



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
DEPARTAMENTO DE ENGENHARIA CIVIL  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

BRUNO E SILVA URSULINO

**ANÁLISE RETROSPECTIVA DE SECAS UTILIZANDO SENSORIAMENTO  
REMOTO E MODELAGEM NA BACIA DO RIO CAPIBARIBE**

Recife

2024

BRUNO E SILVA URSULINO

**ANÁLISE RETROSPECTIVA DE SECAS UTILIZANDO SENSORIAMENTO  
REMOTO E MODELAGEM NA BACIA DO RIO CAPIBARIBE**

Tese apresentada ao Programa de Pós-graduação em Engenharia Civil do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Doutor em Engenharia Civil. Área de concentração: Tecnologia Ambiental e Recursos Hídricos.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Suzana Maria Gico Lima Montenegro.

Recife

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Ursulino, Bruno e Silva.

Análise retrospectiva de secas utilizando sensoriamento remoto e modelagem na bacia do Rio Capibaribe / Bruno e Silva Ursulino. - Recife, 2024.

148f.: il.

Tese (Doutorado) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Civil, 2024.

Orientação: Suzana Maria Gico Lima Montenegro.

Inclui referências.

1. índices de seca; 2. SWAT; 3. Propagação da seca; 4. ENSO; 5. Teleconexão. I. Montenegro, Suzana Maria Gico Lima. II. Título.

UFPE-Biblioteca Central

BRUNO E SILVA URSULINO

**ANÁLISE RETROSPECTIVA DE SECAS UTILIZANDO SENSORIAMENTO  
REMOTO E MODELAGEM NA BACIA DO RIO CAPIBARIBE**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para obtenção do título de Doutor em Engenharia Civil, Área de Tecnologia Ambiental e Recursos Hídricos.

Aprovada em 19/11/2024

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Suzana Maria Gico Lima Montenegro – UFPE

**BANCA EXAMINADORA**

participação por videoconferência  
Prof. Dr. Alfredo Ribeiro Neto (examinador interno)  
Universidade Federal de Pernambuco

participação por videoconferência  
Prof.<sup>a</sup> Dr.<sup>a</sup> Carolyne Wanessa Lins de Andrade Lima (examinadora externa)  
Universidade Federal da Paraíba

participação por videoconferência  
Prof. Dr. Richarde Marques da Silva (examinador externo)  
Universidade Federal da Paraíba

participação por videoconferência  
Prof. Dr. Victor Hugo Rabelo Coelho (examinador externo)  
Universidade Federal da Paraíba

participação por videoconferência  
Prof.<sup>a</sup> Dr.<sup>a</sup> Josiclêda Domiciano Galvício (examinadora externa)  
Universidade Federal de Pernambuco

## **AGRADECIMENTOS**

À professora Suzana Maria Gico Lima Montenegro, pelos ensinamentos, oportunidades, incentivo e confiança ao longo de toda a minha pós-graduação, que foram essenciais para a conclusão desta pesquisa.

Aos professores Alfredo Ribeiro Neto, Carolyne Andrade, Richarde Marques, Victor Hugo e Josiclêda Galvêncio por aceitarem o convite para avaliação desta tese.

À Universidade Federal de Pernambuco (UFPE), especialmente aos professores do Grupo de Pesquisa em Recursos Hídricos: Anderson Paiva, Jaime Cabral, Leidjane Oliveira, Sylvana Santos e José Roberto Azevedo.

Ao grupo do SUPer/SWAT, pelas valiosas discussões e compartilhamento de informações sobre as etapas da modelagem hidrológica, e por disponibilizar o projeto da bacia do rio Capibaribe, fundamentais para a realização desta pesquisa.

Aos colegas e amigos da pós, em especial ao grupo de pesquisa das salas 14 e 19, por todo o tempo convivido e pela cooperação ao longo desses anos.

Às secretarias do Programa de Pós-Graduação em Engenharia Civil (PPGEC), em especial a Andrea Negromonte, Claudiana e Juliana pela gentiliza e prontidão em sempre nos ajudar.

Ao Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) pela oportunidade da capacitação docente e aos colegas do campus Aracati pelo apoio e incentivo nos últimos anos.

À Fundação de Amparo à Ciência e Tecnologia de Pernambuco (FACEPE) pela concessão da bolsa durante os dois primeiros anos do doutorado (IBPG-0078-3.01/18).

À Agência Pernambucana de Águas e Clima (APAC) e Agência Nacional de Águas (ANA) por disponibilizar os dados pluviométricos, fluviométricos e dos reservatórios. Ao Centro Nacional de Monitoramento e Alertas de Desastres Naturais (Cemaden) por disponibilizar os dados de umidade do solo. À NASA (National Aeronautics and Space Administration) e ao USGS (United States Geological Survey) por disponibilizar as imagens de satélites, e ao NOAA (National Oceanic and Atmospheric Administration) por disponibilizar os dados de teleconexão.

E a todos aqueles que contribuíram direta ou indiretamente para a concretização deste trabalho.

## RESUMO

Informações sobre a disponibilidade do conteúdo de água no solo são indispensáveis para fornecer alertas de intensidade das secas, início da estação chuvosa, datas de plantio e sinais antecipados de perdas de produção. As redes de monitoramento convencionais apresentam restrições quanto à cobertura espaço-temporal das variáveis agrometeorológicas, limitando o monitoramento efetivo da seca. Alternativamente, dados de sensoriamento remoto e modelagem têm sido utilizados para caracterização e previsibilidade dos diferentes tipos de secas. Dessa forma, este estudo objetiva investigar as relações entre secas meteorológicas, agrícolas e da vegetação e os possíveis impactos da teleconexão atmosférica em uma bacia de transição entre a Caatinga e a Mata Atlântica. Dados do produto *Climate Hazard Group InfraRed Precipitation Satellite* (CHIRPS) foram utilizados para a obtenção da precipitação e cálculo do *Standardized Precipitation Index* (SPI), adotado para caracterização da seca meteorológica. O índice *Normalized Difference Vegetation Index* (NDVI), proveniente do produto MOD13Q1, foi utilizado para quantificar a seca da vegetação (aNDVI). A umidade do solo, modelada no *Soil and Water Assessment Tool* (SWAT), foi utilizada para caracterização da seca agrícola, através do *Standardized Soil Moisture Index* (SSMI). Para compreender detalhadamente as relações entre as secas, os índices foram correlacionados tanto no nível de sub-bacia quanto em unidades de análise maiores. Uma abordagem utilizando análise wavelet foi aplicada para explorar a relação tempo-frequência entre a variabilidade das secas e os eventos El Niño–Oscilação Sul (ENSO). Os resultados mostraram que as secas meteorológicas de curto prazo (SPI-3) ocorreram com maior frequência no Agreste e, com o aumento da escala de tempo (SPI-6 e SPI-12), os eventos se tornaram mais severos e duradouros nessa região. A variabilidade da vegetação demonstrou estar diretamente relacionada à precipitação, com maior vigor vegetativo em anos chuvosos e limitações de crescimento em períodos secos, além de apresentar uma tendência decrescente do NDVI. O tempo de resposta da vegetação à precipitação ocorreu geralmente em um mês, com coeficientes de correlação maiores que 0,56, enquanto a seca na vegetação demonstrou maior sensibilidade ao efeito cumulativo da seca meteorológica de três e seis meses. O modelo SWAT foi eficaz na simulação da variabilidade mensal da umidade do solo, apesar de limitações na captura das vazões de pico e em áreas com regimes fluviais intermitentes. A relação entre as diferentes

secas apresentou uma forte interação sazonal: secas meteorológicas se propagaram rapidamente para secas agrícolas, especialmente no outono e nas camadas superficiais, enquanto a transição para a seca da vegetação foi mais lenta, com maior duração no Agreste durante a primavera e no litoral no outono. Quanto à relação tempo-frequência, foi observada uma influência periódica do SPI precedendo o SSMI em escalas de 8 e 64 meses, enquanto os ciclos significativos entre SSMI e aNDVI variaram conjuntamente na maior parte dos anos, em períodos de 1 a 64 meses. Os eventos ENSO demonstraram modular fortemente as secas meteorológicas da bacia, ao mesmo tempo que a sua influência na seca agrícola foi mais fragmentada, principalmente no extremo oeste e na área de transição para a Zona da Mata.

**Palavras-chave:** índices de seca; SWAT; propagação da seca; ENSO; teleconexão.

## ABSTRACT

Information on soil moisture availability is essential to provide drought intensity alerts, rainy season onset, planting dates, and early warnings of crop loss. Conventional monitoring networks present restrictions on the spatiotemporal coverage of agrometeorological variables, constraining effective drought monitoring. Alternatively, remote sensing data and modeling have been used in hydrological studies that seek to quickly understand the characteristics and predictability of different drought types. Thus, this study aimed to investigate the relationships between the meteorological, agricultural and vegetation droughts, and the possible impacts of atmospheric teleconnections in a transition basin between the Caatinga and the Atlantic Forest. Data from the *Climate Hazard Group InfraRed Precipitation Satellite* (CHIRPS) product were used to obtain the historical precipitation series of occurrences and calculate the Standardized Precipitation Index (SPI) to characterize meteorological drought. The *Normalized Difference Vegetation Index* (NDVI) from the MOD13Q1 product was used to quantify the vegetation drought (aNDVI). Soil moisture, modeled at different depths using the *Soil and Water Assessment Tool* (SWAT), was employed to characterize agricultural drought through the *Standardized Soil Moisture Index* (SSMI). To thoroughly understand the relationships between droughts, the indices were correlated considering different lags and time scales, both at the sub-basin level and in larger analysis units. A wavelet analysis approach was applied to explore the time-frequency relationship between drought variability and *El Niño–Southern Oscillation* (ENSO) events. The results showed that short-term droughts (SPI-3) occurred more frequently in Agreste, and as the time scale increased (SPI-6 and SPI-12), the events were more severe and prolonged in this region. Vegetation variability was directly related to precipitation, with greater vegetative vigor in rainy years and growth limitations in dry periods, in addition to presenting a decreasing trend of NDVI in most of the basin. Vegetation's response time to precipitation typically occurred within one month, with correlation coefficients above 0.56, while vegetation drought was more sensitive to the cumulative effect of meteorological drought over three and six months, on the coast and in the Agreste, respectively. The SWAT model was effective in simulating the monthly variability of soil moisture, despite limitations in capturing peak flows and in areas with intermittent river regimes. The relationship between the different droughts showed a strong seasonal interaction: meteorological droughts propagated quickly to

agricultural droughts, particularly in autumn and in the superficial soil layers, while the transition to vegetation drought was slower, lasting longer in the Agreste during spring and along the coast in autumn. Regarding the time-frequency relationship, a periodic influence was observed, with SPI preceding SSMI on scales of 8 to 64 months, while significant cycles between SSMI and aNDVI varied jointly over most years, from 1 to 64 months, with greater coherence in deeper soil layers. ENSO events strongly modulated meteorological droughts in the basin, while their influence on agricultural drought was more fragmented, particularly in the far west and the transition area to the Atlantic Forest.

