante eventos de seca.

A Figura 29 mostra a correlação entre a precipitação mensal e os parâmetros biofísicos (NDVI, LAI, NDMI e LST) para diferentes defasagens temporais (0, -1, -2, -3 e -4 meses) de acordo com o uso e cobertura da terra. Isso posto, a análise estatística de correlação de Pearson permite observar que nos diferentes usos da terra as variações sazonais da cobertura vegetal, com base nos parâmetros biofísicos, possuem correlação mínima ou nula com a precipitação em defasagem temporal de 0 meses (PP0).

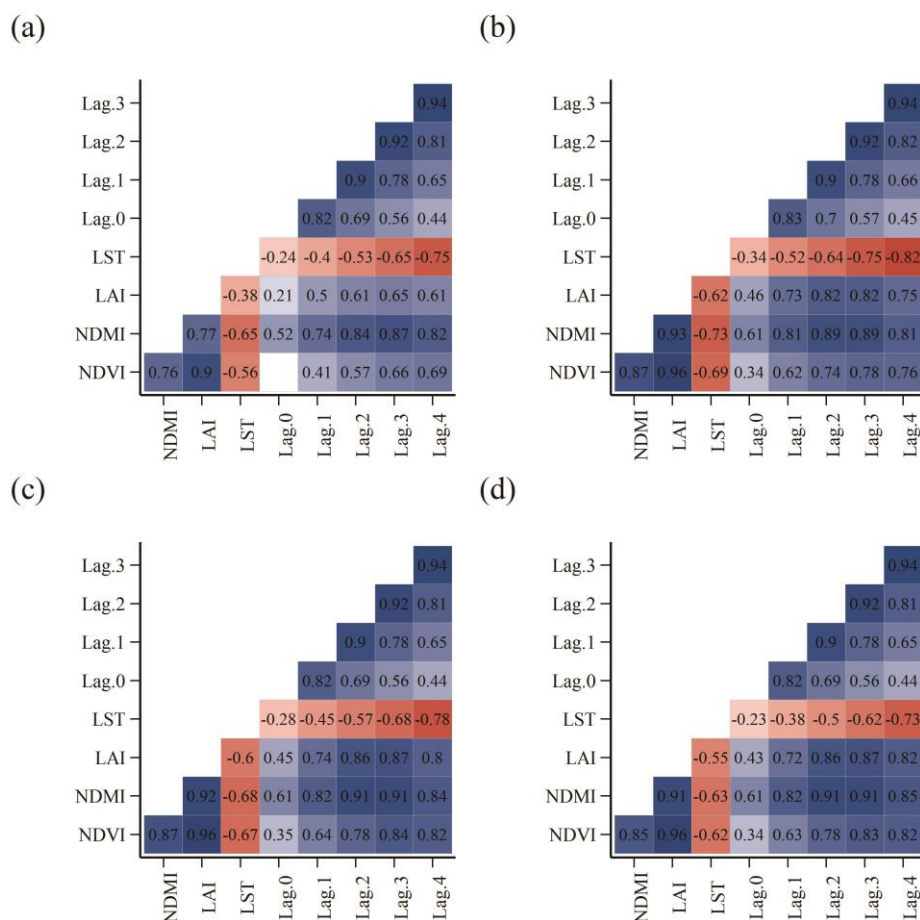
Em contraste, foi constatada elevada correlação positiva significativa entre os parâmetros biofísicos (NDVI, LAI e NDMI) e a precipitação pluviométrica a partir de 1 mês de defasagem (Lag-1), com correlação máxima verificada no período de defasagem de 3 meses (Lag-3) em todas as classes de uso da terra, com exceção do NDVI na classe agricultura irrigada que foi mais sensível a precipitação ocorrida no período de 4 meses de defasagem (Lag-4).

Estes resultados, permitem afirmar que na ausência de irrigação a cobertura vegetal da região em estudo apresenta altamente dependência da variabilidade pluviométrica e rápida resposta da cobertura vegetal aos sinais de precipitação, com o seu pico de resposta a ocorrência de chuvas após 3 meses. A relação entre os índices de vegetação e a precipitação pluviométrica tem sido amplamente relatada. Barbosa et al. (2018) encontraram relações significativas entre NDVI e precipitação, mas as respostas variaram em função do tipo de cobertura vegetal da Caatinga, com defasagens que variaram de 1 a 3 meses.

No presente estudo, a LST mostrou relação inversa com a precipitação, e consequentemente, com os índices NDVI, LAI e NDMI. Por conseguinte, a correlação negativa máxima entre LST e precipitação foi verificada com 4 meses de defasagem (PP4) em todas as classes de uso da terra, com valores entre -0,73 e -0,82 (Figura 29).

Em geral, a redução das chuvas promove o aumento da LST que eleva a taxa de esgotamento da umidade do solo, prejudica a fotossíntese da planta, reduz a taxa de germinação e o estabelecimento de plântulas e aumenta a mortalidade das plantas, culminando em reduções do NDVI, LAI e NDMI. O inverso ocorre com o aumento da precipitação que promove aumento da umidade do solo, possibilitando o crescimento da cobertura vegetal que induz a redução da LST, através de processos biofísicos como redução do albedo da superfície e aumento da evapotranspiração.

Figura 29 - Correlação entre os parâmetros biofísicos e a precipitação pluviométrica para diferentes defasagens temporais (Lag: 0, -1, -2, -3 e -4 meses). (a) agricultura irrigada, (b) Caatinga densa, (c) formação vegetal florestal e (d) área não vegetada.



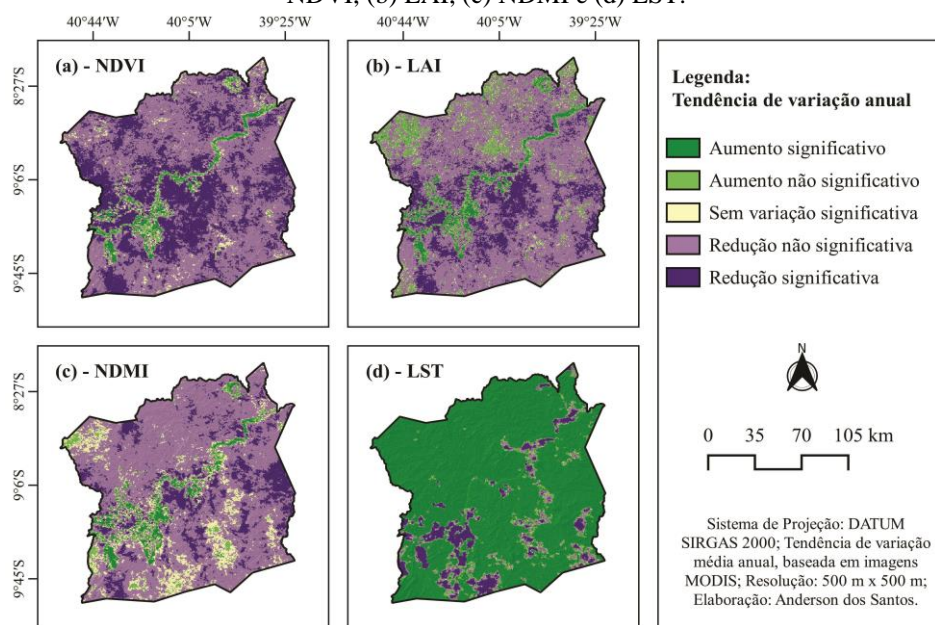
Os parâmetros biofísicos NDVI, LAI, NDMI apresentaram forte correlação entre si, para todos os usos da terra, com valores do coeficiente de correlação de Pearson variando de 0,76 a 0,96. Por outro lado, é possível observar menores correlações da LST com os demais parâmetros biofísicos, principalmente nas classes de agricultura irrigada e área não vegetada. Por conseguinte, a menor correlação da LST com os demais parâmetros biofísicos ocorreu com o LAI, com valores que variaram de  $-0,38$  nas áreas de agricultura irrigada a  $-0,62$  nas áreas de Caatinga densa. Enquanto a maior correlação da LST ocorreu com o NDMI, com valores que oscilaram de  $-0,73$  nas áreas de Caatinga densa a  $-0,62$  nas áreas não vegetadas.

Os resultados evidenciam que os parâmetros biofísicos utilizados no presente estudo quando combinados com informações de precipitação apresentam grande potencial no monitoramento das mudanças espaço temporais do uso e cobertura da terra e da dinâmica e resiliência da cobertura vegetal as mudanças climáticas, em especial a mudanças na variabilidade das chuvas.

#### 4.12 Análise de tendência das alterações espaciais e temporais dos parâmetros biofísicos da superfície da terra

As estimativas de inclinação mediana Theil-Sen são usadas para calcular os valores de tendência e geralmente são usadas em conjunto com o teste não paramétrico Mann-Kendall (MK). Este estudo sobrepôs os resultados da inclinação mediana de Theil-Sen e o teste de MK, para obter as tendências de variação média anual dos parâmetros biofísicos (NDVI, LAI, NDMI e LST) na região em estudo da BHSF em uma escala de pixel, durante o período de 2001 a 2020, a fim de entender se ocorreram mudanças significativas na distribuição espaço-temporal desses parâmetros (Figura 30).

Figura 30 - Tendência de variação média anual na região em estudo da BHSF entre os anos de 2001 a 2020. (a) NDVI, (b) LAI, (c) NDMI e (d) LST.



Os resultados indicam que a região em estudo possui uma cobertura vegetal instável com tendências decrescentes dos valores de NDVI, LAI e NDMI em cerca de 90,43%, 81,58% e 79,59% da região em estudo, respectivamente. Contudo, a proporção de áreas com redução significativa dos valores de NDVI, LAI e NDMI foi de apenas 34,11%, 18,78% e 14,74%, respectivamente (Tabela 13).

As áreas com redução significativa dos parâmetros biofísicos NDVI, LAI e NDMI concentram-se, principalmente, no município de Juazeiro, que representa 34,50%, 41,74% e 53,21% das áreas com redução significativa de NDVI, LAI e NDMI, respectivamente, seguido pelos municípios de Curaçá e Petrolina. É importante destacar que, as áreas com redução

significativa de NDVI, LAI e NDMI são compostas, basicamente, por formação vegetal não florestal (Caatinga herbácea, pastagem e agricultura de sequeiro) e pequenos fragmentos isolados de Caatinga densa.

Tabela 13 - Análise estatística da tendência de variação média anual do NDVI, LAI, NDMI e LST na região em estudo da BHSF durante os anos de 2001 a 2020.

Sen	Valor Z	Mudança de tendência	NDVI	LAI	NDMI	LST
			Área (%)			
>0,0005	>1,96	Aumento significativo	2,75	3,80	3,44	82,51
>0,0005	-1,96-1,96	Aumento não significativo	3,49	12,19	5,59	5,72
-0,0005-0,0005	-1,96-1,96	Sem variação significativa	3,33	2,43	11,28	0,41
<-0,0005	-1,96-1,96	Redução não significativa	56,32	62,8	64,95	4,98
<-0,0005	<-1,96	Redução significativa	34,11	18,78	14,74	6,38

Estudos recentes demonstraram que os efeitos da variabilidade climática e da seca causam redução da umidade, degradação dos pigmentos fotossintéticos, redução da área foliar e mortalidade da vegetação (RUA et al., 2023; SILVA et al., 2021b; MENDES et al., 2013), pode ser a razão, em parte, das tendências observadas no presente estudo. Outras razões podem estar relacionadas aos efeitos das ações antrópicas (por exemplo, desmatamento, queima de biomassa, sobrepastoreio, crescimento urbano, surgimento de áreas de agricultura de sequeiro).

Nos últimos anos, às mudanças na cobertura da terra pela interferência da atividade humana fragilizaram o ecossistema, potencializando os efeitos dos eventos seca na BSHF, que naturalmente é suscetível as variações da precipitação pluviométrica, além de apresenta características geológicas únicas que dificultam o crescimento e desenvolvimento da vegetação (por exemplo: afloramentos rochosos e solos rasos com baixa capacidade de armazenamento de água) (JARDIM et al., 2022). Quando em conjunto estes aspectos agravaram os problemas ambientais da BHSF, tornando a região vulnerável ao processo de desertificação.

Por outro lado, é possível observar uma grande proporção de áreas com tendência de aumento significativo dos valores de LST ao longo de 2001 a 2020, correspondendo a 82,51% da área total da região em estudo da BHSF (Figura 29 e Tabela 13). Deve-se mencionar que vários estudos relacionam o aumento da LST em regiões tropicais ao desmatamento e conversão da vegetação nativa para outros usos da terra (COHN et al., 2019; CROMPTON et al., 2021; SILVÉRIO et al., 2015; CORREIA FILHO et al., 2019b; JARDIM et al., 2022), a redução drástica das chuvas e as condições anormais da vegetação em virtude dos recentes eventos de seca (MARENGO; TORRES; ALVES, 2017; DOS SANTOS et al., 2020a; REINERS; SOBRINO; KUENZER, 2023).

A maioria das áreas com aumento significativo dos valores de NDVI, LAI e NDMI e redução significativa dos valores de LST, correspondem a áreas com agricultura irrigada, circunvizinhas a corpos hídricos, de difícil acesso (por exemplo: áreas com maior altitude ou declividade) e abandonadas que passam por algum grau de recuperação da cobertura vegetal. Ressalta-se que, o município de Juazeiro também concentra a maior proporção de áreas com redução significativa de LST (63,76%).

## 5 CONCLUSÕES

Os resultados da análise dos dados de precipitação do produto CHIRPS evidenciaram que os padrões de precipitação pluviométrica na BHSF estão mudando ao longo dos anos. Além disso, as análises dos dados *in situ* indicaram que a temperatura média do ar para a estação chuvosa NDJ aumentou 0,57 °C e a vazão média anual reduziu 935 m<sup>3</sup>.s<sup>-1</sup> no período de 1991-2020.

As alterações nos padrões de precipitação provocaram eventos de seca meteorológica mais frequente, com maior duração e intensidade, sobretudo entre os anos de 2012 a 2018, coincidindo com o fenômeno El Niño e anomalias de TSM no Atlântico tropical. Além disso, os eventos de seca meteorológica ocorridos no período de 2012 a 2018, culminaram no mais longo e severo evento de seca hidrológica dos últimos trinta anos, com tendências crescentes em escalas temporais de curto e longo prazo, que comprometeram os múltiplos usos d'água na região em estudo da BHSF. Os resultados também sugeriram, que nem todos os anos de El Niño provocam eventos de secas na região em estudo da BHSF, e que nem todas as secas ocorridas na região estão relacionadas a ocorrência de El Niño

Em relação a cobertura vegetal os resultados indicaram uma redução da cobertura vegetal. As principais causas para este declínio podem estar relacionadas a influência das atividades humanas, principalmente, o desmatamento da Caatinga e a degradação da pastagem. A segunda causa está relacionada as mudanças climáticas, que na região em estudo tem provocado o aumento da temperatura do ar e da frequência, duração e intensidade das secas, conforme evidenciado pelos resultados dos parâmetros biofísicos, que indicaram uma baixa capacidade de recuperação da vegetação após anos secos, provocando alterações na cobertura, saúde e vitalidade da vegetação, comprometendo a resiliência da vegetação na BHSF e podendo possivelmente ocasionar uma mudança na composição das espécies vegetais da flora local, tornando a região mais suscetível aos processos de degradação do solo.

As mudanças no uso e cobertura da terra exerceram importante influência na dinâmica espaço-temporal da cobertura vegetal na região em estudo da BHSF no período de 2001 a 2020, ocasionando a redução das áreas de Caatinga densa, como decorrência principalmente da conversão de vegetação nativa densa em áreas para fins agropecuários. Além disso, houve um aumento de 62,70% das áreas de agricultura irrigada. Os resultados também mostraram que houve uma redução de 15,19% das áreas de corpos hídricos, que evidenciou a potencialidade dos efeitos severos dos eventos de seca na BHSF.

Em geral, as modificações na distribuição regional da vegetação influenciaram na variabilidade da precipitação anual, com volume de chuvas 8% maior nas áreas de Caatinga densa em relação as áreas não vegetadas e com formação vegetal não florestal. Além disso, a precipitação influenciou na resposta dos parâmetros biofísicos, confirmando a importância da precipitação como propulsor da cobertura vegetal no bioma Caatinga. Os resultados também evidenciaram, que o pico de resposta da vegetação ocorre após 3 meses da incidência de chuvas, resultando na maior cobertura vegetal ao fim da estação chuvosa.

Na análise das tendências de variação média anual da distribuição espaço-temporal dos parâmetros biofísicos entre 2001 e 2020, conclui-se que a BHSF possui uma cobertura vegetal instável com tendências de redução significativa dos valores de NDVI, LAI e NDMI em cerca de 34,11%, 18,78% e 14,74% da região em estudo, respectivamente. E tendência de aumento significativo dos valores de LST, correspondendo a 82,51% da área total da região em estudo da BHSF, como resultado da redução da cobertura e resiliência da vegetação em decorrência do aumento da frequência e intensidade dos eventos de seca e do uso e cobertura da terra.

Por fim, os resultados evidenciaram que os parâmetros biofísicos utilizados no presente estudo quando combinados com dados hidrometeorológicos apresentam grande potencial no monitoramento das mudanças espaço-temporais do uso e cobertura da terra e da dinâmica e resiliência da cobertura vegetal as mudanças climáticas, podendo contribuir para formulação de políticas públicas de mitigação e adaptação aos eventos climáticos extremos.

## REFERÊNCIAS

- ACHITE, M.; WAŁĘGA, A.; TOUBAL, A. K.; MANSOUR, H.; KRAKAUER, N. Spatiotemporal characteristics and trends of meteorological droughts in the wadi mina basin, northwest algeria. **Water (Switzerland)**, v. 13, n. 21, 2021.
- ADANE, G. B.; HIRPA, B. A.; LIM, C. H.; LEE, W. K. Evaluation and comparison of satellite-derived estimates of rainfall in the diverse climate and terrain of central and northeastern ethiopia. **Remote Sensing**, v. 13, n. 7, 2021.
- AHMED, K. R.; AKTER, S. Analysis of landcover change in southwest Bengal delta due to floods by NDVI, NDWI and K-means cluster with landsat multi-spectral surface reflectance satellite data. **Remote Sensing Applications: Society and Environment**, v. 8, n. August, p. 168–181, 2017.
- ALLEN, R. G.; TASUMI, M.; MORSE, A.; TREZZA, R.; WRIGHT, J. L.; BASTIAANSEN, W.; KRAMBER, W.; LORITE, I.; ROBISON, C. W. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)—Applications. **Journal of Irrigation and Drainage Engineering**, v. 133, n. 4, p. 395–406, 2007.
- ALLEN, R. G.; TASUMI, M.; TREZZA, R.; WATERS, R.; BASTIAANSEN, W. G. M. **SEBAL (Surface Energy Balance Algorithms for Land)**. Advance Training and Users Manual—Idaho Implementation, version, 1.0, 2002. 97 p.
- ALLEY, W. M. The Palmer Drought Severity Index: Limitations and Assumptions. **Journal of Applied Meteorology and Climatology**, v. 23, n. 7, p. 1100–1109, 1984.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ANA. **Sala de Situação do rio São Francisco**. 2020. Disponível em: <<https://www.ana.gov.br/sala-de-situacao/sao-francisco/sao-francisco-saiba-mais>>. Acesso em: 31 out. 2021.
- ANA. **SAR - Sistema de Acompanhamento de Reservatórios**. 2023. Disponível em: <<https://www.ana.gov.br/sar0/MedicaoSin?dropDownListEstados=6&dropDownListReservatorios=19121&dataInicial=01%2F01%2F2015&dataFinal=31%2F12%2F2015&button=Buscar>>. Acesso em: 21 maio. 2023.
- ANTONGIOVANNI, M.; VENTICINQUE, E. M.; FONSECA, C. R. Fragmentation patterns of the Caatinga drylands. **Landscape Ecology**, v. 33, n. 8, p. 1353–1367, 2018.
- ANTONGIOVANNI, M.; VENTICINQUE, E. M.; MATSUMOTO, M.; FONSECA, C. R. Chronic anthropogenic disturbance on Caatinga dry forest fragments. **Journal of Applied Ecology**, v. 57, n. 10, p. 2064–2074, 2020.
- ANYAMBA, A.; TUCKER, C. J. Analysis of Sahelian vegetation dynamics using NOAA-AVHRR NDVI data from 1981-2003. **Journal of Arid Environments**, v. 63, n. 3, p. 596–



614, 2005.

APARECIDO, C. F. F.; VANZELA, L. S.; VAZQUEZ, G. H.; LIMA, R. C. Manejo De Bacias Hidrográficas E Sua Influência Sobre Os Recursos Hídricos. **Irriga**, v. 21, n. 2, p. 239, 2018.

ARNAN, X.; LEAL, I. R.; TABARELLI, M.; ANDRADE, J. F.; BARROS, M. F.; CÂMARA, T.; JAMELLI, D.; KNOECHELMANN, C. M.; MENEZES, T. G. C.; MENEZES, A. G. S.; OLIVEIRA, F. M. P.; DE PAULA, A. S.; PEREIRA, S. C.; RITO, K. F.; SFAIR, J. C.; SIQUEIRA, F. F. S.; SOUZA, D. G.; SPECHT, M. J.; VIEIRA, L. A.; ARCOVERDE, G. B.; ANDERSEN, A. N. A framework for deriving measures of chronic anthropogenic disturbance: Surrogate, direct, single and multi-metric indices in Brazilian Caatinga. **Ecological Indicators**, v. 94, n. July, p. 274–282, 2018.

ARRUDA, V. L. S.; PIONTEKOWSKI, V. J.; ALENCAR, A.; PEREIRA, R. S.; MATRICARDI, E. A. . An alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna. **Remote Sensing Applications: Society and Environment**, v. 22, n. 4, p. 100472, 2021.

ASHOK, A.; RANI, H. P.; JAYAKUMAR, K. V. Monitoring of dynamic wetland changes using NDVI and NDWI based landsat imagery. **Remote Sensing Applications: Society and Environment**, v. 23, n. December 2020, p. 100547, 2021.

AUFFHAMMER, M.; HSIANG, S. M.; SCHLENKER, W.; SOBEL, A. Using Weather Data and Climate Model Output in Economic Analyses of Climate Change. **Review of Environmental Economics and Policy**, v. 7 (2), p. 181–198, 2013.

AZEVEDO, S. C. De; CARDIM, G. P.; PUGA, F.; SINGH, R. P.; DA SILVA, E. A. Analysis of the 2012-2016 drought in the northeast Brazil and its impacts on the Sobradinho water reservoir. **Remote Sensing Letters**, v. 9, n. 5, p. 438–446, 2018.

BAI, Y.; ZHA, T.; BOURQUE, C. P. A.; JIA, X.; MA, J.; LIU, P.; YANG, R.; LI, C.; DU, T.; WU, Y. Variation in ecosystem water use efficiency along a southwest-to-northeast aridity gradient in China. **Ecological Indicators**, v. 110, n. October 2019, p. 105932, 2020.

BANDA, K. . et al. Plant diversity patterns in neotropical dry forests and their conservation implications. **Science**, v. 353, p. 1383–1388, 2016.

BARBOSA, H. A.; HUETE, A. R.; BAETHGEN, W. E. A 20-year study of NDVI variability over the Northeast Region of Brazil. **Journal of Arid Environments**, v. 67, n. 2, p. 288–307, 2006.

BARBOSA, H. A.; LAKSHMI KUMAR, T. V.; PAREDES, F.; ELLIOTT, S.; AYUGA, J. G. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008–2016). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 148, n. December, p. 235–252, 2018.

BAYISSA, Y.; TADESSE, T.; DEMISSE, G.; SHIFERAW, A. Evaluation of satellite-based rainfall estimates and application to monitor meteorological drought for the Upper Blue Nile Basin, Ethiopia. **Remote Sensing**, v. 9, n. 7, p. 1–17, 2017.

BECK, H. E.; ZIMMERMANN, N. E.; MCVICAR, T. R.; VERGOPOLAN, N.; BERG, A.; WOOD, E. F. Present and future köppen-geiger climate classification maps at 1-km resolution. **Scientific Data**, v. 5, p. 1–12, 2018.

BERNARDES, M.; KNOPPERS, B.; REZENDE, C.; SOUZA, W.; OVALLE, A. Land-sea interface features of four estuaries on the South America Atlantic coast. **Brazilian Journal of Biology**, v. 72, n. 3 suppl, p. 761–774, 2012.

BERNHARDT, J.; CARLETON, A. M. Comparing daily temperature averaging methods: the role of surface and atmosphere variables in determining spatial and seasonal variability. **Theoretical and Applied Climatology**, v. 136, n. 1–2, p. 499–512, 2019.

BONTEMPO, E.; DALAGNOL, R.; PONZONI, F.; VALERIANO, D. Adjustments to aid the interpretation of drought responses at the caatinga of Northeast Brazil. **Remote Sensing**, v. 12, n. 19, p. 1–29, 2020.

BRITO, C. S. De; SILVA, R. M. Da; SANTOS, C. A. G.; BRASIL NETO, R. M.; COELHO, V. H. R. 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.

BRITO, S. S. B.; CUNHA, A. P. M. A.; CUNNINGHAM, C. C.; ALVALÁ, R. C.; MARENGO, J. A.; CARVALHO, M. A. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v. 38, n. 2, p. 517–529, 2018.

BUCKLEY, E. E. Drought in the sertão as a natural or social phenomenon: establishing the Inspetoria Federal de Obras Contra as Secas, 1909-1923. **Boletim do Museu Paraense Emílio Goeldi. Ciências Humanas**, v. 5, n. 2, p. 379–398, 2010.

BUTT, N.; DE OLIVEIRA, P. A.; COSTA, M. H. Evidence that deforestation affects the onset of the rainy season in Rondonia, Brazil. **Journal of Geophysical Research Atmospheres**, v. 116, n. 11, p. 2–9, 2011.

CABRAL JÚNIOR, J. B.; SILVA, C. M. S. e.; DE ALMEIDA, H. A.; BEZERRA, B. G.; SPYRIDES, M. H. C. Detecting linear trend of reference evapotranspiration in irrigated farming areas in Brazil's semiarid region. **Theoretical and Applied Climatology**, v. 138, n. 1–2, p. 215–225, 2019.

CÂMARA, E. R. G.; SANTOS, J. C. B. Dos; ARAÚJO FILHO, J. C. De; SCHULZE, S. M. B. B.; CORRÊA, M. M.; FERREIRA, T. O.; SOUSA, J. E. S. De; SOUZA JÚNIOR, V. S. De. Parent rock–pedogenesis relationship: How the weathering of metamorphic rocks influences the genesis of Planosols and Luvisols under a semiarid climate in NE Brazil. **Geoderma**, v. 385, p. 114878, 2021.

CAMPOS-TABERNER, M.; MORENO-MARTÍNEZ, Á.; GARCÍA-HARO, F. J.; CAMPS-VALLS, G.; ROBINSON, N. P.; KATTGE, J.; RUNNING, S. W. Global estimation of biophysical variables from Google Earth Engine platform. **Remote Sensing**, v. 10, n. 8, p. 1–17, 2018.

CANTALICE, J. R. B.; NUNES, E. O. S.; CAVALCANTE, D. M.; BARBOSA, B.; BARROS JUNIOR, G.; GUERRA, S. M. S.; ROLIM NETO, F. C. Vegetative-hydraulic parameters generated by agricultural crops for laminar flows under a semi-arid environment of Pernambuco, Brazil. **Ecological Indicators**, v. 106, n. June, p. 105496, 2019.