**Keywords:** drought indices; SWAT; drought propagation; ENSO; teleconnection.

## LISTA DE FIGURAS

Figura 1 - Tipos de seca.....	29
Figura 2 - Fluxograma das etapas que serão utilizadas nesta pesquisa.....	34
Figura 3 - Localização da bacia do rio Capibaribe. ....	35
Figura 4 - Classes do uso e ocupação do solo da bacia do Capibaribe referente aos anos de 1985, 2005 e 2020.....	41
Figura 5 - Transições das principais classes do uso e ocupação do solo da bacia do Capibaribe referente aos anos de 1985, 2005 e 2020. ....	41
Figura 6 - Diferentes valores de Surlag em função da retenção do escoamento superficial e o tempo de concentração (h). ....	45
Figura 7 - Localização dos postos pluviométricos e meteorológico.....	57
Figura 8 - Localização dos reservatórios e postos fluviométricos. ....	57
Figura 9 - Localização das estações de umidade do solo e das sub-bacias do rio Capibaribe. ....	62
Figura 10 - Representação das características de eventos de seca. ....	69
Figura 11 - Unidades de análise da bacia do rio Capibaribe. ....	72
Figura 12 - Distribuição da precipitação total anual obtida do produto CHIRPS para a bacia do rio Capibaribe (1981 a 2020). ....	79
Figura 13 - Distribuição da precipitação média anual obtida do produto CHIRPS para a bacia do rio Capibaribe. ....	80
Figura 14 - Análise de tendência de precipitação das sub-bacias obtida pelo produto CHIRPS nas unidades de análise e na bacia do rio Capibaribe para os períodos de (a) 1981 a 2000 e (b) 2001 a 2020. ....	82
Figura 15 - Distribuição espacial e boxplot dos resultados de SPI no Capibaribe no período de 1981 a 2020: (a) média dos valores de seca e (b) desvio-padrão dos valores de seca. ....	83
Figura 16 - Distribuição espacial e boxplot dos resultados de SPI no Capibaribe no período de 1981 a 2020: (a) número de eventos; (b) duração dos eventos; (c) intensidade das secas e (d) severidade das secas. ....	85
Figura 17 - Distribuição espacial do (a) número total de meses com $SPI \leq -1$ e frequência de meses com seca nas categorias (b) moderada ( $-1,49 < SPI < -1$ ), (c) severa ( $-1,99 < SPI < -1,5$ ) e (d) extrema ( $< -2$ ) para o SPI 3, 6 e 12 com histogramas. ....	88

Figura 18 - Distribuição do NDVI médio anual obtidas do produto MOD13Q1 para a bacia do rio Capibaribe (2001 a 2020). .....	91
Figura 19 - Análise de tendência do NDVI médio anual das sub-bacias nas unidades de análise e na bacia do rio Capibaribe no período de 2001 a 2020. ....	93
Figura 20 - Boxplot da correlação entre a precipitação e NDVI padronizados das sub-bacias com diferentes defasagens (meses), agrupados por unidades de análise. ...	94
Figura 21 - Boxplot da correlação entre as escalas de SPI e aNDVI das sub-bacias, agrupados por unidades de análise. ....	96
Figura 22 - Espacialização dos valores dos parâmetros ajustados para as áreas de contribuição dos postos fluviométricos da bacia. ....	98
Figura 23 - Comparação entre as vazões mensais simuladas e observadas nos períodos de calibração e validação. ....	100
Figura 24 - Valores dos índices de desempenho para os seis postos fluviométricos. ....	101
Figura 25 - Comparação da umidade do solo diária observada <i>in-situ</i> e da umidade do solo simulada pelo SWAT, em unidade volumétricas, para a profundidade de 10 cm. ....	103
Figura 26 - Desempenho entre a umidade do solo média mensal observada e simulada. ....	106
Figura 27 - Heatmap da correlação média mensal entre índices em diferentes defasagens e profundidades do solo da sub-bacia 31: (a), (c) e (e) mostram SSMI-1 e SPI- <i>n</i> em defasagens; (b), (d) e (f) mostram aNDVI-1 e SSMI- <i>n</i> em defasagens. ...	108
Figura 28 - Semelhante à Figura 27, com os resultados da sub-bacia 18. ....	109
Figura 29 - Semelhante à Figura 27, com os resultados da sub-bacia 4. ....	109
Figura 30 - Semelhante à Figura 27, com os resultados da sub-bacia 42. ....	110
Figura 31 - Transformada wavelet cruzada entre SSMI e SPI nas diferentes sub-bacias e profundidades do solo. ....	114
Figura 32 - Coerência wavelet entre SSMI e SPI nas diferentes sub-bacias e profundidades do solo. ....	114
Figura 33 - Transformada wavelet cruzada entre SSMI e aNDVI nas diferentes sub-bacias e profundidades do solo. ....	116
Figura 34 - Coerência wavelet entre SSMI e aNDVI nas diferentes sub-bacias e profundidades do solo. ....	117

Figura 35 - Correlações mensais entre ENSO e SPI em diferentes escalas e defasagens nas quatro sub-bacias. O símbolo ● indica a máxima correlação.....	119
Figura 36 - Correlações mensais entre ENSO e SSMI, referente à profundidade total do solo, em diferentes escalas e defasagens nas quatro sub-bacias. O símbolo ● indica a máxima correlação.....	120
Figura 37 - Transformada wavelet cruzada e coerência wavelet entre ENSO e SPI nas diferentes sub-bacias. ....	122
Figura 38 - Transformada wavelet cruzada e coerência wavelet entre ENSO e SSMI (profundidade total do solo) nas diferentes sub-bacias. ....	123

## LISTA DE TABELAS

Tabela 1 - Classes de solos existentes na bacia do rio Capibaribe. ....	38
Tabela 2 - Identificação das estações fluviométricas utilizadas. ....	58
Tabela 3 - Principais informações dos reservatórios utilizados no projeto. ....	58
Tabela 4 - Descrição dos parâmetros utilizados na modelagem. ....	59
Tabela 5 - Classificação da eficiência da modelagem através do NS, PBIAS e R <sup>2</sup> ...	61
Tabela 6 - Relação dos ângulos de fase e direção das setas no espectro de potência da wavelet cruzada e no espectro de coerência da wavelet. ....	76

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>16</b>
1.1	HIPÓTESE.....	18
1.2	OBJETIVOS.....	18
<b>1.2.1</b>	<b>Objetivo geral.....</b>	<b>18</b>
<b>1.2.2</b>	<b>Objetivos específicos.....</b>	<b>18</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA E REVISÃO DE LITERATURA.....</b>	<b>19</b>
2.1	Função hidrológica da umidade do solo, com ênfase no semiárido.....	19
2.2	Sensoriamento remoto aplicado à hidrologia.....	22
2.3	Modelagem hidrológica.....	24
2.4	Utilização da umidade do solo no monitoramento das secas.....	27
<b>2.4.1</b>	<b>Panorama das secas no Nordeste brasileiro.....</b>	<b>27</b>
<b>2.4.2</b>	<b>Indicadores de seca: Métodos e Aplicações.....</b>	<b>30</b>
<b>2.4.3</b>	<b>A umidade do solo como indicador de seca.....</b>	<b>32</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>34</b>
3.1	Caracterização da área de estudo.....	34
<b>3.1.1</b>	<b>Clima.....</b>	<b>37</b>
<b>3.1.2</b>	<b>Relevo e solos.....</b>	<b>37</b>
<b>3.1.3</b>	<b>Uso e ocupação do solo.....</b>	<b>39</b>
3.2	O modelo SWAT.....	42
<b>3.2.1</b>	<b>Fase da terra.....</b>	<b>42</b>
<b>3.2.2</b>	<b>Escoamento superficial.....</b>	<b>43</b>
<b>3.2.3</b>	<b>Evapotranspiração.....</b>	<b>45</b>
<b>3.2.4</b>	<b>Percolação.....</b>	<b>48</b>
<i>3.2.4.1</i>	<i>Escoamento sub-superficial lateral.....</i>	<i>49</i>
<b>3.2.5</b>	<b>Águas subterrâneas.....</b>	<b>50</b>
<b>3.2.6</b>	<b>Cobertura vegetal.....</b>	<b>51</b>
<b>3.2.7</b>	<b>Fase de água ou de propagação.....</b>	<b>52</b>
<b>3.2.8</b>	<b>Reservatórios.....</b>	<b>54</b>
3.3	Banco de dados da modelagem no SWAT.....	55
<b>3.3.1</b>	<b>Modelo digital de elevação (MDE).....</b>	<b>55</b>
<b>3.3.2</b>	<b>Dados do solo e cobertura da terra.....</b>	<b>56</b>
<b>3.3.3</b>	<b>Dados climáticos.....</b>	<b>56</b>

<b>3.3.4</b>	<b>Postos fluviométricos e reservatórios</b> .....	<b>57</b>
3.4	Etapas de Execução do modelo SWAT .....	58
3.5	Estimativa da umidade do solo .....	61
3.6	Séries temporais de indicadores de seca .....	64
<b>3.6.1</b>	<b>Dados de precipitação por sensoriamento remoto</b> .....	<b>65</b>
<b>3.6.2</b>	<b>Índice de Precipitação Padronizada</b> .....	<b>67</b>
<b>3.6.3</b>	<b>Índice de vegetação</b> .....	<b>69</b>
3.7	Influência do El Niño Oscilação Sul (ENSO).....	70
3.8	Correlação e análise temporal entre os índices .....	71
<b>3.8.1</b>	<b>Resposta da vegetação à variabilidade da precipitação</b> .....	<b>72</b>
3.8.1.1	<i>Propagação entre as secas</i> .....	73
3.8.1.2	<i>Análise wavelet</i> .....	75
<b>4</b>	<b>RESULTADOS</b> .....	<b>78</b>
4.1	Dinâmica da precipitação anual na bacia do rio Capibaribe .....	78
4.2	Caracterização da seca com base no produto CHIRPS .....	83
4.3	Distribuição espaço-temporal do NDVI com base no produto MODIS .....	90
4.4	Estimativa da umidade do solo .....	97
<b>4.4.1</b>	<b>Calibração e validação das vazões simuladas pelo modelo SWAT</b> .....	<b>97</b>
<b>4.4.2</b>	<b>Validação dos dados modelados de umidade do solo</b> .....	<b>103</b>
4.5	Relação entre a seca meteorológica, seca agrícola e seca da vegetação. ....	107
4.6	Relações entre eventos ENSO e as secas meteorológica e agrícola .....	117
4.7	Incertezas e limitações .....	125
<b>5</b>	<b>CONCLUSÕES E RECOMENDAÇÕES</b> .....	<b>127</b>
	<b>REFERÊNCIAS</b> .....	<b>130</b>

## 1 INTRODUÇÃO

A seca é um fenômeno climático recorrente, complexo e extremo, caracterizado por um período prolongado de precipitações abaixo do normal, resultando em impactos negativos em diferentes setores e atividades da sociedade, como a agricultura, a segurança alimentar, o turismo e a geração de energia (Azmi; Rüdiger; Walker, 2016; Cammalleri; Vogt; Salamon, 2016; Mishra; Singh, 2010). Esses impactos se manifestam diretamente em todos os componentes do sistema hidrológico, seja no abastecimento de água (chuva), no armazenamento (umidade do solo, águas subterrâneas e superficiais) ou na troca ou fluxo (evapotranspiração, drenagem/recarga e escoamento) (Anderson *et al.*, 2013; Chen *et al.*, 2019).

Os eventos de seca são considerados fenômenos lentos e podem ser recorrentes em vastas regiões do mundo, tendo características únicas quanto à duração e a intensidade (Wilhite, 2005; Zeri *et al.*, 2022). Em virtude de os efeitos se acumularem por um considerável período, podendo perdurar por anos antes do término do evento, torna-se difícil prever com precisão o início, o final e o grau de severidade do fenômeno (Cirilo, 2015; Cunha *et al.*, 2019). Ademais, as evidências apontam que as mudanças climáticas aumentarão o risco e a gravidade dos eventos extremos, dependendo das regiões, estações e indicadores de seca considerados (Cook *et al.*, 2020; IPCC, 2014). Assim, o monitoramento das secas e a compreensão das variações climáticas são indispensáveis para mitigar os impactos recorrentes e inesperados dos extremos climáticos (Shafiee-Jood *et al.*, 2014; Wilhite, 2014).

No Brasil, as secas são generalizadas e recorrentes na região Nordeste, mais precisamente no semiárido, que naturalmente é afetado por baixos índices pluviométricos e altas taxas de evapotranspiração. Nos últimos anos, a região enfrentou um evento de seca com intensidade e impactos na economia e sociedade não vistos há várias décadas (Marengo *et al.*, 2019; Souza, Alzira *et al.*, 2018). Essas condições produzem perdas progressivas de resiliência e afetam negativamente as populações mais vulneráveis, principalmente as mais pobres e as que vivem da agricultura de pequena escala (Marengo *et al.*, 2019; Simões *et al.*, 2010).

O monitoramento, avaliação e previsão de secas são desafiadores porque nenhum método ou índice único é efetivamente capaz de caracterizar todos os tipos de seca devido a suas causas distintas e vasta variabilidade espacial e temporal (Brown *et al.*, 2008). Esse tipo de acompanhamento, quando realizado por meio de

redes de monitoramento convencionais, com base em dados de campo, apresenta grandes dificuldades considerando a baixa densidade de estações e a expansão territorial do Nordeste. Para melhorar as precisões e minimizar os desafios na compreensão dos eventos e impactos das secas, outras formas de obtenção de dados referentes as variáveis hidrológicas e climáticas, em diversos níveis de detalhamento espacial, têm sido utilizadas, como o sensoriamento remoto e os modelos de superfície terrestre de balanço hídrico.

Os produtos de sensoriamento remoto são capazes de fornecer informações oportunas e confiáveis para o estudo das secas devido à abrangência dos mais diversos dados gerados pelos sensores, dentre eles a precipitação, a evapotranspiração, as condições da vegetação, a temperatura da superfície e a umidade do solo (Sousa Junior; Lacruz, 2015; Xu *et al.*, 2018).

A inclusão de dados do conteúdo de água solo nesse tipo de abordagem é fundamental para compreensão da dinâmica da variável nas diferentes zonas do solo, em especial a radicular, durante a ocorrências de eventos extremos. Essas investigações não foram amplamente abordadas até agora devido a algumas limitações para obtenção de séries temporais de umidade do solo em profundidades específicas, sejam advindas de sensores orbitais ou *in-situ* (Chatterjee *et al.*, 2022; Chen *et al.*, 2019; Havrylenko *et al.*, 2016).

A modelagem hidrológica tornou-se uma abordagem promissora para obtenção da distribuição espacial e temporal da umidade do solo em escala de bacia. Dentre os inúmeros modelos hidrológicos, o Soil and Water Assessment Tool (SWAT), com a vantagem de avaliação quantitativa simples, boa aplicabilidade, simulações contínuas por longos períodos e precisões satisfatórias nos resultados, tem sido gradualmente utilizado para obtenção do conteúdo de água no solo em estudos associados a eventos de seca nas mais diferentes regiões (Chen *et al.*, 2019; Havrylenko *et al.*, 2016; Rajib; Merwade; Yu, 2016; Sehgal; Sridhar, 2018, 2019; Uniyal *et al.*, 2017).

A implementação das mais diferentes tecnologias e ferramentas que facilitem uma gestão mais eficiente dos recursos hídricos é indispensável, especialmente em regiões que enfrentam secas persistentes e dificuldades de acesso à água. A utilização dessas técnicas pode fornecer uma compreensão mais abrangente dos fatores que afetam a disponibilidade dos recursos hídricos, tanto em termos espaciais quanto temporais, e tem ganhado destaque como uma atividade promissora para enfrentar esses desafios.

## 1.1 HIPÓTESE

O uso combinado de dados de sensoriamento remoto e modelagem hidrológica permite uma compreensão mais detalhada e precisa da variabilidade climática e do comportamento hidrológico retrospectivo em uma bacia sob diferentes condições hidroclimáticas no nordeste brasileiro.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo geral

A presente pesquisa tem como objetivo geral investigar as relações entre secas meteorológicas, agrícolas e da vegetação e suas teleconexões com eventos ENSO na bacia hidrográfica do rio Capibaribe.

### 1.2.2 Objetivos específicos

- Caracterizar os índices de seca de curto, médio e longo prazo a partir de produtos de sensoriamento remoto em escala da bacia e sub-bacia hidrográfica;
- Avaliar os padrões espaço-temporais da seca meteorológica na bacia e a sua relação com a vegetação;
- Estimar o conteúdo de água no solo através de modelagem hidrológica com o SWAT;
- Avaliar a escala de tempo e os mecanismos de propagação entre as secas meteorológica, da vegetação e agrícola;
- Analisar a influência da teleconexão atmosférica na ocorrência das secas meteorológicas e agrícolas.

## 2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO DE LITERATURA

### 2.1 FUNÇÃO HIDROLÓGICA DA UMIDADE DO SOLO, COM ÊNFASE NO SEMIÁRIDO

A umidade do solo refere-se à água contida na camada superior do solo, chamada de zona vadosa, e é uma variável de estado que controla uma ampla gama de processos ecológicos, hidrológicos, geotécnicos e meteorológicos (Romano, 2014; Seneviratne *et al.*, 2010). Além disso, a variável desempenha um papel importante nas previsões do tempo e do clima da escala regional à global (Vereecken *et al.*, 2008), pois é responsável por influenciar diretamente a partição dos fluxos de água e energia entre a terra e a atmosfera, desempenhando um papel fundamental na avaliação dos diferentes componentes do balanço hídrico e energético (Brocca *et al.*, 2017b; Wang; Qu, 2009; Zhang; Zhou, 2016).

Devido à influência dominante em processos físicos chave, o conhecimento sobre o conteúdo de água no solo é importante em muitas disciplinas e aplicações científicas, como, por exemplo, em ecologia e em estudos do ciclo regional da água, mudanças climáticas e monitoramento ambiental (Bosch *et al.*, 2004; Wang; Qu, 2009). A umidade do solo também tem sido bastante utilizada em estudos que buscam avaliar a seca em ambientes com vegetação, pois o conteúdo de água presente no solo é um fator limitante para o crescimento vegetal (Nicolai-Shaw *et al.*, 2017; Zhang; Zhou, 2016; Zhou *et al.*, 2021).

A umidade do solo desempenha um papel fundamental em ecossistemas com limitação de água, como nas regiões semiáridas e áridas, que cobrem mais de 40% da superfície terrestre global (Reynolds *et al.*, 2007). Nessas regiões, a compreensão adequada da variabilidade temporal e espacial do conteúdo de água no solo é fundamental, pois irrigações regulares são frequentemente necessárias, mas os recursos hídricos são muito limitados, além dos impactos na produção, rendimento e no estado de saúde das safras (Vereecken *et al.*, 2008; Wang; Lettenmaier; Sheffield, 2011; Wu *et al.*, 2016). Ademais, por causa da limitação de água nesses ambientes, a umidade do solo afeta fortemente a hidrologia da superfície da terra, a hidrologia subsuperficial e os fluxos eco-hidrológicos (Maheu *et al.*, 2018; Seneviratne *et al.*,

2010), reiterando a importância de avanços no entendimento da umidade do solo e na sua variabilidade no tempo e no espaço.

Nesse aspecto, alguns fatores, como os componentes do ciclo hidrológico (em especial a precipitação e a evapotranspiração) e ambientais (características do solo, vegetação e topografia), impactam diretamente na variabilidade espacial e temporal da umidade do solo (Chaney *et al.*, 2014; Fang *et al.*, 2016; Li *et al.*, 2021). Esses podem influenciar de forma distinta a heterogeneidade do conteúdo de água no solo quando analisadas diferentes escalas, todavia, uma compreensão precisa a respeito da interferência na variabilidade espacial da umidade do solo ainda é limitada. Brocca *et al.* (2017), explicam que, com base em resultados de pesquisas sobre esse tema, as variáveis meteorológicas, precipitação e evapotranspiração, têm um evidente impacto em padrões de umidade do solo em grandes escalas (> 500-1000 km<sup>2</sup>), enquanto em escalas menores, são os fatores estáticos (cobertura da terra, topografia e textura/estrutura do solo) que aparentam afetar a variabilidade espacial da umidade do solo, embora a forma exata dessas relações não seja totalmente precisa. Srivastava *et al.* (2021) apresentam dois motivos que elucidam as incertezas a respeito do nível de interferência desses fatores sobre variabilidade do conteúdo de água no solo, sendo: a inter-relação entre os fatores que torna difícil a separação dos seus efeitos e a quantificação da sua importância relativa e; a amostragem das medições de umidade do solo no espaço e no tempo, que às vezes pode levar a resultados contraditórios.