CARNEIRO, E.; LOPES, W.; ESPINDOLA, G. Urban land mapping based on remote sensing time series in the google earth engine platform: A case study of the teresina-timon conurbation area in Brazil. **Remote Sensing**, v. 13, n. 7, 2021.

CASTRO, C. N. De; PEREIRA, C. N. **Revitalização da bacia hidrográfica do rio São Francisco histórico, diagnóstico e desafios**. IPEA ed. Brasília, 2019.

CAVALCANTE, G.; MIRANDA, L. B. De; MEDEIROS, P. R. P. Circulation and salt balance in the São Francisco river Estuary (NE/Brazil). **Revista Brasileira de Recursos Hídricos**, v. 22, n. 0, 2017.

CAVALCANTI, I. F. de A. The influence of extratropical Atlantic Ocean region on wet and dry years in north-Northeastern Brazil. **Frontiers in Environmental Science**, v. 3, n. 4, p. 1–10, 2015.

CBHSF. **Os biomas predominantes da bacia do São Francisco**. 2016. Disponível em: <[https://cbhsaofrancisco.org.br/noticias/natureza\\_blog/os-biomas-predominantes-do-vale-do-sao-francisco/](https://cbhsaofrancisco.org.br/noticias/natureza_blog/os-biomas-predominantes-do-vale-do-sao-francisco/)>. Acesso em: 27 ago. 2021.

CECCATO, P.; GOBRON, N.; FLASSE, S.; PINTY, B.; TARANTOLA, S. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. **Remote Sensing of Environment**, v. 82, n. 2–3, p. 198–207, 2002.

CHABARIBERY, D.; SILVA, J. R. Da; TAVARES, L. F. de J.; LOLI, M. V. B.; SILVA, M. R. Da; MONTEIRO, A. V. V. M. Recuperação de matas ciliares: sistemas de formação de floresta nativa em propriedades familiares. **Informações Econômicas**, v. 38, n. 6, p. 7–20, 2008.

CHANDRA, A. Das; NOGUCHI, R.; AHAMED, T. An assessment of drought stress in tea estates using optical and thermal remote sensing. **Remote Sensing**, v. 13, n. 14, 2021.

CHANG, Y.; DING, Y.; ZHAO, Q.; ZHANG, S. Remote estimation of terrestrial evapotranspiration by Landsat 5 TM and the SEBAL model in cold and high-altitude regions: a case study of the upper reach of the Shule River Basin, China. **Hydrological Processes**, v. 31, n. 3, p. 514–524, 2017.

CHAVES, I. de B.; LOPES, V. L.; FFOLLIOTT, P. F.; PAES-SILVA, A. P. Uma Classificação Morfo-Estrutural Para Descrição E a Morfo-Structural Classification for Description and Evaluation of the Biomass of the Caatinga Vegetation. **Revista Brasileira de Geografia Física**, v. 06, n. 2, p. 225–228, 2008.

CHESF. **Sistemas CHESF**. 2017. Disponível em: <<https://www.chesf.gov.br/SistemaChesf/Pages/SistemaGeracao/LuizGonzaga.aspx>>. Acesso

em: 31 out. 2021.

CLIMANÁLISE. **Climanálise Boletim**. 2023. Disponível em: <<http://climanalise.cptec.inpe.br/~rclimanl/boletim/>>. Acesso em: 5 maio. 2023.

CODEVASF. **A bacia do São Francisco**. 2019. Disponível em: <<https://www.codevasf.gov.br/linhas-de-negocio/revitalizacao/conteudo-plano-digital/planos-nascentes/plano-nascente-sao-francisco/a-bacia-do-sao-francisco>>. Acesso em: 27 out. 2021.

COHN, A. S.; BHATTARAI, N.; CAMPOLO, J.; CROMPTON, O.; DRALLE, D.; DUNCAN, J.; THOMPSON, S. Forest loss in Brazil increases maximum temperatures within 50 km. **Environmental Research Letters**, v. 14, n. 8, 2019.

CORREIA FILHO, W. L. F.; DE OLIVEIRA-JÚNIOR, J. F.; DE BARROS SANTIAGO, D.; DE BODAS TERASSI, P. M.; TEODORO, P. E.; DE GOIS, G.; BLANCO, C. J. C.; DE ALMEIDA SOUZA, P. H.; DA SILVA COSTA, M.; GOMES, H. B.; DOS SANTOS, P. J. Rainfall variability in the Brazilian northeast biomes and their interactions with meteorological systems and ENSO via CHELSA product. **Big Earth Data**, v. 3, n. 4, p. 315–337, 2019a.

CORREIA FILHO, W. L. F.; SANTIAGO, D. de B.; DE OLIVEIRA-JÚNIOR, J. F.; SILVA JUNIOR, C. A. Da. Impact of urban decadal advance on land use and land cover and surface temperature in the city of Maceió, Brazil. **Land Use Policy**, v. 87, n. January, p. 104026, 2019b.

COSTA, D. D.; UVO, C. B.; ROLIM DA PAZ, A.; DE OLIVEIRA CARVALHO, F.; FRAGOSO, C. R. Long-term relationships between climate oscillation and basin-scale hydrological variability during rainy season in eastern Northeast Brazil. **Hydrological Sciences Journal**, v. 63, n. 11, p. 1636–1652, 2018.

COSTA, J. C.; PEREIRA, G.; SIQUEIRA, M. E.; DA SILVA CARDOZO, F.; DA SILVA, V. V. Validação Dos Dados De Precipitação Estimados Pelo Chirps Para O Brasil. **Revista Brasileira de Climatologia**, v. 24, p. 228–243, 2019.

COSTA, M. da S.; OLIVEIRA-JÚNIOR, J. F. De; SANTOS, P. J. Dos; CORREIA FILHO, W. L. F.; GOIS, G. De; BLANCO, C. J. C.; TEODORO, P. E.; SILVA JUNIOR, C. A. Da; SANTIAGO, D. de B.; SOUZA, E. de O.; JARDIM, A. M. da R. F. Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño–Southern Oscillation. **International Journal of Climatology**, v. 41, n. S1, p. E2111–E2135, 2021.

COSTA, R. L.; MACEDO DE MELLO BAPTISTA, G.; GOMES, H. B.; DANIEL DOS SANTOS SILVA, F.; LINS DA ROCHA JÚNIOR, R.; DE ARAÚJO SALVADOR, M.; HERDIES, D. L. Analysis of climate extremes indices over northeast Brazil from 1961 to 2014. **Weather and Climate Extremes**, v. 28, 2020.

CREECH, C. T.; SIQUEIRA, R. B.; SELEGEAN, J. P.; MILLER, C. Anthropogenic impacts to the sediment budget of São Francisco River navigation channel using SWAT. **International Journal of Agricultural and Biological Engineering**, , v. 8, n. 3, p. 1–20, 2015.

CROMPTON, O.; CORREA, D.; DUNCAN, J.; THOMPSON, S. Deforestation-induced surface warming is influenced by the fragmentation and spatial extent of forest loss in Maritime Southeast Asia. **Environmental Research Letters**, v. 16, n. 11, 2021.

CUI, Y.; ZENG, C.; CHEN, X.; FAN, W.; LIU, H.; LIU, Y.; XIONG, W.; SUN, C.; LUO, Z. A New Fusion Algorithm for Simultaneously Improving Spatio-temporal Continuity and Quality of Remotely Sensed Soil Moisture over the Tibetan Plateau. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, n. 2016, 2020.

CUNHA, A. P. M. A.; TOMASELLA, J.; RIBEIRO-NETO, G. G.; BROWN, M.; GARCIA, S. R.; BRITO, S. B.; CARVALHO, M. A. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. **Atmospheric Science Letters**, v. 19, n. 10, p. 1–8, 2018.

CUNHA, A. P. M. A.; ZERI, M.; LEAL, K. D.; COSTA, L.; CUARTAS, L. A.; MARENGO, J. A.; TOMASELLA, J.; VIEIRA, R. M.; BARBOSA, A. A.; CUNNINGHAM, C.; CAL GARCIA, J. V.; BROEDEL, E.; ALVALÁ, R.; RIBEIRO-NETO, G. Extreme drought events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n. 11, 2019.

CUNHA, A. P. M.; ALVALÁ, R. C.; NOBRE, C. A.; CARVALHO, M. A. Monitoring vegetative drought dynamics in the Brazilian semiarid region. **Agricultural and Forest Meteorology**, v. 214–215, p. 494–505, 2015.

CUNHA, J. E. d. B. L.; RUFINO, I. A. A.; DA SILVA, B. B.; CHAVES, I. de B. Dynamics of vegetal cover for São João do Rio do Peixe Basin (Paraíba) using remote sensing. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 5, p. 539–548, 2012.

CUNHA, J.; NÓBREGA, R. L. B.; RUFINO, I.; ERASMI, S.; GALVÃO, C.; VALENTE, F. Surface albedo as a proxy for land-cover clearing in seasonally dry forests: Evidence from the Brazilian Caatinga. **Remote Sensing of Environment**, v. 238, n. May 2018, 2020.

DA SILVA, A. S. A.; FILHO, M. C.; MENEZES, R. S. C.; STOSIC, T.; STOSIC, B. Trends and persistence of dry-wet conditions in northeast Brazil. **Atmosphere**, v. 11, n. 10, p. 1–15, 2020.

DAS, A. C.; SHAHRIAR, S. A.; CHOWDHURY, M. A.; HOSSAIN, M. L.; MAHMUD, S.; TUSAR, M. K.; AHMED, R.; SALAM, M. A. Assessment of remote sensing-based indices for drought monitoring in the north-western region of Bangladesh. **Heliyon**, v. 9, n. 2, p. e13016, 2023.

DENG, Y.; JIANG, W.; TANG, Z.; LING, Z.; WU, Z. Long-term changes of open-surface water bodies in the Yangtze River Basin based on the Google Earth Engine cloud platform. **Remote Sensing**, v. 11, n. 19, 2019.

DENG, Y.; WANG, S.; BAI, X.; TIAN, Y.; WU, L.; XIAO, J.; CHEN, F.; QIAN, Q. Relationship among land surface temperature and LUCC, NDVI in typical karst area. **Scientific Reports**, v. 8, n. 1, p. 1–12, 2018.

DI VITTORIO, A. V.; MILLER, N. L. Evaluating a modified point-based method to downscale cell-based climate variable data to high-resolution grids. **Theoretical and Applied Climatology**, v. 112, n. 3–4, p. 495–519, 2013.

DIDAN, K.; MUNOZ, A. B.; SOLANO, R.; HUETE, A. **MODIS Vegetation Index User 's Guide (Collection 6)**. University ed. v. 3, 2015.

DINIZ, C.; CORTINHAS, L.; NERINO, G.; RODRIGUES, J.; SADECK, L.; ADAMI, M.; SOUZA-FILHO, P. W. M. Brazilian mangrove status: Three decades of satellite data analysis. **Remote Sensing**, v. 11, n. 7, 2019.

DOS SANTOS, C. A. C.; MARIANO, D. A.; DAS CHAGAS A. DO NASCIMENTO, F.; FABIANE, F. R.; DE OLIVEIRA, G.; SILVA, M. T.; DA SILVA, L. L.; DA SILVA, B. B.; BEZERRA, B. G.; SAFA, B.; DE S. MEDEIROS, S.; NEALE, C. M. U. Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. February 2019, p. 101982, 2020a.

DOS SANTOS, C. A. C.; MARIANO, D. A.; DAS CHAGAS A. DO NASCIMENTO, F.; FABIANE, F. R.; DE OLIVEIRA, G.; SILVA, M. T.; DA SILVA, L. L.; DA SILVA, B. B.; BEZERRA, B. G.; SAFA, B.; DE S. MEDEIROS, S.; NEALE, C. M. U. Spatio-temporal patterns of energy exchange and evapotranspiration during an intense drought for drylands in Brazil. **International Journal of Applied Earth Observation and Geoinformation**, v. 85, n. February 2019, 2020b.

EDWARDS, D.; MCKEE, T. Characteristics of 20th century drought in the United States at multiple time scales. **Climatology Report No. 97-2**, n. May 1–30., p. 1–172, 1997.

ELEFThERIOU, D.; KIACHIDIS, K.; KALMINTZIS, G.; KALEA, A.; BANTASIS, C.; KOUMADORAKI, P.; SPATHARA, M. E.; TSOLAKI, A.; TZAMPAZIDOU, M. I.; GEMITZI, A. Determination of annual and seasonal daytime and nighttime trends of MODIS LST over Greece - climate change implications. **Science of The Total Environment**, v. 616–617, p. 937–947, 2018.

EOS. **NDMI (Normalized Difference Moisture Index)**. 2023. Disponível em: <<https://eos.com/pt/make-an-analysis/ndmi/>>. Acesso em: 19 maio. 2023.

ERFANIAN, A.; WANG, G.; FOMENKO, L. Unprecedented drought over tropical South America in 2016: Significantly under-predicted by tropical SST. **Scientific Reports**, v. 7, n. 1, p. 22–24, 2017.

ESPINDOLA, G. M. De; DE SILVA FIGUEREDO, E.; PIKANÇO JÚNIOR, P.; DOS REIS FILHO, A. A. Cropland expansion as a driver of land-use change: the case of Cerrado-Caatinga transition zone in Brazil. **Environment, Development and Sustainability**, 2021.

ESSE, C.; CORREA-ARANEDA, F.; ACUÑA, C.; SANTANDER-MASSA, R.; DE LOS RÍOS-ESCALANTE, P.; SAAVEDRA, P.; JAQUE-JARAMILLO, X.; MORENO, R.; GARCÍA-MENESES, P. M.; SOTO, D. P. Structure, diversity, and environmental determinants of high-latitude threatened conifer forests. **Forests**, v. 12, n. 6, 2021.

FAO. Iuss Working Group WRB, 2015. **World reference base for soil resources 2014, update 2015: International soil classification system for naming soils and creating legends for soil maps**. Food and Agriculture Organization of the United Nations. Rome.