Quanto à inter-relação entre os fatores, é válido pontuar que, sob outra perspectiva, alguns processos hidrológicos de superfície podem ser afetados diretamente pelo conteúdo de água no solo. Para exemplificar, destacam-se a geração de escoamento, ocorrência de enchentes ou secas, a previsão do tempo de curto prazo, a erosão do solo, o transporte de soluto e a dinâmica da vegetação (Brocca *et al.*, 2017; Chaney *et al.*, 2015; Romano, 2014; Wang; Lettenmaier; Sheffield, 2011), além de impactos adicionais nos processos climáticos, em particular na temperatura do ar, estabilidade da camada limite e, em alguns casos, na precipitação (Seneviratne *et al.*, 2010). Considerando essa última variável, Taylor *et al.* (2012) constataram, a partir de uma análise em escala global, a influência do conteúdo de água sobre a convecção úmida da tarde, ressaltando resultados mais perceptíveis nas regiões semi-áridas, onde os fluxos de superfície aumentam a partir de solos mais secos e os eventos convectivos são frequentes.

A resposta hidrológica do escoamento superficial a eventos de chuva em paisagens semiáridas é determinada por vários fatores de interação (Castillo; Gómez-Plaza; Martínez-Mena, 2003; Zhao *et al.*, 2014), que se diferenciam daqueles que regulam a hidrologia de ambientes mais úmidos (Wit, 2001). De acordo com Solé-Benet *et al.* (1997), os fatores mais relevantes, além da variabilidade espacial e temporal da precipitação, são as condições de superfície, como crostas do solo, pavimentação rochosa, cobertura vegetal e posição geomorfológica. Huo *et al.* (2020) destacam que nas regiões semiáridas, o mecanismo dominante de geração do escoamento é o excesso de infiltração devido à camada espessa do solo e aos baixos teores de umidade. Para Fitzjohn, Ternan e Williams (1998), a umidade do solo é um fator chave na determinação da resposta do escoamento superficial a um determinado evento de precipitação.

Em relação à influência sobre a dinâmica da vegetação, a água presente nas camadas mais profundas do solo, zonas em que a umidade não é sensível à evapotranspiração diária e aos eventos regulares de chuva, funcionam como reservatórios e são fundamentais para a produtividade das plantas e a sustentabilidade do ecossistema, principalmente em regiões áridas ou semiáridas, com escassez sazonal de água (Cao *et al.*, 2018; Fang *et al.*, 2016). As plantas têm fortes efeitos no equilíbrio hídrico do ecossistema devido a sua capacidade de acessar, transportar e transpirar a umidade do solo (Yinglan *et al.*, 2019). Em regiões semiáridas, a via principal do transporte de água no solo é entre a captação de água pela raiz e a evapotranspiração (Jian *et al.*, 2015). Nessas regiões, as respostas da vegetação variam entre os tipos funcionais de plantas e dependem da dinâmica sazonal e da umidade nas diferentes profundidades do solo (Yang *et al.*, 2014; Yinglan *et al.*, 2019). Durante os períodos de seca, a umidade das camadas mais profundas do solo fornece a água necessária para o desenvolvimento das plantas, sendo, portanto, fundamental para o crescimento vegetal na ocorrência dos eventos de escassez hídrica.

Quanto ao monitoramento da variável em regiões semiáridas, Amri *et al.* (2011) alertam que a análise sazonal da influência da vegetação pode proporcionar erros na estimativa do conteúdo de água no solo. De fato, a dinâmica do ciclo da vegetação pode variar significativamente de um ano para outro nas regiões propensas a frequentes períodos de seca. Além desse fator, Cosh *et al.* (2008) explicam que as investigações voltadas à compreensão da dinâmica temporal da umidade do solo em

regiões áridas e semiáridas ainda são pouco realizadas e, quando ocorrem, são em curtos períodos e não consideram uma grande rede de monitoramento.

Nesse contexto, torna-se imprescindível a obtenção de informações sobre o conteúdo de umidade do solo de maneira ampla e detalhada, levando em consideração tanto sua variação espacial quanto temporal. Embora seja uma tarefa trabalhosa e onerosa, atualmente existem alternativas viáveis, especialmente com a popularização das técnicas de sensoriamento remoto e a utilização de modelos hidrológicos, mesmo apresentando algumas limitações. Em regiões como o semiárido brasileiro, essas alternativas mostram-se como ferramentas valiosas para o entendimento da variação sazonal da umidade do solo. Além disso, a inclusão desses dados no monitoramento das secas, pode proporcionar uma compreensão mais abrangente das características e impactos dos eventos extremos.

## 2.2 SENSORIAMENTO REMOTO APLICADO À HIDROLOGIA

A captura de informações espaciais é amplamente realizada por meio do sensoriamento remoto, que utiliza a detecção da radiação eletromagnética onde há uma interação com os objetos e a atmosfera, sem a necessidade de contato físico com o alvo. Esse tipo de interação com a superfície da Terra é capaz de fornecer informações precisas sobre diversos aspectos, incluindo a direção, intensidade, comprimento de onda e polarização da radiação. As informações coletadas podem ser utilizadas para inferir não apenas a distância entre o sensor e o objeto, mas também outras características importantes da cena observada. Essas medições podem oferecer informações posicionais sobre os objetos e dados sobre as características dos materiais da superfície (Zhu *et al.*, 2018).

O desenvolvimento do sensoriamento remoto tem sido caracterizado por sensores cada vez mais especializados e precisos. Há uma variedade de sensores em operação em diferentes partes do espectro eletromagnético e, dependendo do tipo, o sensor pode coletar dados de uma ou várias faixas espectrais. Como resultado, é possível adquirir informações de energia que não são visíveis ao olho humano. Os dispositivos ópticos de sensoriamento remoto operam no visível, infravermelho próximo, infravermelho médio, e a porção infravermelha de ondas curtas do espectro eletromagnético (Reddy, 2018).

Independentemente da escala do estudo, o sensoriamento remoto oferece uma oportunidade de fornecer uma metodologia consistente e repetível, adequada tanto para estudos piloto rápidos quanto para campanhas de monitoramento de longo prazo (Tomlinson *et al.*, 2011). Os produtos são os mais diversos, como o uso da terra e mapeamento de cobertura, as mudanças na cobertura da terra, a dinâmica da vegetação de desmatamento e a dinâmica da qualidade da água, secas, inundações, crescimento urbano etc. (Jeyaseelan, 2003; Singh; Vyas, 2022).

De acordo com Araújo (2020), as características dos sensores orbitais variam conforme a sua finalidade, como por exemplo, sensores utilizados para monitoramento ambiental e mudanças no uso do solo operam na faixa visível do espectro (0,4 a 0,7  $\mu\text{m}$ ). Os principais tipos de instrumentos de satélite usados para estimar as variáveis em estudos de clima e agricultura são Terra/Aqua (MODIS), NOAA/AVHRR, SPOT-VGT, TM e ETM do LANDSAT e SEVIRI na série de satélites METEOSAT (Toulios, 2015).

Em relação à precipitação, vários são os produtos para esse tipo de estimativa, alguns baseados em sensores orbitais ou reanálise, tendo tornado um novo método de observação meteorológica, compensando a limitada cobertura espacial dos métodos tradicionais de observação no fornecendo dados complementares (Brito *et al.*, 2021; Santos *et al.*, 2021; Zambrano *et al.*, 2017). A partir do lançamento do *Tropical Rainfall Measuring Mission* (TRMM), em 27 de novembro de 1997, um número crescente de produtos de precipitação por satélite começou a surgir (Lei; Zhao; Ao, 2022). Os principais produtos incluem o *TRMM Multi-satellite Precipitation Analysis* (TMPA) (Huffman *et al.*, 2007), *Climate Hazards Group Infrared Precipitation with Station Data* (CHIRPS) (Funk *et al.*, 2015), *Climate Prediction Center Morphing Technique* (CMORPH) (Joyce *et al.*, 2004), *Global Satellite Mapping of Precipitation* (GSMaP) (Kubota *et al.*, 2007), *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN) (Sorooshian *et al.*, 2000) e os seus produtos aprimorados (PERSIANN-CDR) (Ashouri *et al.* 2015). De modo geral, cada produtos de precipitação por satélite tem suas especificações, diferindo, por exemplo, nas formas das fontes de dados e nos tipos de algoritmos utilizados para recuperação, como também nas técnicas de correções correspondentes.

O sensoriamento remoto da vegetação é realizado principalmente pela obtenção das informações de refletância de ondas eletromagnéticas das copas usando sensores passivos (Xue; Su, 2017). A refletância da vegetação ao espectro

eletromagnético (refletância espectral ou características de emissão da vegetação) é determinada por características químicas e morfológicas da superfície de órgãos ou folhas (Zhang; Kovacs, 2012). Xue e Su (2017) explicam que as principais aplicações de sensoriamento remoto de vegetação são baseadas nos seguintes espectros de luz: (i) região do ultravioleta (UV), que vai de 10 a 380 nm; (ii) os espectros visíveis, que são compostos pelas regiões de comprimento de onda azul (450 - 495 nm), verde (495 - 570 nm) e vermelho (620 - 750 nm); e (iii) a banda do infravermelho próximo e médio (850 - 1700 nm). De acordo com Arkebauer (2005), a taxa de emissividade da superfície das folhas (equivalente à absorvidade na faixa de ondas térmicas) de uma planta verde totalmente crescida sem nenhum estresse biótico ou abiótico geralmente está na faixa de 0,96 a 0,99 e é mais frequente entre 0,97 e 0,98. Já para plantas secas, a taxa de emissividade geralmente tem uma faixa maior indo de 0,88 a 0,94.

Os dados de refletância espectral correspondentes têm sido bastante usados na forma de índices espectrais, que são combinações matemáticas de duas ou mais bandas espectrais selecionadas para descrever os parâmetros biofísicos de interesse (Jones; Vaughan, 2010). Muitos são os índices espectrais utilizados para diferentes finalidades em investigações no campo da hidrologia e agrometeorologia, e, quando aliado aos produtos de precipitação por satélite, permitem diagnósticos mais rápidos e compreensões mais detalhadas dos impactos das secas.

### 2.3 MODELAGEM HIDROLÓGICA

Os modelos hidrológicos são desenvolvidos para a compreensão dos processos dinâmicos, testagem de hipóteses e para auxiliar na tomada de decisão em escala de bacia hidrográfica (Moges *et al.*, 2021). O melhor modelo, segundo Devia, Ganasri e Dwarakish (2015), é aquele que fornece resultados próximos da realidade, utilizando poucos parâmetros, e com menor complexidade.

De acordo com Tucci (2005), os modelos hidrológicos podem ser utilizados para prever as consequências de alterações antrópicas ou hidroclimatológicas em bacia hidrográficas, como, por exemplo, as vazões decorrentes de chuvas intensas, efeitos de modificações no uso do solo, o impacto da urbanização de uma bacia etc. Contudo, existem algumas limitações para a utilização desses modelos, como a quantidade e qualidade dos dados hidrológicos e a dificuldade de formular

matematicamente alguns processos e simplificar o comportamento espacial de variáveis e fenômenos.

Como forma de complementar a escassez de dados hidrológicos ou suprir os custos com medições diretas das variáveis hidrológicas, para o desenvolvimento de estudos em bacias, os pesquisadores têm buscado cada vez mais a utilização desses modelos. Quando devidamente calibrados e validados a partir de dados observados, que em geral são curtos e limitados, os modelos representam importantes fontes de conhecimento dos componentes hidrológicos ao longo do tempo, permitindo a obtenção de dados até mesmo em bacias pouco ou não monitoradas (Santos; Silva; Paiva, 2005; Viana *et al.*, 2018).

Duas informações de entrada mais importantes exigidas para todos os modelos, segundo Devia, Ganasri e Dwarakish (2015), são os dados de precipitação e a área de drenagem. Ao mesmo tempo, algumas características da região hidrográfica como as condições do solo, a cobertura vegetal, o relevo, o conteúdo de água no solo e as águas subterrâneas também podem ser consideradas. Os modelos hidrológicos são classificados com base nos dados de entrada, nos parâmetros do modelo e na extensão dos princípios físicos aplicados (Devia; Ganasri; Dwarakish, 2015; Nesru, 2023):

- Modelos empíricos: utilizam relações matemáticas derivadas de séries temporais de entradas e saídas simultâneas, não representando os processos físicos da bacia e válidos apenas no limite da área estudada. O hidrograma unitário é um exemplo desse método.
- Modelos conceituais: descrevem todos os componentes dos processos hidrológicos, obedecendo aos processos físicos que regem aquele fenômeno. É composto por uma série de reservatórios interconectados para representar os diferentes componentes do processo hidrológico por meio de recarga e esgotamento.
- Modelos de base física: buscam representar matematicamente os fenômenos reais utilizando variáveis de estado, que são mensuráveis em função tanto do tempo quanto do espaço. Podem levar em consideração a variabilidade espacial do uso do solo, declividade, tipo de solo e clima para lidar com os processos hidrológicos semi ou totalmente distribuídos dentro da bacia (Jaiswal; Ali; Bharti, 2020).

- Estocásticos: utilizam conceitos numéricos e estatísticos para relacionar uma determinada entrada com saída do modelo. Diferente dos modelos determinísticos, esses modelos geram diferentes valores de saída para um único conjunto de entradas. O objetivo é representar propriedades estatísticas significativas de um ou mais dados de séries temporais, enfatizando a dependência temporal dos parâmetros hidrológicos associados ao modelo.
- Determinísticos: representam os processos físicos observados através de variáveis físicas quantificáveis. Não exigem dados hidrológicos e meteorológicos extensos para calibração, mas exigem a avaliação de volumes substanciais de variáveis que descrevem as características do estado da área (Abbott *et al.*, 1986). Se todos os parâmetros forem considerados livre de variação aleatória, o modelo é não probabilístico, sendo então chamado de modelo determinístico.

Devia, Ganasri e Dwarakish (2015) destacam que cada modelo tem especificações quanto a aplicabilidade, proporcionando simulações a nível de pequenas bacias e até modelos globais. São os dados de precipitação e a área de drenagem. Muitas são as potencialidades na utilização da modelagem hidrológica na escala de bacia hidrográfica, calibradas ou não calibradas, auxiliando na previsão de enchentes, nos impactos das secas, no gerenciamento adequado de recursos hídricos e avaliação da qualidade da água, erosão e sedimentação, circulação de nutrientes e pesticidas, uso da terra e mudanças climáticas etc.

No Nordeste Brasileiro, um grande esforço tem sido desenvolvido nos últimos anos no sentido de descrever os processos hidrológicos em bacias hidrográficas da região como suporte ao gerenciamento de recursos hídricos, especialmente no Estado de Pernambuco (Araújo, 2020). Dessa forma, o projeto SUPer (Sistema de Unidades de resposta hidrológica para Pernambuco), disponível em <https://super.swat.tamu.edu/>, foi desenvolvido com base no modelo semi-distribuído e contínuo no tempo chamado *Soil and Water Assessment Tool* (SWAT), criado pela Texas A&M University, integrando as bases de dados climáticos, de cobertura vegetal, e hidrológicos da região.

O modelo SWAT é especialmente útil para avaliar os impactos das mudanças de uso e ocupação do solo em bacias hidrográficas de diferentes escalas. Ele se destaca por ser compatível com diversos softwares de geoprocessamento, incluindo o ArcGIS e o QGIS. Para executar simulações e previsões de cenários, o modelo

SWAT depende de informações espaciais detalhadas, incluindo um modelo digital de elevação, séries temporais de dados de precipitação, informações sobre hidrografia, fluxo de água, mapas de solo, mapas de uso e ocupação do solo, dados de vazão, umidade relativa, velocidade do vento, temperatura mínima e máxima e informações sobre a radiação solar. Todas essas informações são essenciais para que o modelo possa simular e prever com precisão os processos hidrológicos em uma bacia hidrográfica.

O SWAT tem sido amplamente utilizado por pesquisadores, uma vez que foi projetado para prever o impacto das práticas de manejo da terra na água, sedimentos e planejamento de manejo agrícola de grandes e complexas bacias hidrográficas (Havrylenko *et al.*, 2016). Alguns estudos em bacias localizadas no Nordeste brasileiro têm aplicado satisfatoriamente o modelo em diferentes tipos de investigações, como a simulação de vazão (Silva *et al.*, 2018), produção de sedimentos (Medeiros *et al.*, 2019), impactos das mudanças climáticas nos processos hidrológicos (Andrade *et al.*, 2021; Santos *et al.*, 2021) e análise da confiabilidade de produtos de precipitação como dados de entrada (Viana *et al.*, 2021).

## 2.4 UTILIZAÇÃO DA UMIDADE DO SOLO NO MONITORAMENTO DAS SECAS

### 2.4.1 Panorama das secas no Nordeste brasileiro

As secas são riscos naturais recorrentes e ocorrem em praticamente todas as zonas climáticas, originando-se principalmente dos volumes anormalmente baixos de precipitação recebidos durante um longo período, como uma estação ou um ano (Mishra; Singh, 2010; Raposo; Costa; Rodrigues, 2023). Como resultado dos déficits de chuva, há um aumento da demanda de água atmosférica, com taxas de evaporação acima do normal e de umidade do solo e produção de escoamento abaixo do normal (Chen *et al.*, 2019; Van Loon *et al.*, 2024). Geralmente classificadas em quatro categorias (Paredes; Barbosa; Guevara, 2015; Wilhite; Glantz, 1985), que incluem:

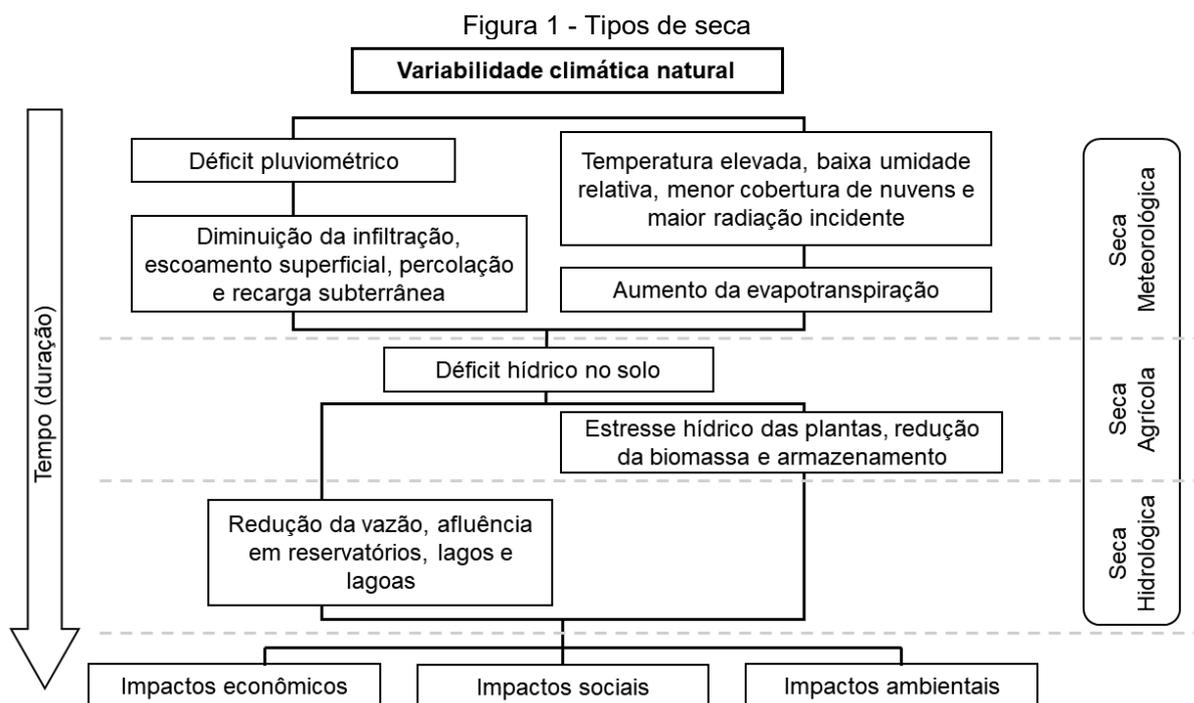
Meteorológica: definida em termos do grau de déficit de precipitação e sua duração, estando muito abaixo da quantidade normal esperada. Caracterizada por baixa umidade relativa do ar e uma menor cobertura de nuvens, causando elevação da temperatura devido as maiores taxas de radiação;

Agrícola: ocorre quando não há umidade suficiente no solo para o desenvolvimento de uma cultura, em qualquer estágio de crescimento, gerando impactos agrícolas como o estresse hídrico de plantas, a redução de biomassa etc. A seca agrícola, diferentemente da meteorológica, depende do próprio sistema afetado, pois uma disponibilidade hídrica reduzida pode não resultar em estresse hídrico para uma cultura em fase inicial de crescimento, mas ser insuficiente para o mesmo cultivo num estágio mais avançado.

Hidrológica: caracterizada pela redução significativa da disponibilidade de mananciais superficiais ou subterrâneos, podendo ser quantificada com base na vazão de rios, armazenamento de lagos ou represas, nível das águas subterrâneas etc. Esse déficit hídrico torna-se um fator limitante no atendimento aos usos estabelecidos em sistemas de gestão de águas locais.

Socioeconômica: associada aos impactos socioeconômicos gerados pela seca, podendo ser definido como a incapacidade de suprir a demanda de bens econômicos (água potável, grãos alimentícios, eletricidade etc.) resultante do déficit hídrico originado pela seca meteorológica.

Esse tipo de classificação (Figura 1) é fundamental para a análise do processo de propagação da seca e para a identificação das características a serem avaliadas. Na ocorrência de uma seca meteorológica, a infiltração de água no solo é reduzida, o que pode levar à diminuição do escoamento superficial e o aumento das taxas de evapotranspiração. Isso resulta em um balanço de água negativo nas camadas superficiais do solo, reduzindo a disponibilidade de água para as plantas com raízes menos profundas. À medida que a estiagem continua, plantas maiores também são afetadas, pois a limitação do processo de infiltração de água no solo afeta diretamente a passagem vertical da umidade para as camadas mais profundas. Caso a seca persista, a reposição de água no solo é continuamente afetada, o que pode ter graves consequências para a vegetação.