FENDRICH, A. N.; BARRETTO, A.; DE FARIA, V. G.; DE BASTIANI, F.; TENNESON, K.; GUEDES PINTO, L. F.; SPAROVEK, G. Disclosing contrasting scenarios for future land cover in Brazil: Results from a high-resolution spatiotemporal model. **Science of the Total Environment**, v. 742, p. 140477, 2020.

FERNANDES, M. M.; FERNANDES, M. R. de M.; GARCIA, J. R.; MATRICARDI, E. A. T.; DE ALMEIDA, A. Q.; PINTO, A. S.; MENEZES, R. S. C.; SILVA, A. de J.; LIMA, A. H. de S. Assessment of land use and land cover changes and valuation of carbon stocks in the Sergipe semiarid region, Brazil: 1992–2030. **Land Use Policy**, v. 99, n. May, p. 104795, 2020.

FERREIRA, J. M. S.; FERREIRA, H. dos S.; SILVA, H. A. Da; SANTOS, A. M. Dos; GALVÍNCIO, J. D. Análise Espaço-Temporal da Dinâmica da Vegetação de Caatinga no Município de Petrolina – PE. **Revista Brasileira de Geografia Física**, v. 04, p. 904–922, 2012.

FERREIRA, T. R.; SILVA, B. B. D.; DE MOURA, M. S. B.; VERHOEF, A.; NÓBREGA, R. L. B. The use of remote sensing for reliable estimation of net radiation and its components: a case study for contrasting land covers in an agricultural hotspot of the Brazilian semiarid region. **Agricultural and Forest Meteorology**, v. 291, n. January, p. 108052, 2020.

FEYISA, G. L.; MEILBY, H.; FENSHOLT, R.; PROUD, S. R. Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. **Remote Sensing of Environment**, v. 140, p. 23–35, 2014.

FRANCISCO, P. R. M.; CHAVES, I. B.; CHAVES, L. H. G.; BRANDÃO, Z. N.; LIMA, E. R. V.; SILVA, B. B. Mapeamento da Vulnerabilidade das Terras da Bacia Hidrográfica do Rio Taperoá. **Revista Brasileira de Geografia Física**, v. 06, p. 1275–1291, 2013.

FREITAS, A. A.; DRUMOND, A.; CARVALHO, V. S. B.; REBOITA, M. S.; SILVA, B. C.; UVO, C. B. Drought Assessment in São Francisco River Basin, Brazil: Characterization through SPI and Associated Anomalous Climate Patterns. **Atmosphere**, v. 13, n. 1, 2022.

FREITAS, C. De. Old Chico's new tricks: Neoliberalization and water sector reform in Brazil's São Francisco River Basin. **Geoforum**, v. 64, p. 292–303, 2015.

FU, R.; YIN, L.; LI, W.; ARIAS, P. A.; DICKINSON, R. E.; HUANG, L.; CHAKRABORTY, S.; FERNANDES, K.; LIEBMANN, B.; FISHER, R.; MYNENI, R. B. Increased dry-season length over southern Amazonia in recent decades and its implication for future climate projection. **Proceedings of the National Academy of Sciences of the United States of America**, v. 110, n. 45, p. 18110–18115, 2013.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. **Scientific Data**, v. 2, p. 1–21, 2015.

GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. December 1996, p. 257–

266, 1996.

GARCÍA-LEÓN, D.; CONTRERAS, S.; HUNINK, J. Comparison of meteorological and satellite-based drought indices as yield predictors of Spanish cereals. **Agricultural Water Management**, v. 213, n. May 2018, p. 388–396, 2019.

GAZNAYEE, H. A. A.; ZAKI, S. H.; AL-QURAIISHI, A. M. F.; ALIEHSAN, P. H.; HAKZI, K. K.; RAZVANCHY, H. A. S.; RIKSEN, M.; MAHDI, K. Integrating Remote Sensing Techniques and Meteorological Data to Assess the Ideal Irrigation System Performance Scenarios for Improving Crop Productivity. **Water**, v. 15, n. 8, p. 1605, 2023.

GENZ, F.; LUZ, L. D. Distinguishing the effects of climate on discharge in a tropical river highly impacted by large dams. **Hydrological Sciences Journal**, v. 57, n. 5, p. 1020–1034, 2012.

GHAZARYAN, G.; DUBOVYK, O.; GRAW, V.; KUSSUL, N.; SCHELLBERG, J. Local-scale agricultural drought monitoring with satellite-based multi-sensor time-series. **GIScience and Remote Sensing**, v. 57, n. 5, p. 704–718, 2020.

GHULAM, A.; QIN, Q.; TEYIP, T.; ZHAN, Z. Designing of the perpendicular drought index. **Environmental Geology**, v. 52, n. 6, p. 1045–1052, 2007.

GIANNINI, A.; SARAVANAN, R.; CHANG, P. The preconditioning role of Tropical Atlantic Variability in the development of the ENSO teleconnection: Implications for the prediction of Nordeste rainfall. **Climate Dynamics**, v. 22, n. 8, p. 839–855, 2004.

GOMES, R. dos S.; LIMA, K. C. Influence of the modes of climate variability in the Tropical Pacific and Atlantic on accumulated rainfall and reservoir water volumes in the Northeast Brazil. **International Journal of Climatology**, v. 41, n. 11, p. 5331–5349, 2021.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, n. 2016, p. 18–27, 2017.

GOSHIME, D. W.; ABSI, R.; LEDÉSSERT, B. Evaluation and bias correction of CHIRP rainfall estimate for rainfall-runoff simulation over Lake Ziway Watershed, Ethiopia. **Hydrology**, v. 6, n. 3, 2019.

GU, Y.; BROWN, J. F.; VERDIN, J. P.; WARDLOW, B. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. **Geophysical Research Letters**, v. 34, n. 6, p. 1–6, 2007.

GU, Y.; HUNT, E.; WARDLOW, B.; BASARA, J. B.; BROWN, J. F.; VERDIN, J. P. Evaluation of MODIS NDVI and NDWI for vegetation drought monitoring using Oklahoma Mesonet soil moisture data. **Geophysical Research Letters**, v. 35, n. 22, p. 1–5, 2008.

GUO, H.; BAO, A.; LIU, T.; NDAYISABA, F.; HE, D.; KURBAN, A.; DE MAEYER, P. Meteorological drought analysis in the Lower Mekong Basin using satellite-based long-term CHIRPS product. **Sustainability (Switzerland)**, v. 9, n. 6, 2017.



HAO, X.; LI, W.; DENG, H. The oasis effect and summer temperature rise in arid regions - Case study in Tarim Basin. **Scientific Reports**, v. 6, n. September, p. 1–9, 2016.

HARSÁNYI, E.; BASHIR, B.; ALSILIBE, F.; ALSAFADI, K.; ALSALMAN, A.; SZÉLES, A.; RAHMAN, M. H. U.; BÁCSKAI, I.; JUHÁSZ, C.; RATONYI, T.; MOHAMMED, S. Impact of agricultural drought on sunflower production across Hungary. **Atmosphere**, v. 12, n. 10, 2021.

HOAGLAND, S. J.; BEIER, P.; LEE, D. Using MODIS NDVI phenoclasses and phenoclusters to characterize wildlife habitat: Mexican spotted owl as a case study. **Forest Ecology and Management**, v. 412, n. October, p. 80–93, 2018.

HORDOFA, A. T.; LETA, O. T.; ALAMIREW, T.; KAWO, N. S.; CHUKALLA, A. D. Performance evaluation and comparison of satellite-derived rainfall datasets over the Ziway lake basin, Ethiopia. **Climate**, v. 9, n. 7, 2021.

HOU, Q.; JI, Z.; YANG, H.; YU, X. Impacts of climate change and human activities on different degraded grassland based on NDVI. **Scientific Reports**, v. 12, n. 1, 2022.

HOUNSOU-GBO, G. A.; ARAUJO, M.; BOURLÈS, B.; VELEDA, D.; SERVAIN, J. Tropical Atlantic contributions to strong rainfall variability along the northeast Brazilian coast. **Advances in Meteorology**, v. 2015, 2015.

HUETE, A.; DIDAN, K.; VAN LEEUWEN, W.; MIURA, T.; GLENN, E. **MODIS Vegetation Indices. In Land Remote Sensing and Global Environmental Change: NASA's Earth Observing System and the Science of ASTER and MODIS**. Springer ed. New York, NY, USA, 2011.

HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295–309, 1988.

JABER, S. M.; ABU-ALLABAN, M. M. MODIS-based land surface temperature for climate variability and change research: the tale of a typical semi-arid to arid environment. **European Journal of Remote Sensing**, v. 53, n. 1, p. 81–90, 2020.

JARDIM, A. M. da R. F.; DA SILVA, M. V.; SILVA, A. R.; SANTOS, A. Dos; PANDORFI, H.; DE OLIVEIRA-JÚNIOR, J. F.; DE LIMA, J. L. M. P.; DE SOUZA, L. S. B.; JÚNIOR, G. do N. A.; LOPES, P. M. O.; DE ALBUQUERQUE MOURA, G. B.; DA SILVA, T. G. F. Spatiotemporal climatic analysis in Pernambuco State, Northeast Brazil. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 223, n. February, p. 105733, 2021a.

JARDIM, A. M. da R. F.; JÚNIOR, G. do N. A.; SILVA, M. V. Da; SANTOS, A. Dos; SILVA, J. L. B. Da; PANDORFI, H.; OLIVEIRA-JÚNIOR, J. F. De; TEIXEIRA, A. H. de C.; TEODORO, P. E.; LIMA, J. L. M. P. De; JUNIOR, C. A. da S.; SOUZA, L. S. B. De; SILVA, E. A.; SILVA, T. G. F. Da. 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.

JARDIM, A. M. da R. F.; MORAIS, J. E. F. De; SOUZA, L. S. B. De; LOPES, D. de C.;

SILVA, M. V. Da; PANDORFI, H.; OLIVEIRA-JÚNIOR, J. F. De; SILVA, J. L. B. Da; STEIDLE NETO, A. J.; MORELLATO, L. P. C.; DE LIMA, J. L. M. P.; SILVA, T. G. F. Da. A systematic review of energy and mass fluxes, and biogeochemical processes in seasonally dry tropical forests and cactus ecosystems. **Journal of South American Earth Sciences**, v. 126, n. February, 2023.

JARDIM, A. M. da R. F.; SANTOS, H. R. B.; ALVES, H. K. M. N.; FERREIRA-SILVA, S. L.; SOUZA, L. S. B. De; ARAÚJO JÚNIOR, G. do N.; SOUZA, M. de S.; ARAÚJO, G. G. L. De; SOUZA, C. A. A. De; SILVA, T. G. F. Da. No Title Genotypic differences relative photochemical activity, inorganic and organic solutes and yield performance in clones of the forage cactus under semi-arid environment. **Plant Physiology and Biochemistry**, v. 162, n. 5, p. 421–430, 2021b.

JL, L.; ZHANG, L.; WYLIE, B. K.; ROVER, J. On the terminology of the spectral vegetation index  $(NIR - SWIR)/(NIR+SWIR)$ . **International Journal of Remote Sensing**, v. 32, n. 21, p. 6901–6909, 2011.

JIANG, F.; CHEN, C.; LI, C.; KUTIA, M.; SUN, H. A Novel Spatial Simulation Method for Mapping the Urban Forest Carbon Density in Southern China by the Google Earth Engine. **Remote Sensing**, v. 13, n. 14, p. 2792, 2021.

JONG, P. De; TANAJURA, C. A. S.; SÁNCHEZ, A. S.; DARGAVILLE, R.; KIPERSTOK, A.; TORRES, E. A. Hydroelectric production from Brazil's São Francisco River could cease due to climate change and inter-annual variability. **Science of the Total Environment**, v. 634, p. 1540–1553, 2018.

JUNQUEIRA, R.; VIOLA, M. R.; DE MELLO, C. R.; VIEIRA-FILHO, M.; ALVES, M. V. G.; AMORIM, J. da S. Drought severity indexes for the Tocantins River Basin, Brazil. **Theoretical and Applied Climatology**, v. 141, n. 1–2, p. 465–481, 2020.

JUSTICE, C. O.; TOWNSHEND, J. R. G.; VERMOTE, E. F.; MASUOKA, E.; WOLFE, R. E.; SALEOUS, N.; ROY, D. P.; MORISETTE, J. T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1–2, p. 3–15, 2002.

KAISER, H. F. The varimax criterion for analytic rotation in factor analysis. **Psychometrika**, v. 23, n. 3, p. 187–200, 1958.

KALISA, W.; ZHANG, J.; IGBAWUA, T.; KAYIRANGA, A.; UJOH, F.; AONDOAKAA, I. S.; TUYISHIME, P.; LI, S.; SIMBI, C. H.; NIBAGWIRE, D. Spatial Multi-Criterion Decision Making ( SMDM ) Drought Assessment and Sustainability over East Africa from 1982 to 2015. **Remote Sensing**, v. 13, n. 24, p. 5067, 2021.

KANG, Y.; GUO, E.; WANG, Y.; BAO, Y.; BAO, Y.; MANDULA, N. Monitoring Vegetation Change and Its Potential Drivers in Inner Mongolia from 2000 to 2019. **Remote Sensing**, v. 13, p. 1–25, 2021.

KC, K.; ZHAO, K.; ROMANKO, M.; KHANAL, S. Assessment of the spatial and temporal patterns of cover crops using remote sensing. **Remote Sensing**, v. 13, n. 14, 2021.

KENDALL, M. G. **Rank Correlation Methods**. Charles Gr ed. London, 1975.

KIM, S. W.; JUNG, Y. Y. Application of the InVEST model to quantify the water yield of North Korean forests. **Forests**, v. 11, n. 8, p. 1–11, 2020.

KOCH, R.; ALMEIDA-CORTEZ, J. S.; KLEINSCHMIT, B. Revealing areas of high nature conservation importance in a seasonally dry tropical forest in Brazil: Combination of modelled plant diversity hot spots and threat patterns. **Journal for Nature Conservation**, v. 35, p. 24–39, 2017.