Fonte: National Drought Mitigation Center, University of Nebraska-Lincoln, U.S.A.

Precipitações de baixa intensidade podem não ser suficientes para restabelecer a deficiência de água no solo e, conseqüentemente, impossibilitam a ocorrência do escoamento superficial. O resultado desse cenário é a diminuição da recarga subterrânea dos aquíferos e do fluxo superficial dos rios e lagos. A seca hidrológica é justamente o resultado dos baixos níveis de água nessas fontes.

A seca é uma grande preocupação no Nordeste brasileiro pois sua maior área é composta por uma região semiárida densamente povoada, constituindo um fenômeno grave que coloca em risco a segurança alimentar, energética e hídrica da região (Marengo; Cunha; Alves, 2016; Rebello *et al.*, 2020). A extrema variabilidade climática observada, típica das regiões semiáridas, resulta em diversos impactos socioeconômicos e é relatada desde o século XIX (Campos, 2015). Uma lista de eventos de seca registrados nos últimos anos no Nordeste foi apresentada por Marengo *et al.* (2018): 1583, 1603, 1624, 1692, 1711, 1720, 1723-1724, 1744-1746, 1754, 1760, 1772, 1766-1767, 1777-1780, 1784, 1790-1794, 1804, 1809, 1810, 1816-1817, 1824-1825, 1827, 1830-1833, 1845, 1877-1879, 1888-1889, 1891, 1898, 1900, 1902-1903, 1907, 1915, 1919, 1932-1933, 1936, 1941-1944, 1951-53, 1958, 1966, 1970, 1976, 1979-1981, 1982-1983, 1986-87, 1992-1993, 1997-1998, 2001-2002, 2005, 2010 e 2012-2016. Esse último registro ainda tem sido observado em relação a duração do evento, estudos mais recentes consideram que a última seca no Nordeste

durou até o ano de 2018 (Alvalá *et al.*, 2019; Cuartas *et al.*, 2022; Marengo *et al.*, 2020). Além disso, esse episódio é considerado o mais grave das últimas décadas e afetou muitos municípios do Nordeste, afetando quase 9 milhões de pessoas (Brito *et al.*, 2018).

Assim, caracterizar e compreender o potencial impacto das secas na disponibilidade de recursos hídricos é essencial para futuras ações de mitigação e adaptação em todos os setores produtivos do Brasil (Cuartas *et al.*, 2022). A avaliação e o monitoramento convencionais da seca geralmente se concentram nos aspectos meteorológicos da seca e os dados de precipitação e/ou evapotranspiração são frequentemente usados para construir índices meteorológicos de seca para o monitoramento no espaço e no tempo (Heim, 2002).

#### **2.4.2 Indicadores de seca: Métodos e Aplicações**

Existem diversos índices que são comumente aceitos como ferramentas para monitorar eventos e impactos da seca, incluindo sua duração, intensidade e gravidade. São vários os tipos de dados de entrada para essas estimativas, que dependem do tipo de seca e do índice adequado para avaliação de interesse. Dados com base em variáveis climáticas e hidrológicas, como séries de precipitação, umidade do solo, evapotranspiração e condição da vegetação, ou até mesmo a junção de algumas dessas variáveis, são utilizados para monitorar e quantificar a intensidade e os impactos desses eventos. Além disso, o desempenho de quaisquer índices de seca depende da disponibilidade e acessibilidade de dados climáticos e hidrológicos confiáveis (Mukhawana; Kanyerere; Kahler, 2023).

Outros índices são obtidos diretamente das informações espectrais, a partir dos produtos de sensoriamento remoto. Segundo Aghakouchak *et al.* (2015), os índices de seca derivados de séries temporais de satélites são altamente confiáveis para monitorar e avaliar a severidade da seca por sua resolução espaço-temporal, especialmente onde estão disponíveis estações de medição limitadas.

Diversos índices têm sido desenvolvidos com o objetivo de identificar déficits precipitação. Desses, destacam-se: o Percentil da Precipitação Normal, o Índice Chinês Z, o Índice de Precipitação e Evapotranspiração Padronizado (SPEI), o Índice de Severidade da Seca de Palmer (PDSI) e o Índice da Anomalia da Precipitação. O Índice Normalizado de Precipitação (SPI), desenvolvido por Mckee *et al.* (1993, 1995),

é um dos índices mais comumente utilizados para monitoramento de secas e considera apenas dados de precipitação. Sua eficácia levou a Organização Mundial de Meteorologia (WMO) a recomendar o uso do SPI como índice "meteorológico" de seca em 2009 (Hayes *et al.*, 2011).

O (SPI) apresenta vantagens e desvantagens em sua aplicação. Entre as vantagens, estão a possibilidade de determinação do tempo de retorno da seca, a ampla flexibilidade em diferentes escalas temporais, a simplicidade de aplicação, a versatilidade em combinação com outras variáveis, a capacidade de análise espacial e a comparação entre diferentes regiões, além de permitir o monitoramento e aviso prévio da seca (Hayes *et al.*, 2011; Svoboda; Fuchs, 2016; Zargar *et al.*, 2011) Por outro lado, as desvantagens do SPI consistem na necessidade de séries que tenham no mínimo 30 anos de dados contínuos de precipitação, o que pode ser difícil de se obter em regiões com baixa disponibilidade de dados pluviométricos e uma reduzida série histórica de produtos gerados através de sensoriamento remoto. Além disso, se ocorrerem mudanças ou erros nos dados ofertados pelas instituições, os valores de SPI podem mudar e deixar de representar o estado de seca (Svoboda; Fuchs, 2016; Zargar *et al.*, 2011).

Para monitorar as condições da vegetação no tempo e no espaço, muitos índices de vegetação foram desenvolvidos (Sandeep *et al.*, 2021), o NDVI é um dos índices de vegetação mais conhecidos e utilizado no monitoramento e na ocorrência de seca e condições da vegetação (Al-Quraishi; Gaznayee; Crespi, 2021; Berger; Wang; Mather, 2013; Fan *et al.*, 2018), especialmente em ambientes semiáridos onde a vegetação cobre menos de 30% da área (Berger; Wang; Mather, 2013; Reddy *et al.*, 2020).

Gonçalves *et al.* (2021) destacam que esse índice tem como principais vantagens a facilidade de processamento e obtenção de dados, além da possibilidade de auxiliar no acompanhamento das alterações sazonais no ciclo de vida das plantas. Por outro lado, algumas limitações podem ser observadas no uso de sensores e coleta de dados, tais como erros técnicos decorrentes de problemas nos sensores ou no processamento dos dados, interferências causadas pela coloração dos solos e presença de água na vegetação ou no solo.

### 2.4.3 A umidade do solo como indicador de seca

Uma característica fundamental das secas é a disponibilidade extremamente baixa de umidade do solo, devido à redução da precipitação e/ou aumento da evapotranspiração (Seneviratne *et al.*, 2012). Baixos índices pluviométricos por longos períodos provocam consequentes impactos na vegetação devido a diminuição do conteúdo de água no solo. Dessa forma, as informações sobre a umidade do solo são essenciais para o monitoramento da intensidade das secas, início da estação chuvosa, datas de plantio e alertas precoces de perdas de produtividade (Zeri *et al.*, 2022).

Para entender a inter-relação entre a umidade do solo e a seca em grande escala espacial, são necessários dados de longo prazo da umidade do solo (Sehgal, 2017). Como consequência dos registros prontamente disponíveis de precipitação e vazão, a avaliação de secas meteorológicas e hidrológicas é relativamente fácil (Chen *et al.*, 2019). No entanto, na maioria das regiões do mundo, a falta de redes de monitoramento de umidade do solo espacialmente extensas impede a limitação da umidade do solo em sistemas de monitoramento de seca (Ford *et al.*, 2015).

Tem havido uma extensa aplicação de informações de umidade do solo próximo à superfície obtidas por meio de sensoriamento remoto na agricultura e na meteorologia (Sehgal, 2017). Nas últimas décadas, com as vantagens da cobertura espaço-temporal contínua e extensa, a tecnologia de sensoriamento remoto por satélite tem atraído cada vez mais atenção para as observações de umidade do solo (Ahmadalipour; Moradkhani; Demirel, 2017; Mishra *et al.*, 2017), no entanto, as limitações como a detecção apenas das camadas mais superficiais (2 – 7 cm), as desvantagens de reescalamento, resolução espacial grosseira, qualidade muito baixa sob certas condições de superfície (vegetação densa, solos congelados, neve, terreno montanhoso) limitaram a aplicação generalizada de estimativas de umidade do solo por sensoriamento em simulações hidrológicas operacionais (Brocca *et al.*, 2017; Chen *et al.*, 2019). Além disso, a umidade do solo próximo à superfície não é suficiente para avaliar de forma abrangente a severidade da seca (Sehgal, 2017).

Dessa forma, algumas investigações para compreensão da dinâmica das secas têm buscado incorporar aos índices, comumente utilizados, informações da umidade do solo em grandes escalas temporais obtidas por meio de modelos hidrológicos

(Chen *et al.*, 2019; Havrylenko *et al.*, 2016; Sehgal; Sridhar, 2018, 2019; Uniyal *et al.*, 2017; Zeri *et al.*, 2022).

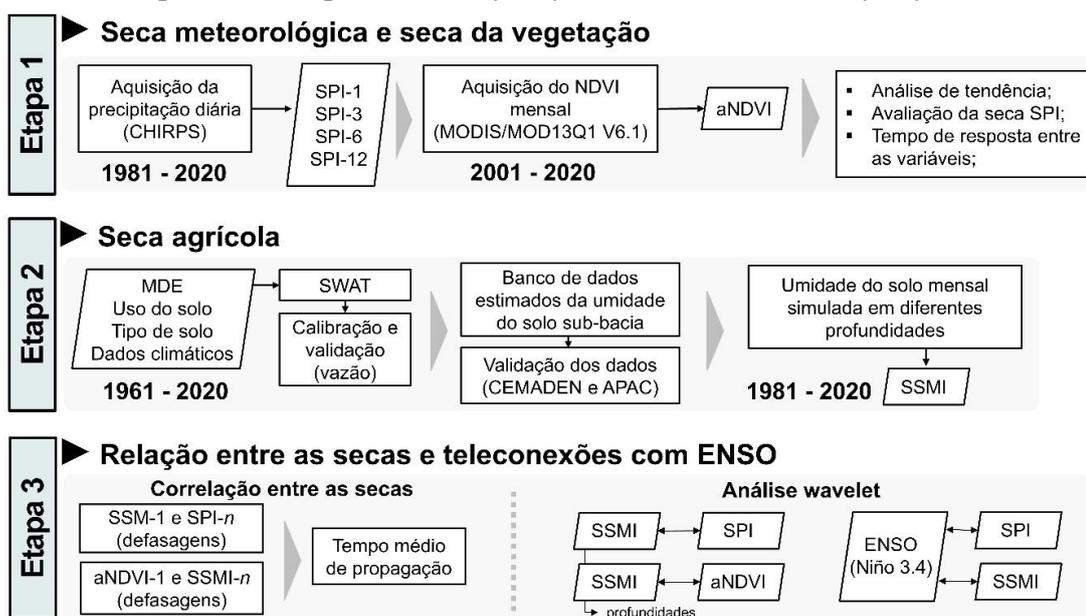
Havrylenko *et al.* (2016) investigaram a confiabilidade das estimativas de longo prazo da umidade do solo utilizando o SWAT na bacia de Arrecifes, em Buenos Aires, comparando os resultados com a variação temporal do SPI e NDVI, para caracterização de episódios de seca. Chen *et al.* (2019) obtiveram series históricas do conteúdo de água no solo modela com o SWAT na bacia do rio Luanhe, Nordeste da China, para investigar tempos de propagação e a relação entre as secas meteorológicas, agrícolas e hidrológicas, através da correlação com os índices SPEI, SRI, SSI e circulação atmosférica em grande escala. Zeri *et al.* (2022) utilizaram a umidade do solo simulada pelo modelo *Joint UK Land Environment Simulator* (JULES) no semiárido brasileiro e avaliaram a relação da série obtida com SPI e VHI, observando defasagens entre 1 e 1,5 mês na escala anual, sugerindo que tendências negativas da anomalia de umidade do solo e precipitação podem ser utilizadas como um alerta precoce para perdas de produção durante a estação de crescimento.

Em resumo, a integração das informações da umidade do solo no monitoramento das secas tem se mostrado uma abordagem essencial na complementação e melhoria da caracterização e previsão desses eventos. Embora existam desafios relacionados ao monitoramento espacial e temporal do conteúdo de água no solo, os avanços tecnológicos combinados com o uso de modelos hidrológicos podem aperfeiçoar a compreensão das tendências e previsões de secas agrícolas. Tais estratégias são fundamentais para o planejamento e o gerenciamento da seca em regiões mais vulneráveis, como o semiárido brasileiro, tendo em vista a redução de impactos socioeconômicos e ambientais.

### 3 MATERIAIS E MÉTODOS

Para obtenção dos objetivos propostos, este estudo foi dividido em três etapas, conforme a Figura 2. Inicialmente, foram obtidos e avaliados os índices de seca meteorológicos e da vegetação, através de produtos de sensoriamento remoto. A segunda etapa correspondeu à aquisição das informações da seca agrícola em diferentes profundidades do solo, obtidas a partir da umidade do solo simulada no modelo SWAT. Na terceira e última fase, as séries temporais dos diferentes índices foram correlacionadas considerando diferentes escalas e defasagens temporais, a fim de identificar os mecanismos de propagação entre as secas meteorológicas, agrícolas e hidrológicas. Por fim, foram avaliadas as teleconexões entre os eventos ENSO e as secas meteorológicas e agrícolas ao longo dos últimos anos.

Figura 2 - Fluxograma das etapas que serão utilizadas nesta pesquisa

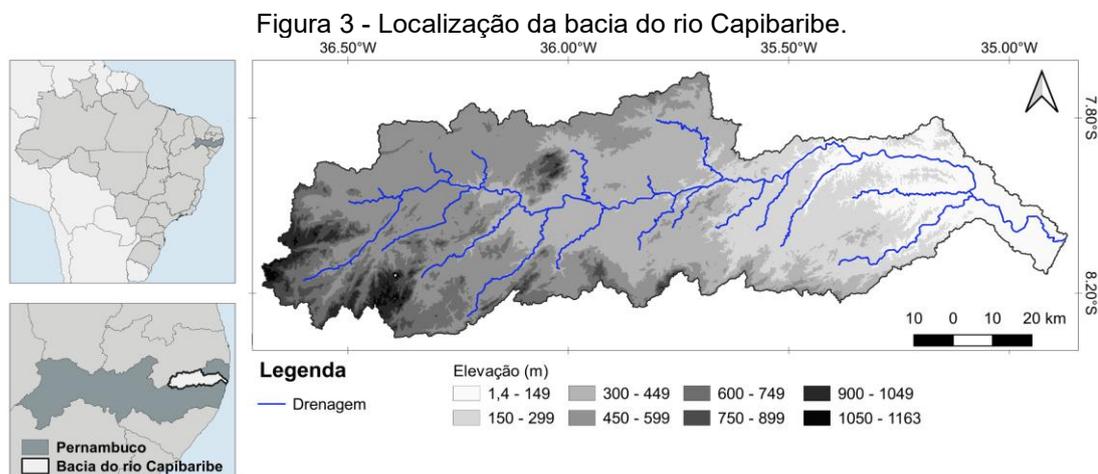


Fonte: O autor (2024).

#### 3.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo compreende a bacia do rio Capibaribe, que corresponde a Unidade de Planejamento Hídrico UP2, estando localizada na porção norte oriental do estado de Pernambuco (Figura 3), entre 07°41'20" e 08°19'30" de latitude sul, e 34°51'00" e 36°41'58" de longitude oeste. Limita-se ao norte com as bacias do rio Goiana (UP1) e grupo de bacias de pequenos rios litorâneos 1 - GL1(UP14), ao sul

com a bacia do rio Ipojuca (UP3) e o grupo de bacias de pequenos rios litorâneos 2 - GL2 (UP15), a leste com o Oceano Atlântico e os grupos GL1 e GL2 e, a oeste, com o Estado da Paraíba e a bacia do rio Ipojuca (APAC, 2022).



Fonte: O autor (2024).

De acordo com o Plano Hidroambiental da bacia, a sua área de abrangência inclui parte das regiões de desenvolvimento Agreste Central (RD 08), Agreste Setentrional (RD 09), Mata Sul (RD 10), Mata Norte (RD 11) e região metropolitana do Recife (RD 12), o que resulta em um ambiente complexo em relação aos contrastes climáticos, de relevo, de solo e de cobertura vegetal e socioeconômicos. Essa heterogeneidade territorial exige um adequado modelo de gestão hídrico e ambiental, que seja capaz de atender às suas particularidades sub-regionais e locais.

No ano de 2002, a partir do Plano Diretor da bacia hidrográfica do rio Capibaribe, toda a sua extensão foi dividida em quatro unidades de análise (UA), levando em consideração as características hidrológicas, climatológicas e socioeconômicas. Dessa forma, a subdivisão resultou nas unidades: UA 1 ou Unidade de Toritama, que abrange o terço superior da bacia; UA 2 ou Unidade de Jucazinho, compreendendo parte da área da bacia entre Toritama até o reservatório Jucazinho; UA 3 ou Unidade de Limoeiro, correspondente as áreas de drenagem desde o reservatório Jucazinho até o reservatório Carpina; e a UA 4 ou Unidade São Lourenço da Mata, que abrange as áreas de drenagem do seu terço inferior.

A bacia possui uma área de aproximadamente 7.454 km<sup>2</sup>, correspondendo a 7,58% do território de Pernambuco. Desde a sua nascente, na divisa dos municípios de Jataúba e Poção, a uma altitude aproximada de 1.000 metros, até o seu exutório,

no Recife, o rio Capibaribe percorre 42 municípios, sendo 15 localizados inteiramente na bacia e 26 com sua sede nela (PERNAMBUCO, 2006). Ao longo de todo o seu percurso, que tem uma extensão total de 280 km até a foz, o rio Capibaribe apresenta regime fluvial intermitente nos seus altos e médios cursos, tornando-se perene no seu baixo curso, a partir do município de Limoeiro. Em relação à rede de drenagem da bacia, o rio tem como principais tributários pela margem direita: o riacho do Mimoso, o riacho Tabocas, o riacho Carapatós, o riacho das Éguas, o riacho Caçatuba, o riacho Grota do Fernando, o rio Cotunguba, o riacho Goitá, e rio Tapacurá e outros de menor porte; e pela margem esquerda, destacam-se: o riacho Jundiá, o riacho do Pará, o riacho Tapera, o riacho Arroz, o riacho da Topada, o riacho Caiá e o rio Camaragibe.

Em relação ao sistema de reservatórios, Braga *et al.* (2015) destacam que a capacidade de acumulação de água é da ordem de 800 milhões de metros cúbicos. Dentre os principais reservatórios em operação, destacam-se Jucazinho, Carpina, Tapacurá, Goitá e Poço Fundo, concentrando mais de 90% da capacidade total de acumulação na região. Esses estão localizados estrategicamente em condições de controlar e regularizar as maiores vazões do rio Capibaribe, com operação destinada a atender os usos múltiplos, incluindo o abastecimento, piscicultura, irrigação e o controle de enchentes. Na bacia ainda existem outros reservatórios de pequeno porte, que corresponde a maioria, aproximadamente 900, com a capacidade máxima inferior a 500 mil metros cúbicos.

A disponibilidade de água subterrânea é significativa apenas na UA 4. A bacia cobre aquíferos de rocha cristalina em praticamente toda a sua área, havendo ocorrência de unidades sedimentares restritas apenas no seu baixo curso, na UA 4. A disponibilidade hídrica subterrânea em UA 1, UA 2 e UA 3 corresponde a 3,73% da disponibilidade subterrânea em UA 4 ( $1.257 \text{ m}^3 \text{ s}^{-1}$ ) (PERNAMBUCO, 2010; Ribeiro Neto *et al.*, 2014).

A variabilidade temporal da demanda de água, segundo Ribeiro Neto *et al.* (2014), é fortemente influenciada pelo crescimento populacional e econômico nos municípios da bacia. Durante a década de 2000, a taxa média anual de crescimento da demanda de água seguiu fatores sociais e econômicos, como a taxa de crescimento anual do produto interno bruto, o crescimento anual da população, o crescimento da área agrícola, a melhoria do índice de desenvolvimento humano e o aumento da carga de poluentes lançada no rio (PERNAMBUCO, 2010).

Esses fatores são fortemente influenciados pelo desenvolvimento das indústrias têxtil e sucroalcooleira, situada no terço médio abaixo da bacia. A título de exemplo, a UA 2 conta com um importante polo de confecções, que demanda fornecimento adequado e tem grande impacto ambiental devido a geração de efluentes dos processos de lavagem e destonagem de tecidos. As principais culturas irrigadas são a cana-de-açúcar, na AU 4, e hortaliças, na AU 3.