KOVDA, I. Vertisols: Extreme features and extreme environment. **Geoderma Regional**, v. 22, p. e00312, 2020.

LAWRENCE, D.; VANDECAR, K. Effects of tropical deforestation on climate and agriculture. **Nature Climate Change**, v. 5, n. 1, p. 27–36, 2015.

LEE, Y.; KIM, S. The modified SEBAL for mapping daily spatial evapotranspiration of South Korea using three flux towers and Terra MODIS data. **Remote Sensing**, v. 8, n. 12, 2016.

LI, W.; NIU, Z.; SHANG, R.; QIN, Y.; WANG, L.; CHEN, H. High-resolution mapping of forest canopy height using machine learning by coupling ICESat-2 LiDAR with Sentinel-1, Sentinel-2 and Landsat-8 data. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, n. February, p. 102163, 2020.

LI, Z. L.; TANG, B. H.; WU, H.; REN, H.; YAN, G.; WAN, Z.; TRIGO, I. F.; SOBRINO, J. A. Satellite-derived land surface temperature: Current status and perspectives. **Remote Sensing of Environment**, v. 131, p. 14–37, 2013.

LI, Z.; ZHAO, L.; WANG, L.; ZOU, D.; LIU, G.; HU, G.; DU, E.; XIAO, Y.; LIU, S.; ZHOU, H.; XING, Z.; WANG, C.; ZHAO, J.; CHEN, Y.; QIAO, Y.; SHI, J. Retrieving Soil Moisture in the Permafrost Environment by Sentinel-1/2 Temporal Data on the Qinghai–Tibet Plateau. **Remote Sensing**, v. 14, n. 23, p. 1–21, 2022.

LIMA, F. J. L. De; MARTINS, F. R.; COSTA, R. S.; GONÇALVES, A. R.; DOS SANTOS, A. P. P.; PEREIRA, E. B. The seasonal variability and trends for the surface solar irradiation in northeastern region of Brazil. **Sustainable Energy Technologies and Assessments**, v. 35, n. August, p. 335–346, 2019.

LINDSEY, R.; HERRING, D.; ABBOTT, M.; CONBOY, B.; ESAIAS, W.; JUSTICE, C.; KING, M.; MURPHY, B.; SALOMONSON, V. **The moderate resolution imaging spectrometer (MODIS)**, 2020.

LINS, C. M. T.; SOUZA, E. R. De; SOUZA, T. E. M. dos S.; PAULINO, M. K. S. S.; MONTEIRO, D. R.; SOUZA JÚNIOR, V. S. De; DOURADO, P. R. M.; REGO JUNIOR, F. E. de A.; SILVA, Y. J. A. Da; SCHAFFER, B. Influence of vegetation cover and rainfall intensity on soil attributes in an area undergoing desertification in Brazil. **CATENA**, v. 221, p. 106751, 2023.

LONG, D.; YAN, L.; BAI, L.; ZHANG, C.; LI, X.; LEI, H.; YANG, H.; TIAN, F.; ZENG,

C.; MENG, X.; SHI, C. Generation of MODIS-like land surface temperatures under all-weather conditions based on a data fusion approach. **Remote Sensing of Environment**, v. 246, n. April, p. 111863, 2020.

LU, Y.; WU, P.; MA, X.; YANG, H.; WU, Y. Monitoring Seasonal and Diurnal Surface Urban Heat Islands Variations Using Landsat-Scale Data in Hefei, China, 2000-2017. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 13, p. 6410–6423, 2020.

LUHAIM, Z. Bin; TAN, M. L.; TANGANG, F.; ZULKAFI, Z.; CHUN, K. P.; YUSOP, Z.; YASEEN, Z. M. Drought variability and characteristics in the muda river basin of malaysia from 1985 to 2019. **Atmosphere**, v. 12, n. 9, p. 1–19, 2021.

LUO, J.; MA, X.; CHU, Q.; XIE, M.; CAO, Y. Characterizing the Up-To-Date Land-Use and Land-Cover Change in Xiong'an New Area from 2017 to 2020 Using the Multi-Temporal Sentinel-2 Images on Google Earth Engine. **ISPRS International Journal of Geo-Information**, v. 10, n. 7, p. 464, 2021.

LYRA, G. B.; OLIVEIRA-JÚNIOR, J. F.; GOIS, G.; CUNHA-ZERI, G.; ZERI, M. Rainfall variability over Alagoas under the influences of SST anomalies. **Meteorology and Atmospheric Physics**, v. 129, n. 2, p. 157–171, 2017.

LYU, J.; YIN, S.; SUN, Y.; WANG, K.; LUO, P.; MENG, X. Flood Runoff Simulation under Changing Environment, Based on Multiple Satellite Data in the Jinghe River Basin of the Loess Plateau, China. **Remote Sensing**, v. 15, n. 3, p. 550, 2023.

MANETA, M. P.; TORRES, M.; WALLENDER, W. W.; VOSTI, S.; KIRBY, M.; BASSOI, L. H.; RODRIGUES, L. N. Water demand and flows in the São Francisco River Basin (Brazil) with increased irrigation. **Agricultural Water Management**, v. 96, n. 8, p. 1191–1200, 2009.

MANN, H. B. Non-parametric test against trend. **Econometrica: Journal of the Econometric Society**, v. 13, n. 3, p. 245–259, 1945.

MARENGO, J. A.; ALVES, L. M.; ALVALA, R. C. S.; CUNHA, A. P.; BRITO, S.; MORAES, O. L. L. Climatic characteristics of the 2010-2016 drought in the semiarid northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 90, n. 2, p. 1973–1985, 2018.

MARENGO, J. A.; ALVES, L. M.; SOARES, W. R.; RODRIGUEZ, D. A.; CAMARGO, H.; RIVEROS, M. P.; PABLÓ, A. D. Two contrasting severe seasonal extremes in tropical South America in 2012: Flood in Amazonia and drought in Northeast Brazil. **Journal of Climate**, v. 26, n. 22, p. 9137–9154, 2013.

MARENGO, J. A.; CUNHA, A. P. M. A.; NOBRE, C. A.; RIBEIRO NETO, G. G.; MAGALHAES, A. R.; TORRES, R. R.; SAMPAIO, G.; ALEXANDRE, F.; ALVES, L. M.; CUARTAS, L. A.; DEUSDARÁ, K. R. L.; ÁLVALA, R. C. S. Assessing drought in the drylands of northeast Brazil under regional warming exceeding 4 °C. **Natural Hazards**, v. 103, n. 2, p. 2589–2611, 2020.

MARENGO, J. A.; TORRES, R. R.; ALVES, L. M. Drought in Northeast Brazil—past, present, and future. **Theoretical and Applied Climatology**, v. 129, n. 3–4, p. 1189–1200, 2017.

MARIANO, D. A.; SANTOS, C. A. C. do.; WARDLOW, B. D.; ANDERSON, M. C.; SCHILTMAYER, A. V.; TADESSE, T.; SVOBODA, M. D. Use of remote sensing indicators to assess effects of drought and human-induced land degradation on ecosystem health in Northeastern Brazil. **Remote Sensing of Environment**, v. 213, n. September 2017, p. 129–143, 2018.

MARQUES, T. V.; MENDES, K.; MUTTI, P.; MEDEIROS, S.; SILVA, L.; PEREZ-MARIN, A. M.; CAMPOS, S.; LÚCIO, P. S.; LIMA, K.; DOS REIS, J.; RAMOS, T. M.; DA SILVA, D. F.; OLIVEIRA, C. P.; COSTA, G. B.; ANTONINO, A. C. D.; MENEZES, R. S. C.; SANTOS E SILVA, C. M.; BEZERRA, B. Environmental and biophysical controls of evapotranspiration from Seasonally Dry Tropical Forests (Caatinga) in the Brazilian Semiarid. **Agricultural and Forest Meteorology**, v. 287, n. February 2019, p. 107957, 2020.

MARTINS, M. A.; TOMASELLA, J.; RODRIGUEZ, D. A.; ALVALÁ, R. C. S.; GIAROLLA, A.; GAROFOLO, L. L.; JÚNIOR, J. L. S.; PAOLICCHI, L. T. L. C.; PINTO, G. L. N. Improving drought management in the Brazilian semiarid through crop forecasting. **Agricultural Systems**, v. 160, n. November 2016, p. 21–30, 2018a.

MARTINS, V. S.; KALEITA, A.; BARBOSA, C. C. F.; FASSONI-ANDRADE, A. C.; LOBO, F. de L.; NOVO, E. M. L. M. 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, 2018b.

MCFEETERS, S. K. Landslides Extraction From Diverse Remote Sensing Data Sources. **Remote Sensing of Environment**, v. 25, n. 3, p. 687–711, 1996.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales Preprints. **Eighth Conference on Applied Climatology**, p. 1–6, 1993.

MEDEIROS, F. J. De; LIMA, K. C.; CAETANO, D. D. A.; SILVA, F. J. D. O. Impact of the interannual variability of precipitation on the reservoirs of the Semiarid Northeast Brazil Region. **Anuario do Instituto de Geociencias**, v. 41, n. 3, p. 731–741, 2018.

MEDEIROS, F. J. De; OLIVEIRA, C. P. De; TORRES, R. R.; RODRIGUES, D. Climatic aspects and vertical structure circulation associated with the severe drought in Northeast Brazil (2012–2016). **Climate Dynamics**, v. 55, n. 9–10, p. 2327–2341, 2020.

MEDEIROS, P. R. P.; CAVALCANTE SEGUNDO, G. H.; MAGALHÃES, E. M. M. Comportamento da turbidez e material em suspensão, em um rio com vazão regularizada por sistema de barragens em cascata: Rio São Francisco (NE, Brasil). **Geochimica Brasiliensis**, v. 29, n. 1, p. 35–44, 2015.

MEDEIROS, P. R. P.; SANTOS, M. M. Dos; CAVALCANTE, G. H.; SOUZA, W. F. L. De; SILVA, W. F. Da. Características ambientais do Baixo São Francisco (AL/SE): efeitos de barragens no transporte de materiais na interface continente-oceano. **Geochimica**

**Brasiliensis**, v. 28, n. 1, p. 65–78, 2014.

MEDEIROS, R.; ANDRADE, J.; RAMOS, D.; MOURA, M.; PÉREZ-MARIN, A. M.; DOS SANTOS, C. A. C.; DA SILVA, B. B.; CUNHA, J. Remote Sensing Phenology of the Brazilian Caatinga and Its Environmental Drivers. **Remote Sensing**, v. 14, n. 11, 2022.

MEKANIK, F.; IMTEAZ, M. A.; GATO-TRINIDAD, S.; ELMAHDI, A. Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. **Journal of Hydrology**, v. 503, p. 11–21, 2013.

MELO, S. C. De; ARAÚJO FILHO, J. C. De; CARVALHO, R. M. C. M. de O. Keys curves of sediment discharges in suspension in the Lower São Francisco. **Revista Brasileira de Geografia Física**, v. 13, n. 03, p. 1248–1262, 2020.

MENDES, K. R.; GRANJA, J. A. A.; OMETTO, J. P.; ANTONINO, A. C. D.; MENEZES, R. S. C.; PEREIRA, E. C.; POMPELLI, M. F. Croton blanchetianus modulates its morphophysiological responses to tolerate drought in a tropical dry forest. **Functional Plant Biology**, v. 44, n. 10, p. 1039–1051, 2017.

MENDES, M. M. de S.; LACERDA, C. F. De; FERNANDES, F. É. P.; CAVALCANTE, A. C. R.; OLIVEIRA, T. S. De. Ecophysiology of deciduous plants grown at different densities in the semiarid region of Brazil. **Theoretical and Experimental Plant Physiology**, v. 25, n. 2, p. 94–105, 2013.

MESA, O.; URREA, V.; OCHOA, A. Trends of hydroclimatic intensity in Colombia. **Climate**, v. 9, n. 7, p. 120–143, 2021.

MMA. **Ministério do Meio Ambiente**. 2021. Disponível em: <<https://antigo.mma.gov.br/biomas/caatinga.html>>. Acesso em: 27 ago. 2021.

MOLION, L. C. B.; BERNADO, S. de O. Uma Revisão da Dinâmica das Chuvas no Nordeste brasileiro. **Revista Brasileira de Meteorologia**, v. v.17, n.1, p. 1–10, 2002.

MONDAL, P.; LIU, X.; FATOYINBO, T. E.; LAGOMASINO, D. Evaluating combinations of sentinel-2 data and machine-learning algorithms for mangrove mapping in West Africa. **Remote Sensing**, v. 11, n. 24, 2019.

MOURA, G. B. de A.; BRITO, J. I. B. De; SOUSA, F. de A. S. De; CAVALCANTI, E. P.; SILVA, J. L. B. Da; NASCIMENTO, C. R.; LOPES, P. M. O. Identificação de preditores para as chuvas do setor leste do Nordeste do Brasil utilizando análise de correlação canônica. **Revista Brasileira De Geografia**, v. v.13, n.04, p. 1463–1482, 2020.

MOURA NETO, A. De; FERNANDES, G. S. T.; LOPES, J. R. de A.; LIMA, E. de A.; LOPES, P. M. O.; RODRIGUES, L. S.; GONÇALVES JUNIOR, A. da S. Changes in land use and cover and their consequences on the spatial distribution of evapotranspiration and climatic elements in southwest Piauí, MATOPIBA. **Journal of South American Earth Sciences**, v. 120, p. 104084, 2022.

MUTTI, P. R.; DE ABREU, L. P.; DE M. B. ANDRADE, L.; SPYRIDES, M. H. C.; LIMA, K. C.; DE OLIVEIRA, C. P.; DUBREUIL, V.; BEZERRA, B. G. A detailed framework for

the characterization of rainfall climatology in semiarid watersheds. **Theoretical and Applied Climatology**, v. 139, n. 1–2, p. 109–125, 2020.

NASA/MODIS. **National Aeronautics and Space Administration/ Moderate Resolution Imaging Spectroradiometer**. 2021. Disponível em:

<<https://modis.gsfc.nasa.gov/data/dataproduct/>>. Acesso em: 27 ago. 2021.

NASA/USGS. **National Aeronautics and Space Administration/United States Geological Survey**. 2021. Disponível em: <[www.usgs.gov/core-science-systems/nli/landsat](http://www.usgs.gov/core-science-systems/nli/landsat)>. Acesso em: 27 ago. 2021.

NDEHEDEHE, C. E.; HAILE, G. G.; AGUTU, N. O.; FERREIRA, V. G.; GETIRANA, A.; OKWUASHI, O. Hydrological hotspots of climatic influence in Brazil: A two-step regularization approach. **Atmospheric Research**, v. 246, p. 105116, 2020.

NEVES, L. V. de M. W.; FRACETTO, F. J. C.; FRACETTO, G. G. M.; ARAÚJO FILHO, J. C. De; ARAUJO, J. K. S.; SANTOS, J. C. B. Dos; MENDES JÚNIOR, J. P.; SOUZA JÚNIOR, V. S. De. Microbial abundance and C and N stocks in tropical degraded Planosols from semiarid northeastern Brazil. **Catena**, v. 196, n. August 2020, p. 104931, 2021.

NEWBOLD, T.; HUDSON, L. N.; HILL, S. L. L.; CONTU, S.; LYSENKO, I.; SENIOR, R. A.; BÖRGER, L.; BENNETT, D. J.; CHOIMES, A.; COLLEN, B.; DAY, J.; DE PALMA, A.; DÍAZ, S.; ECHEVERRIA-LONDOÑO, S.; EDGAR, M. J.; FELDMAN, A.; GARON, M.; HARRISON, M. L. K.; ALHUSSEINI, T.; INGRAM, D. J.; ITESCU, Y.; KATTGE, J.; KEMP, V.; KIRKPATRICK, L.; KLEYER, M.; CORREIA, D. L. P.; MARTIN, C. D.; MEIRI, S.; NOVOSOLOV, M.; PAN, Y.; PHILLIPS, H. R. P.; PURVES, D. W.; ROBINSON, A.; SIMPSON, J.; TUCK, S. L.; WEIHER, E.; WHITE, H. J.; EWERS, R. M.; MACE, G. M.; SCHARLEMANN, J. P. W.; PURVIS, A. Global effects of land use on local terrestrial biodiversity. **Nature**, v. 520, n. 7545, p. 45–50, 2015.

NOBRE, P.; MALAGUTTI, M.; URBANO, D. F.; DE ALMEIDA, R. A. F.; GIAROLLA, E. Amazon deforestation and climate change in a coupled model simulation. **Journal of Climate**, v. 22, n. 21, p. 5686–5697, 2009.

NÓBREGA, R. S.; FHELPE, R.; FARIAS, D. E. L.; COSTA, C. A.; GRANDE, C. Variabilidade temporal e espacial da precipitação pluviométrica em pernambuco através de índices de extremos climáticos. **Revista Brasileira de Meteorologia**, v. 30, n. 2, p. 171–180, 2015.

OLIVEIRA-JÚNIOR, J. F. De; DA SILVA JUNIOR, C. A.; TEODORO, P. E.; ROSSI, F. S.; BLANCO, C. J. C.; LIMA, M.; DE GOIS, G.; CORREIA FILHO, W. L. F.; DE BARROS SANTIAGO, D.; DOS SANTOS VANDERLEY, M. H. G. 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, n. 9, p. 4478–4493, 2021.

OLIVEIRA, L. B. De; FONTES, M. P. F.; RIBEIRO, M. R.; KER, J. C. Morphology and classification of Luvisols and Planosols developed on metamorphic rocks in Semiarid northeastern Brazil. **Revista Brasileira de Ciencia do Solo**, v. 33, n. 5, p. 1333–1345, 2009.

OLIVEIRA, P. T.; SANTOS E SILVA, C. M.; LIMA, K. C. Climatology and trend analysis

of extreme precipitation in subregions of Northeast Brazil. **Theoretical and Applied Climatology**, v. 130, n. 1–2, p. 77–90, 2017.

OLIVEIRA, R. S.; BEZERRA, L.; DAVIDSON, E. A.; PINTO, F.; KLINK, C. A.; NEPSTAD, D. C.; MOREIRA, A. Deep root function in soil water dynamics in cerrado savannas of central Brazil. **Functional Ecology**, v. 19, n. 4, p. 574–581, 2005.

PANDEY, P. C.; CHAUHAN, A.; MAURYA, N. K. Evaluation of earth observation datasets for LST trends over India and its implication in global warming. **Ecological Informatics**, v. 72, p. 101843, 2022.

PAREDES-TREJO, F.; BARBOSA, H. A.; GIOVANNETTONE, J.; LAKSHMI KUMAR, T. V.; THAKUR, M. K.; BURITI, C. de O.; UZCÁTEGUI-BRICEÑO, C. Drought assessment in the são francisco river basin using satellite-based and ground-based indices. **Remote Sensing**, v. 13, n. 19, 2021.

PAREDES-TREJO, F. J.; BARBOSA, H. A.; LAKSHMI KUMAR, T. V. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. **Journal of Arid Environments**, v. 139, p. 26–40, 2017.

PAREKH, J. R.; POORTINGA, A.; BHANDARI, B.; MAYER, T.; SAAH, D.; CHISHTIE, F. Automatic Detection of Impervious Surfaces from Remotely Sensed Data Using Deep Learning. **Remote Sensing**, v. 13, n. 8, p. 3166, 2021.

PARENTE, L.; FERREIRA, L. Assessing the spatial and occupation dynamics of the Brazilian pasturelands based on the automated classification of MODIS images from 2000 to 2016. **Remote Sensing**, v. 10, n. 4, 2018.

PARENTE, L.; MESQUITA, V.; MIZIARA, F.; BAUMANN, L.; FERREIRA, L. Assessing the pasturelands and livestock dynamics in Brazil, from 1985 to 2017: A novel approach based on high spatial resolution imagery and Google Earth Engine cloud computing. **Remote Sensing of Environment**, v. 232, n. June, p. 111301, 2019.

PÉREZ-HOYOS, A.; REMBOLD, F.; KERDILES, H.; GALLEGO, J. Comparison of global land cover datasets for cropland monitoring. **Remote Sensing**, v. 9, n. 11, 2017.

PIMENTA, F. M.; SPEROTO, A. T.; COSTA, M. H.; DIONIZIO, E. A. Historical changes in land use and suitability for future agriculture expansion in Western Bahia, Brazil. **Remote Sensing**, v. 13, n. 6, p. 1–31, 2021.

PRESTON, W.; DO NASCIMENTO, C. W. A.; DA SILVA, Y. J. A. B.; SILVA, D. J.; FERREIRA, H. A. Soil fertility changes in vineyards of a semiarid region in Brazil. **Journal of Soil Science and Plant Nutrition**, v. 17, n. 3, p. 672–685, 2017.

QUEIROZ, M. G. De; SILVA, T. G. F. Da; ZOLNIER, S.; JARDIM, A. M. da R. F.; SOUZA, C. A. A. De; ARAÚJO JÚNIOR, G. do N.; MORAIS, J. E. F. De; SOUZA, L. S. B. De. 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, n. January, p. 104457, 2020.

QUESADA-MONTANO, B.; WETTERHALL, F.; WESTERBERG, I. K.; HIDALGO, H. G.;



HALLDIN, S. Characterising droughts in Central America with uncertain hydro-meteorological data. **Theoretical and Applied Climatology**, v. 137, n. 3–4, p. 2125–2138, 2019.

QURESHI, S.; KOOHPAYMA, J.; FIROZJAEI, M. K.; KAKROODI, A. A. Evaluation of Seasonal, Drought, and Wet Condition Effects on Performance of Satellite-Based Precipitation Data over Different Climatic Conditions in Iran. **Remote Sensing**, v. 14, n. 1, p. 76, 2022.

RAHMAN, K. U.; SHANG, S.; ZOHAIB, M. Assessment of merged satellite precipitation datasets in monitoring meteorological drought over pakistan. **Remote Sensing**, v. 13, n. 9, p. 1–37, 2021.

RAZA, A.; HUSSAIN, I.; ALI, Z.; FAISAL, M.; ELASHKAR, E. E.; SHOUKRY, A. M.; AL-DEEK, F. F.; GANI, S. A seasonally blended and regionally integrated drought index using Bayesian network theory. **Meteorological Applications**, v. 28, n. 3, p. 1–24, 2021.

REFATI, D. C.; SILVA, J. L. B. Da; MACEDO, R. S.; LIMA, R. da C. C.; SILVA, M. V. Da; PANDORFI, H.; SILVA, P. C.; OLIVEIRA-JÚNIOR, J. F. De. Influence of drought and anthropogenic pressures on land use and land cover change in the brazilian semiarid region. **Journal of South American Earth Sciences**, v. 126, n. January, 2023.

REINERS, P.; SOBRINO, J.; KUENZER, C. Satellite-Derived Land Surface Temperature Dynamics in the Context of Global Change—A Review. **Remote Sensing**, v. 15, n. 7, p. 1–33, 2023.

RIBEIRO, E. M. S.; ARROYO-RODRÍGUEZ, V.; SANTOS, B. A.; TABARELLI, M.; LEAL, I. R. Chronic anthropogenic disturbance drives the biological impoverishment of the Brazilian Caatinga vegetation. **Journal of Applied Ecology**, v. 52, n. 3, p. 611–620, 2015.

RIBEIRO, K.; SOUSA-NETO, E. R. De; CARVALHO, J. A. De; SOUSA LIMA, J. R. De; MENEZES, R. S. C.; DUARTE-NETO, P. J.; DA SILVA GUERRA, G.; OMETTO, J. P. H. B. Land cover changes and greenhouse gas emissions in two different soil covers in the Brazilian Caatinga. **Science of the Total Environment**, v. 571, p. 1048–1057, 2016.

ROBINSON, N. P.; ALLRED, B. W.; JONES, M. O.; MORENO, A.; KIMBALL, J. S.; NAUGLE, D. E.; ERICKSON, T. A.; RICHARDSON, A. D. A dynamic landsat derived normalized difference vegetation index (NDVI) product for the conterminous United States. **Remote Sensing**, v. 9, n. 8, p. 1–14, 2017.

RODRIGUES, D. T.; GONÇALVES, W. A.; SPYRIDES, M. H. C.; SANTOS E SILVA, C. M.; DE SOUZA, D. O. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. **International Journal of Climatology**, v. 40, n. 12, p. 5098–5113, 2020a.

RODRIGUES, J. A. de M.; LOPES, P. M. O.; DA SILVA, J. L. B.; ARAÚJO, H. L.; DA SILVA, M. V.; DOS SANTOS, A.; BATISTA, P. H. D.; MOURA, G. B. de A. Spatial-temporal dynamics of caatinga vegetation cover by remote sensing in the Brazilian semiarid region. **DYNA (Colombia)**, v. 87, n. 215, p. 109–117, 2020b.

RODRIGUES, R. R.; HAARSMA, R. J.; CAMPOS, E. J. D.; AMBRIZZI, T. The impacts of inter-El Niño variability on the tropical Atlantic and northeast Brazil climate. **Journal of Climate**, v. 24, n. 13, p. 3402–3422, 2011.

RODRIGUES, R. R.; MCPHADEN, M. J. Why did the 2011–2012 La Niña cause a severe drought in the Brazilian Northeast? **Geophysical Prospecting**, v. 41, n. April, p. 1012–1018, 2014.

ROITMAN, I.; BUSTAMANTE, M. M. C.; HAIDAR, R. F.; SHIMBO, J. Z.; ABDALA, G. C.; EITEN, G.; FAGG, C. W.; FELFILI, M. C.; FELFILI, J. M.; JACOBSON, T. K. B.; LINDOSO, G. S.; KELLER, M.; LENZA, E.; MIRANDA, S. C.; PINTO, J. R. R.; RODRIGUES, A. A.; DELITTI, W. B. C.; ROITMAN, P.; SAMPAIO, J. M. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: Re-evaluating allometric equations and environmental influences. **PLoS ONE**, v. 13, n. 8, p. 1–21, 2018.

ROMAN, P. The São Francisco interbasin water transfer in Brazil: Tribulations of a megaproject through constraints and controversy. **Water Alternatives**, v. 10, n. 2, p. 395–419, 2017.

ROSA, M. R.; BRANCALION, P. H. S.; CROUZEILLES, R.; TAMBOSI, L. R.; PIFFER, P. R.; LENTI, F. E. B.; HIROTA, M.; SANTIAMI, E.; METZGER, J. P. Hidden destruction of older forests threatens Brazil’s Atlantic Forest and challenges restoration programs. **Science Advances**, v. 7, n. 4, p. 1–8, 2021.

RUA, M. L.; SIQUEIRA, G.; FERNANDES, T.; SANTOS, A.; AUGUSTO, M.; SANTANA, D. C.; VINICIUS, M.; PANTOJA, S.; BEATRIZ, K.; TEIXEIRA, S. Meteorological Influence on Space-Time Distribution of Tomé-Açu ( Eastern Amazon ) Vegetation Cover Using MODIS Products. **Anuário do Instituto de Geociências**, v. 46, n. 04, p. 1–11, 2023.

SABAREESHWARI, V.; MARY, P. C. N.; MAHENDRAN, P. P.; PANDIAN, P. S.; GURUSAMY, A.; SUBHASHINI, R. Kriging: An advanced Geostatistical Tool to Interpolate the Textural Variation Influences the Yield and Productivity of Tapioca (*Manihot esculenta*) in Namakkal District, Tamil Nadu, India. **International Journal of Plant & Soil Science**, v. 33, n. 2, p. 53–59, 2021.

SAJADI, P.; SANG, Y.; GHOLAMNIA, M.; BONAFONI, S.; BROCCA, L.; PRADHAN, B.; SINGH, A. Performance Evaluation of Long NDVI Timeseries from AVHRR , MODIS and Landsat Sensors over Landslide-Prone Locations in Qinghai-Tibetan Plateau. [s. l.], p. 1–27, 2021.

SALAZAR, A. A.; ARELLANO, E. C.; MUÑOZ-SÁEZ, A.; MIRANDA, M. D.; DA SILVA, F. O.; ZIELONKA, N. B.; CROWTHER, L. P.; SILVA-FERREIRA, V.; OLIVEIRA-REBOUCAS, P.; DICKS, L. V. Restoration and conservation of priority areas of caatinga’s semi-arid forest remnants can support connectivity within an agricultural landscape. **Land**, v. 10, n. 6, 2021.

SAMANIEGO, L.; KUMAR, R.; ZINK, M. Implications of parameter uncertainty on soil moisture drought analysis in Germany. **Journal of Hydrometeorology**, v. 14, n. 1, p. 47–68, 2013.

SANTHOSH, L. G.; SHILPA, D. N. Assessment of LULC change dynamics and its relationship with LST and spectral indices in a rural area of Bengaluru district, Karnataka India. **Remote Sensing Applications: Society and Environment**, v. 29, p. 100886, 2023.

SANTIAGO, D. de B.; CORREIA FILHO, W. L. F.; OLIVEIRA-JÚNIOR, J. F. De; SILVA JUNIOR, C. A. Da. 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.

SANTOS, C. A. G.; NASCIMENTO, T. V. M. Do; SILVA, R. M. Da. Analysis of forest cover changes and trends in the Brazilian semiarid region between 2000 and 2018. **Environmental Earth Sciences**, v. 79, n. 18, 2020.

SANTOS, C. A. G.; SILVA, R. M. Da; SILVA, A. M.; BRASIL NETO, R. M. Estimation of evapotranspiration for different land covers in a Brazilian semi-arid region: A case study of the Brígida River basin, Brazil. **Journal of South American Earth Sciences**, v. 74, p. 54–66, 2017.

SANTOS, A. Dos; LOPES, P. M. O.; SILVA, M. V. Da; JARDIM, A. M. da R. F.; MOURA, G. B. de A.; FERNANDES, G. S. T.; SILVA, D. A. de O.; SILVA, J. L. B. Da; RODRIGUES, J. A. de M.; SILVA, E. A.; OLIVEIRA-JÚNIOR, J. F. De. 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, n. November, p. 100084, 2020.

SANTOS, H. G. Dos; JÚNIOR, W. de C.; DART, R. de O.; ÁGLIO, M. L. D.; SOUSA, J. S. De; PARES, J. G.; FONTANA, A.; MARTINS, A. L. da S.; OLIVEIRA, A. P. De. **O Novo Mapa de Solos do Brasil Legenda Atualizada**. Embrapa ed. Rio de Janeiro, 2011.

SANTOS, V. J. Dos; CALIJURI, M. L.; RIBEIRO JÚNIOR, J. I.; DE ASSIS, L. C. Rainfall estimation methods in the Brazilian semiarid region: 30-year evaluation on a monthly scale. **International Journal of Climatology**, v. 41, n. S1, p. E752–E767, 2021.

SANTOS, H. de A. e; POMPEU, P. dos S.; KENJI, D. O. L. Changes in the flood regime of São Francisco River (Brazil) from 1940 to 2006. **Regional Environmental Change**, v. 12, n. 1, p. 123–132, 2012.

SANTOS, H. G.; JACOMINE, P. K. T.; DOS ANJOS, L. H. C.; DE OLIVEIRA, V. A.; LUMBRERAS, J. F.; COELHO, M. R.; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos**, 2018.

SANTOS, R. M.; OLIVEIRA-FILHO, A. T.; EISENLOHR, P. V.; QUEIROZ, L. P.; CARDOSO, D. B. O. S.; RODAL, M. J. N. Identity and relationships of the Arboreal Caatinga among other floristic units of seasonally dry tropical forests (SDTFs) of north-eastern and Central Brazil. **Ecology and Evolution**, v. 2, n. 2, p. 409–428, 2012.

SARAIVA, M.; PROTAS, É.; SALGADO, M.; SOUZA, C. Automatic mapping of center pivot irrigation systems from satellite images using deep learning. **Remote Sensing**, v. 12, n. 3, p. 1–14, 2020.

SCHOELLHAMER, D. H.; WRIGHT, S. A.; DREXLER, J. Z. Adjustment of the San Francisco estuary and watershed to decreasing sediment supply in the 20th century. **Marine Geology**, v. 345, n. November 2013, p. 63–71, 2013.

SCHUBERT, S. D.; STEWART, R. E.; WANG, H.; BARLOW, M.; BERBERY, E. H.; CAI, W.; HOERLING, M. P.; KANIKICHARLA, K. K.; KOSTER, R. D.; LYON, B.; MARIOTTI, A.; MECHOSO, C. R.; MÜLLER, O. V.; RODRIGUEZ-FONSECA, B.; SEAGER, R.; SENEVIRANTE, S. I.; ZHANG, L.; ZHOU, T. Global meteorological drought: A synthesis of current understanding with a focus on sst drivers of precipitation deficits. **Journal of Climate**, v. 29, n. 11, p. 3989–4019, 2016.

SEN, P. K. Estimates of the Regression Coefficient Based on Kendall ' s Tau. **Journal of the American Statistical Association**, v. 63, n. 324, p. 1379–1389, 1968.

SHAMSHIRBAND, S.; HASHEMI, S.; SALIMI, H.; SAMADIANFARD, S.; ASADI, E.; SHADKANI, S.; KARGAR, K.; MOSAVI, A.; NABIPOUR, N.; CHAU, K. W. Predicting Standardized Streamflow index for hydrological drought using machine learning models. **Engineering Applications of Computational Fluid Mechanics**, v. 14, n. 1, p. 339–350, 2020.

SIEBERT, S.; WEBBER, H.; REZAEI, E. E. Weather impacts on crop yields - Searching for simple answers to a complex problem. **Environmental Research Letters**, v. 12, n. 8, 2017.

SILVA, C. V. S.; SILVA, J. L. B. Da; MOURA, G. B. D. A.; LOPES, P. M. O.; NASCIMENTO, C. R.; SILVA, L. C. Da. Monitoramento Da Cobertura Vegetal Por Sensoriamento Remoto No Semiárido Brasileiro Através De Índices De Vegetação. **Nativa**, v. 7, n. 6, p. 708, 2019.

SILVA, E. R. M. Da; BARBOSA, I. C. da C.; SILVA, H. J. F.; COSTA, L. G. da S.; ROCHA, E. J. P. Da. Evaluating the Performance of Precipitation Estimate from CHIRPS Product for the Apeú River Basin, Castanhal-PA Revista. **Revista Brasileira de Geografia**, v. 03, p. 1094–1105, 2020a.

SILVA, J. L. B. Da; MOURA, G. B. de A.; SILVA, M. V. Da; OLIVEIRA-JÚNIOR, J. F. De; JARDIM, A. M. da R. F.; REFATI, D. C.; LIMA, R. da C. C.; CARVALHO, A. A. De; FERREIRA, M. B.; BRITO, J. I. B. De; GUEDES, R. V. de S.; LOPES, P. M. O.; NÓBREGA, R. S.; PANDORFI, H.; BEZERRA, A. C.; BATISTA, P. H. D.; JESUS, F. L. F. De; SANCHES, A. C.; SANTOS, R. C. 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, n. December 2022, 2023.

SILVA, J. M. C. Da; LEAL, I. R.; TABARELLI, M. **Caatinga: The Largest Tropical Dry Forest Region in South America**. Cham, Switzerland: Springer International Publishing AG, 2017.

SILVA, M. V. Da; PANDORFI, H.; ALMEIDA, G. L. P. De; LIMA, R. P. De; SANTOS, A. Dos; JARDIM, A. M. da R. F.; ROLIM, M. M.; SILVA, J. L. B. Da; BATISTA, P. H. D.; SILVA, R. A. B. Da; LOPES, P. M. O.; SILVA, D. C. Da. Spatio-temporal monitoring of soil

and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semi-arid region. **Journal of South American Earth Sciences**, v. 107, n. October 2020, p. 103155, 2021a.

SILVA, M. V. Da; PANDORFI, H.; ALMEIDA, G. L. P. De; LIMA, R. P. De; SANTOS, A. Dos; JARDIM, A. M. da R. F.; ROLIM, M. M.; SILVA, J. L. B. Da; BATISTA, P. H. D.; SILVA, R. A. B. Da; LOPES, P. M. O.; SILVA, D. C. Da. Spatio-temporal monitoring of soil and plant indicators under forage cactus cultivation by geoprocessing in Brazilian semi-arid region. **Journal of South American Earth Sciences**, v. 107, n. January, 2021b.

SILVA, M. V. Da; PANDORFI, H.; LOPES, P. M. O.; SILVA, J. L. B. Da; DE ALMEIDA, SILVA, M. V. Da; PANDORFI, H.; LOPES, P. M. O.; SILVA, J. L. B. Da; DE ALMEIDA, G. L. P.; SILVA, D. A. de O.; SANTOS, A. Dos; RODRIGUES, J. A. de M.; BATISTA, P. H. D.; JARDIM, A. M. da R. F. 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.

SILVA, M. V. Da; PANDORFI, H.; OLIVEIRA-JÚNIOR, J. F. De; SILVA, J. L. B. Da; ALMEIDA, G. L. P. De; MONTENEGRO, A. A. de A.; MESQUITA, M.; FERREIRA, M. B.; SANTANA, T. C.; MARINHO, G. T. B.; COSTA, A. R. Da; GIONGO, P. R. 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, n. August, 2022.

SILVA, É. E. de M. e.; PAIXÃO, V. H. F.; TORQUATO, J. L.; LUNARDI, D. G.; LUNARDI, V. de O. Fruiting phenology and consumption of zoochoric fruits by wild vertebrates in a seasonally dry tropical forest in the Brazilian Caatinga. **Acta Oecologica**, v. 105, n. February, p. 103553, 2020c.

SILVA FILHO, R. Da; VASCONCELOS, R. S.; GALVÃO, C. de O.; RUFINO, I. A. A.; CUNHA, J. E. de B. L. Mathematical modelling of the intra-annual behaviour of NDVI in the Caatinga Biome, Brazil. **Ciencia Florestal**, v. 30, n. 2, p. 473–488, 2020.

SILVA, R. M.; SANTOS DA, C. A. G.; MOREIRA, M.; CORTE-REAL, J.; SILVA, V. C. L.; MEDEIROS, I. C. Rainfall and river flow trends using Mann–Kendall and Sen’s slope estimator statistical tests in the Cobres River basin. **Natural Hazards**, v. 77, n. 2, p. 1205–1221, 2015.

SILVÉRIO, D. V.; BRANDO, P. M.; MACEDO, M. N.; BECK, P. S. A.; BUSTAMANTE, M.; COE, M. T. Agricultural expansion dominates climate changes in southeastern Amazonia: The overlooked non-GHG forcing. **Environmental Research Letters**, v. 10, n. 10, 2015.

SOARES, E. C.; SILVA, J. V.; NAVAS, R. **O Baixo São Francisco: Características Ambientais e Sociais**. Edufal ed. Maceió, 2021.

SOBRINO, J. A.; RAISSOUNI, N.; LI, Z. L. A comparative study of land surface emissivity retrieval from NOAA data. **Remote Sensing of Environment**, v. 75, n. 2, p. 256–266, 2001.

SONG, X. P.; HANSEN, M. C.; STEHMAN, S. V.; POTAPOV, P. V.; TYUKAVINA, A.;

VERMOTE, E. F.; TOWNSHEND, J. R. Global land change from 1982 to 2016. **Nature**, v. 560, n. 7720, p. 639–643, 2018.

SOUSA, J. E. S. De; DOS SANTOS, J. C. B.; CORRÊA, M. M.; DO NASCIMENTO, A. F.; SCHULZE, S. M. B. B.; FERREIRA, T. O.; DE ARAÚJO FILHO, J. C.; DE SOUZA JÚNIOR, V. S. Mineralogy and genesis of Planosols under a semi-arid climate, Borborema Plateau, NE Brazil. **CATENA**, v. 184, p. 104260, 2020.

SOUSA JÚNIOR, V. de P.; SPARACINO, J.; DE ESPINDOLA, G. M.; SOUSA DE ASSIS, R. J. Land-Use and Land-Cover Dynamics in the Brazilian Caatinga Dry Tropical Forest. **Conservation**, v. 2, n. 4, p. 739–752, 2022.

SOUSA, M. G.; ARAUJO, J. K. S.; FERREIRA, T. O.; ANDRADE, G. R. P.; ARAÚJO FILHO, J. C.; FRACETTO, G. G. M.; SANTOS, J. C. B.; FRACETTO, F. J. C.; LIMA, G. K.; SOUZA JUNIOR, V. Long-term effects of irrigated agriculture on Luvisol pedogenesis in semi-arid region, northeastern Brazil. **Catena**, v. 206, n. February, 2021.

SOUZA, A. G. S. S.; RIBEIRO NETO, A.; SOUZA, L. L. De. Soil moisture-based index for agricultural drought assessment: SMADI application in Pernambuco State-Brazil. **Remote Sensing of Environment**, v. 252, 2021.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-FILHO, P. W. M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A. V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, E. J.; LENTI, F. E. B.; PATERNOST, F. F.; PAREYN, F. G. C.; SIQUEIRA, J. V.; VIERA, J. L.; NETO, L. C. F.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M. P. G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, v. 12, n. 17, 2020.

SUN, L.; LI, H.; WANG, J.; CHEN, Y.; XIONG, N.; WANG, Z.; WANG, J.; XU, J. Impacts of Climate Change and Human Activities on NDVI in the Qinghai-Tibet Plateau. **Remote Sensing**, v. 15, n. 3, p. 587, 2023.

SUN, T.; FERREIRA, V. G.; HE, X.; ANDAM-AKORFUL, S. A. Water availability of são francisco river basin based on a space-borne geodetic sensor. **Water**, v. 8, n. 5, p. 213, 2016. TAIWO, B. E.; KAFY, A. Al; SAMUEL, A. A.; RAHAMAN, Z. A.; AYOWOLE, O. E.; SHAHRIER, M.; DUTI, B. M.; RAHMAN, M. T.; PETER, O. T.; ABOSEDE, O. O. Monitoring and predicting the influences of land use/land cover change on cropland characteristics and drought severity using remote sensing techniques. **Environmental and Sustainability Indicators**, v. 18, n. August 2022, p. 100248, 2023.

TALLOOR, A. K.; MANHAS, D. S.; KOTHYARI, G. C. Retrieval of land surface temperature, normalized difference moisture index, normalized difference water index of the Ravi basin using Landsat data. **Applied Computing and Geosciences**, v. 9, n. December 2020, p. 100051, 2021.

TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L.; ADELI, S.; BRISCO, B. Google Earth Engine for geo-big data applications: A meta-analysis and

systematic review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 164, n. March, p. 152–170, 2020.

TAVARES, F. M.; SCHULZ, K.; PEREIRA, R. de C. A.; CIERJACKS, A.; ALMEIDA-CORTEZ, J. S. De. Floristic survey of the caatinga in areas with different grazing intensities, Pernambuco, Northeast Brazil. **Journal of Environmental Analysis and Progress**, v. 1, n. 1, p. 43–51, 2016.

TEDESCHI, R. G.; CAVALCANTI, I. F. A.; GRIMM, A. M. Influences of two types of ENSO on South American precipitation. **International Journal of Climatology**, v. 33, n. 6, p. 1382–1400, 2013.

TEIXEIRA, A. H. C.; LEIVAS, J. F.; HERNANDEZ, F. B. T.; FRANCO, R. A. M. Large-scale radiation and energy balances with Landsat 8 images and agrometeorological data in the Brazilian semiarid region. **Journal of Applied Remote Sensing**, v. 11, n. 1, p. 016030, 2017.

TEIXEIRA, A. H. d. C.; BASTIAANSEN, W. G. M.; AHMAD, M. D.; BOS, M. G. Reviewing SEBAL input parameters for assessing evapotranspiration and water productivity for the Low-Middle São Francisco River basin, Brazil. Part A: Calibration and validation. **Agricultural and Forest Meteorology**, v. 149, n. 3–4, p. 462–476, 2009.

TEIXEIRA, A. H. d. C.; TAKEMURA, C. M.; LEIVAS, J. F.; PACHECO, E. P.; BAYMA-SILVA, G.; GARÇON, E. A. M. Water productivity monitoring by using geotechnological tools in contrasting social and environmental conditions: Applications in the São Francisco River basin, Brazil. **Remote Sensing Applications: Society and Environment**, v. 18, p. 100296, 2020.

TEIXEIRA, A. H. de C.; LEIVAS, J. F.; ANDRADE, R. G.; HERNANDEZ, F. B. T.; MOMESSO, F. R. A. Modelling radiation and energy balances with Landsat 8 images under different thermohydrological conditions in the Brazilian semi-arid region. **Remote Sensing for Agriculture, Ecosystems, and Hydrology XVII**, v. 9637, p. 96370U, 2015.

TEIXEIRA, A. H. de C.; LEIVAS, J. F.; PACHECO, E. P.; GARÇON, E. A. M.; TAKEMURA, C. M. Biophysical Characterization and Monitoring Large-Scale Water and Vegetation Anomalies by Remote Sensing in the Agricultural Growing Areas of the Brazilian Semi-Arid Region. **Advances in Remote Sensing for Natural Resource Monitoring**, p. 94–109, 2021a.

TEIXEIRA, L. P.; LUGHADHA, E. N.; DA SILVA, M. V. C.; MORO, M. F. How much of the Caatinga is legally protected? An analysis of temporal and geographical coverage of protected areas in the Brazilian semiarid region. **Acta Botanica Brasilica**, v. 35, n. 3, p. 473–485, 2021b.

TOMASELLA, J.; SILVA PINTO VIEIRA, R. M.; BARBOSA, A. A.; RODRIGUEZ, D. A.; DE OLIVEIRA SANTANA, M.; SESTINI, M. F. Desertification trends in the Northeast of Brazil over the period 2000–2016. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, n. June, p. 197–206, 2018.

TOTÉ, C.; PATRICIO, D.; BOOGAARD, H.; VAN DER WIJNGAART, R.; TARNAVSKY, E.; FUNK, C. Evaluation of satellite rainfall estimates for drought and flood monitoring in

Mozambique. **Remote Sensing**, v. 7, n. 2, p. 1758–1776, 2015.

TRAGANOS, D.; AGGARWAL, B.; POURSANIDIS, D.; TOPOUZELIS, K.; CHRYSOULAKIS, N.; REINARTZ, P. Towards global-scale seagrass mapping and monitoring using Sentinel-2 on Google Earth Engine: The case study of the Aegean and Ionian Seas. **Remote Sensing**, v. 10, n. 8, p. 1–14, 2018.

TRAINI, C.; SCHROTTKE, K.; STATTEGGER, K.; DOMINGUEZ, J. L.; GUIMARÃES, J. K.; VITAL, H.; BESERRA, D.; DA SILVA, A. A. Morphology of subaqueous dunes at the mouth of the Dammed River São Francisco (Brazil). **Journal of Coastal Research**, v. 28, n. 6, p. 1580–1590, 2012.

TREJO, F. P.; BRITO-CASTILLO, L.; ALVES, H. B.; GUEVARA, E. Main features of large-scale oceanic-atmospheric circulation related to strongest droughts during rainy season in Brazilian São Francisco River Basin. **International Journal of Climatology**, v. 36, n. 12, p. 4102–4117, 2016.

ULLAH, W.; AHMAD, K.; ULLAH, S.; TAHIR, A. A.; JAVED, M. F.; NAZIR, A.; ABBASI, A. M.; AZIZ, M.; MOHAMED, A. Analysis of the relationship among land surface temperature (LST), land use land cover (LULC), and normalized difference vegetation index (NDVI) with topographic elements in the lower Himalayan region. **Heliyon**, v. 9, n. 2, p. e13322, 2023.

>

URIBE, M. D. R.; DUKES, J. S. Land cover change alters seasonal photosynthetic activity and transpiration of Amazon forest and Cerrado. **Environmental Research Letters**, v. 16, n. 5, 2021.

URRUTIA, A. L.; GONZÁLEZ-GÓNZALEZ, C.; VAN CAUWELAERT, E. M.; ROSELL, J. A.; GARCÍA BARRIOS, L.; BENÍTEZ, M. Landscape heterogeneity of peasant-managed agricultural matrices. **Agriculture, Ecosystems and Environment**, v. 292, n. May 2019, p. 106797, 2020.

UTIDA, G.; CRUZ, F. W.; ETOURNEAU, J.; BOULOUBASSI, I.; SCHEFUSS, E.; VUILLE, M.; NOVELLO, V. F.; PRADO, L. F.; SIFEDDINE, A.; KLEIN, V.; ZULAR, A.; VIANA, J. C. C.; TURCQ, B. Tropical South Atlantic influence on Northeastern Brazil precipitation and ITCZ displacement during the past 2300 years. **Scientific Reports**, v. 9, n. 1, p. 1–8, 2019.

VAN LOON, A. F.; LAAHA, G. Hydrological drought severity explained by climate and catchment characteristics. **Journal of Hydrology**, v. 526, p. 3–14, 2015.

VASCO, A. N.; NETTO, A. O. A.; SILVA, M. G. The influence of dams on ecohydrological conditions in the São Francisco River Basin, Brazil. **Ecohydrology and Hydrobiology**, n. 2018, 2019.

VASCO, A. N. Do; NETTO, A. de O. A.; PRUSKI, F. F. Impactos das barragens na disponibilidade hídrica do Nordeste do Brasil. **Revista Recursos Hídricos**, v. 38, n. 2, p. 39–49, 2017.

VERHOEVE, S. L.; KEIJZER, T.; KAITILA, R.; WICKAMA, J.; STERK, G. Vegetation



resilience under increasing drought conditions in northern Tanzania. **Remote Sensing**, v. 13, n. 22, p. 1–20, 2021.

VERMOTE, E. F.; ROGER, J. C.; RAY, J. P. **MOD09A1 MODIS Surface Reflectance 8-Day L3 Global 500m SIN Grid V006. NASA EOSDIS Land Processes DAAC (For Collection 6)**. Washington, DC, USA, 2015.

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I. A multiscale drought index sensitive to global warming: The standardized precipitation evapotranspiration index. **Journal of Climate**, v. 23, n. 7, p. 1696–1718, 2010.

VICENTE-SERRANO, S. M.; LÓPEZ-MORENO, J. I.; BEGUERÍA, S.; LORENZO-LACRUZ, J.; AZORIN-MOLINA, C.; MORÁN-TEJEDA, E. Accurate Computation of a Streamflow Drought Index. **Journal of Hydrologic Engineering**, v. 17, n. 2, p. 318–332, 2012.

VIEIRA, R. M. S. P.; TOMASELLA, J.; ALVALÁ, R. C. S.; SESTINI, M. F.; AFFONSO, A. G.; RODRIGUEZ, D. A.; BARBOSA, A. A.; CUNHA, A. P. M. A.; VALLES, G. F.; CREPANI, E.; DE OLIVEIRA, S. B. P.; DE SOUZA, M. S. B.; CALIL, P. M.; DE CARVALHO, M. A.; VALERIANO, D. M.; CAMPELLO, F. C. B.; SANTANA, M. O. Identifying areas susceptible to desertification in the Brazilian northeast. **Solid Earth**, v. 6, n. 1, p. 347–360, 2015.

WAN, Z. New refinements and validation of the MODIS Land-Surface Temperature/Emissivity products. **Remote Sensing of Environment**, v. 112, n. 1, p. 59–74, 2008.

WANG, J.; PETERSEN, W. A.; WOLFF, D. B. Validation of satellite-based precipitation products from TRMM to GPM. **Remote Sensing**, v. 13, n. 9, 2021.

WANG, X.; XIAO, X.; ZOU, Z.; CHEN, B.; MA, J.; DONG, J.; DOUGHTY, R. B.; ZHONG, Q.; QIN, Y.; DAI, S.; LI, X.; ZHAO, B.; LI, B. Tracking annual changes of coastal tidal flats in China during 1986–2016 through analyses of Landsat images with Google Earth Engine. **Remote Sensing of Environment**, v. 238, n. November, 2020.

WARRICK, A. W.; NIELSEN, D. R. **Spatial Variability of Soil Physical Properties in the Field**. [s.l.] : ACADEMIC PRESS, INC., 1980.

WIEGAND, M. C.; DO NASCIMENTO, A. T. P.; COSTA, A. C.; LIMA NETO, I. E. Trophic state changes of semi-arid reservoirs as a function of the hydro-climatic variability. **Journal of Arid Environments**, v. 184, n. September 2020, 2021.

WIJESINGHA, J.; MOECKEL, T.; HENSGEN, F.; WACHENDORF, M. Evaluation of 3D point cloud-based models for the prediction of grassland biomass. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, n. May, p. 352–359, 2019.

WILSON, E. H.; SADER, S. A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, v. 80, n. 3, p. 385–396, 2002.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R.; E, E. . Daily gridded meteorological

variables in Brazil (1980–2013). **International Journal of Climatology**, v. 36, n. 6, p. 2644–2659, 2016.

XAVIER JR, S. F. A.; DA SILVA JALE, J.; STOSIC, T.; DOS SANTOS, C. A. C.; SINGH, V. P. An application of sample entropy to precipitation in Paraíba State, Brazil. **Theoretical and Applied Climatology**, v. 136, n. 1–2, p. 429–440, 2019.

XIANG, Y.; CHEN, J.; LI, L.; PENG, T.; YIN, Z. Evaluation of Eight Global Precipitation Datasets in Hydrological Modeling. **Remote Sensing**, v. 13, n. 14, p. 2831, 2021.

XIAO, J.; XIE, B.; ZHOU, K.; LI, J.; XIE, J.; LIANG, C. Contributions of Climate Change, Vegetation Growth, and Elevated Atmospheric CO<sub>2</sub> Concentration to Variation in Water Use Efficiency in Subtropical China. **Remote Sensing**, v. 14, n. 17, 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, n. 14, p. 3025–3033, 2006.

XU, W.; ZOU, Y.; ZHANG, G.; LINDERMAN, M. A comparison among spatial interpolation techniques for daily rainfall data in Sichuan Province, China. **International Journal of Climatology**, v. 35, n. 10, p. 2898–2907, 2015.

XULU, S.; MBATHA, N.; PEERBHAY, K. Burned Area Mapping over the Southern Cape Forestry Region, South Africa Using Sentinel Data within GEE Cloud Platform. **ISPRS International Journal of Geo-Information**, v. 10, n. 8, p. 511, 2021.

YANG, X.; QIN, Q.; GRUSSENMEYER, P.; KOEHL, M. Urban surface water body detection with suppressed built-up noise based on water indices from Sentinel-2 MSI imagery. **Remote Sensing of Environment**, v. 219, n. September 2017, p. 259–270, 2018.

ZHANG, G.; XU, X.; ZHOU, C.; ZHANG, H.; OUYANG, H. Responses of grassland vegetation to climatic variations on different temporal scales in Hulun Buir Grassland in the past 30 years. **Journal of Geographical Sciences**, v. 21, n. 4, p. 634–650, 2011.

ZHANG, Y.; QIAN, B.; HONG, G. A long-term, 1-km resolution daily meteorological dataset for modeling and mapping permafrost in Canada. **Atmosphere**, v. 11, n. 12, 2020.