### **3.1.1 Clima**

De acordo com a classificação de Köppen (Alvares *et al.*, 2013) a região de estudo é dividida em três diferentes tipos climáticos: no alto curso predomina o tipo BSh (semiárido quente), enquanto no médio curso prevalece o tipo As (clima tropical quente e úmido) e no litoral o tipo Am (clima tropical úmido ou subúmido). A média anual da temperatura oscila entre 20,75° C e 26,20° C, com a temperatura máxima variando entre 25,33° C e 30,17° C. Em toda a bacia, a temperatura média mensal apresenta um comportamento semelhante ao longo do ano, com dois períodos distintos: menores valores de temperatura nos meses de abril e setembro, e aumento da temperatura média mensal nos meses de outubro a março. A umidade relativa do ar, considerando as médias anuais, aumenta no sentido oeste para leste, com os menores valores de 62%, no alto curso, chegando até cerca de 82,5%, próximo ao litoral.

Em relação a distribuição pluviométrica, a bacia apresenta uma variação pluviométrica espacial total anual média de 600 a mais de 2100 mm, com os totais anuais mais altos ocorrendo nas áreas mais próximas ao oceano, reduzindo à medida que avança para o interior, a exceção das áreas brejeiras, as quais sofrem influência da dinâmica orográfica (PERNAMBUCO, 2010).

### **3.1.2 Relevo e solos**

Segundo o Plano Hidroambiental da bacia, o relevo da região apresenta compartimentos morfoestruturais associados à unidade geoambiental do Planalto da Borborema, com maciços setentrionais representados pela Superfície Sertaneja, onde se destacam resíduos da Superfície Sul-Americana, seguidos pela superfície dos Tabuleiros onde ocorrem os relevos dissecados preenchidos por sedimentação

terciária e por fim o ciclo polifásico Paraguaçu, representado pela planície costeira. A superfície Gravatá, primeiro patamar do planalto da Borborema, com cotas superiores a 500 m, integra a superfície Sertaneja com elevações que constituem as serras divisoras da bacia do Capibaribe com a do rio Ipojuca, ao sul, e com do rio Paraíba, ao norte. A partir do médio curso o relevo é representado por colinas arredondadas, entrecortadas por pequenos vales. No baixo curso, ocorrem colinas com cotas altimétricas em torno de 40 m e na região metropolitana do Recife, com cotas entre 8 m e 2 m, ocorrem planícies costeiras com a presença de terraços marinhos.

Em relação aos aspectos pedológicos, o território é constituído por tipos diversificados de solos, como solos pouco estruturados, solos com altas concentrações de argila, bem desenvolvidos e solos aluvionais, de formação alagadiça, além de solos pouco desenvolvidos com até dois horizontes e baixa concentração de nutrientes. Na bacia, os solos predominantes (Tabela 1) são do tipo Argissolos Vermelho-Amarelo (PVA), seguido por Planossolos Háplico (SX) e Neossolos Litólico (RL). Em menor escala, estão os do tipo Neossolos Quartzarênicos (RQ), Argissolo Vermelho (PV) e Cambissolo Háplico (CX).

Tabela 1 - Classes de solos existentes na bacia do rio Capibaribe.

<b>Classe de solo</b>	<b>Área (km<sup>2</sup>)</b>	<b>Área (%)</b>
ARGISSOLO AMARELO (PA)	280,05	3,76
ARGISSOLO VERMELHO (PV)	1,18	0,02
ARGISSOLO VERMELHO-AMARELO (PVA)	1750,51	23,49
CAMBISSOLO HÁPLICO (CX)	12,62	0,17
ESPODOSSOLO HUMILÚVICO (EK)	30,85	0,41
GLEISSOLO HÁPLICO (GX)	120,62	1,62
LATOSSOLO AMARELO (LA)	202,62	2,71
LATOSSOLO VERMELHO-AMARELO (LVA)	39,98	0,54
LUVISSOLO CRÔMICO (TC)	648,48	8,7
NEOSSOLO FLÚVICO (RY)	180,94	2,43
NEOSSOLO LITÓLICO (RL)	1326,15	17,8
NEOSSOLO REGOLÍTICO (RR)	223,11	2,99
NEOSSOLOS QUARTZARÊNICOS (RQ)	0,77	0,01
PLANOSSOLO HÁPLICO (SX)	1666,12	22,36
PLANOSSOLO HÁPLICO (SX) e PLANOSSOLO NÁTRICO (SN)	693,62	9,31
VERTISSOLO HÁPLICO (VX)	182,37	2,45
Água	38,69	0,52
Área Urbana	53,83	0,72

Fonte: Adaptado de Pernambuco, 2010.

Os Argissolos ocupam a maior parte da bacia, estando distribuídos em toda a sua extensão, com significativa presença nos tabuleiros costeiros, ocorrendo sob vegetação de floresta subperenifólia e subcaducifólia, com relevo variando de ondulado a montanhoso. Podem ser muito profundos a rasos, com textura variando de arenosa a argilosa em superfície e de média a muito argilosa em subsuperfície, contendo argila predominantemente de atividade baixa, ocorrendo em diversos relevos, desde o plano ao montanhoso, o que ocasiona impedimentos à mecanização agrícola e riscos de erosão (PERNAMBUCO, 2010).

Ainda segundo Pernambuco (2010), a segunda classe de solos predominante no território, Planossolos, concentram-se na região média e alta do curso do rio. Comumente apresentam elevada fertilidade, possibilitando o seu aproveitamento na agricultura, contudo são susceptíveis a erosão e estão constantemente sujeitos a alagamentos no período chuvoso, e a um grande ressecamento na época seca. Já os solos do tipo Neossolos Litólico aparecem em regiões de relevo movimentado, de ondulado a montanhoso. Esses possuem textura predominantemente arenosa, que em geral apresentam fragmentos de rocha, parcialmente intemperizados, e/ou pedras e cascalhos no seu interior ou mesmo na superfície.

### **3.1.3 Uso e ocupação do solo**

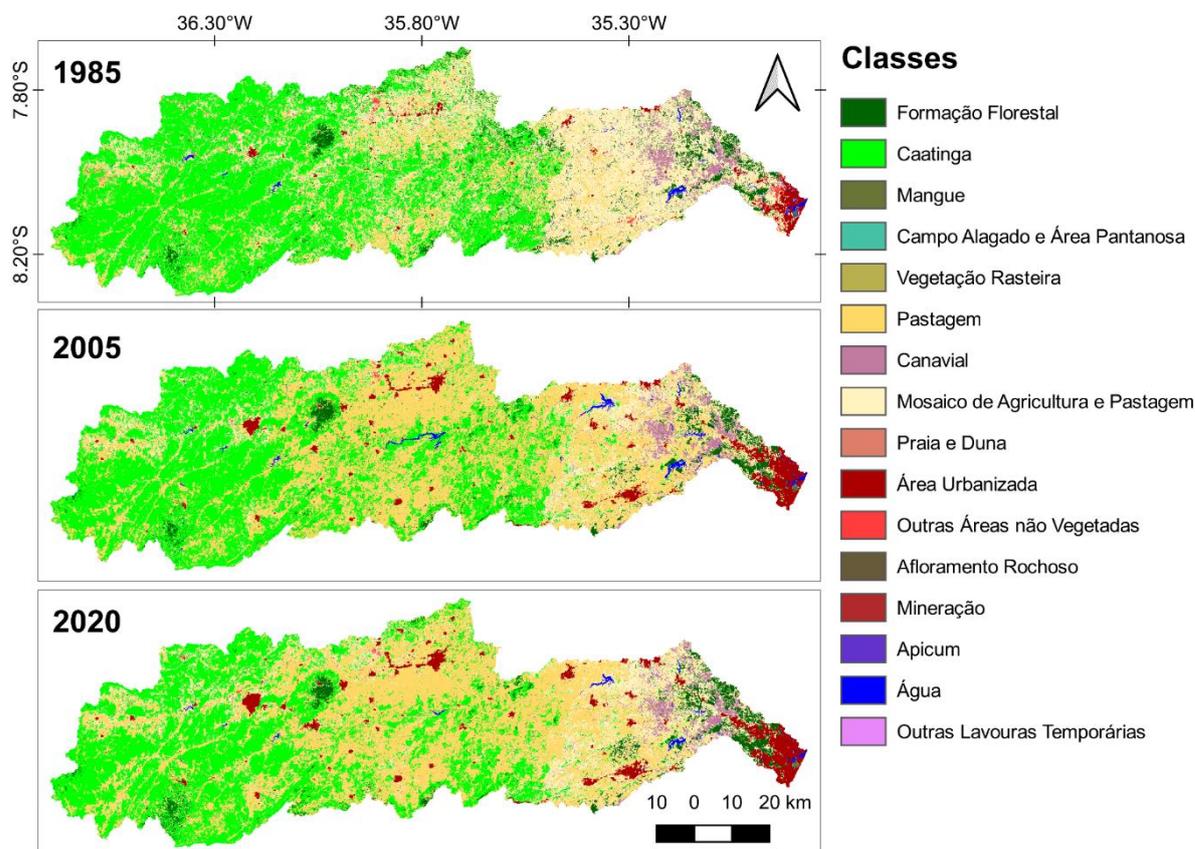
A bacia do rio Capibaribe apresenta um diversificado uso e ocupação do solo no seu território, caracterizado por regiões dinâmicas, com ocupações urbanas, industriais, áreas de pastagem, agricultura e mata atlântica. Braga *et al.* (2015) especificam o uso na bacia destacando as principais atividades econômicas locais, como a indústria sucroalcooleira e o turismo na Mata Sul e o suporte a ciência e tecnologia, turismo e serviços na área de RMR do Capibaribe; a agroindústria e produção de açúcar na Mata Norte; a indústria têxtil, fruticultura e caprinocultura no Agreste Setentrional; a pecuária bovina de corte e o comércio no Agreste Central, além dos aglomerados urbanos que margeiam o curso do rio.

O uso do solo quanto à vegetação é composto, de forma geral, por dois biomas: a Mata Atlântica, localizada na região litorânea, e a Caatinga, predominando na região oeste e central da bacia. Ao longo dos anos, a vegetação natural na bacia sofreu processos de modificações, devido, principalmente, a ocupação urbana e os desmatamentos para plantios agrícolas, pastos e pecuária.

De acordo com a Figura 4, é possível observar a espacialização das classes de uso e cobertura do solo na bacia, referente aos anos de 1985, 2005 e 2020, com dados obtidos do Projeto Brasileiro de Mapeamento Anual de Uso e Cobertura do Solo (MapBiomas, 2021). A dinâmica temporal das classes na ilustração demonstra a predominância da caatinga no ano de 1985 e, nos anos seguintes, um avanço da classe pastagem sobre as áreas de caatinga. Outra mudança perceptível ao longo dos anos é a redução do fragmento mosaico de agricultura e pastagem na região leste da bacia, modificada para diferentes outras classes, incluindo, sobretudo, o crescimento das áreas urbanizadas.

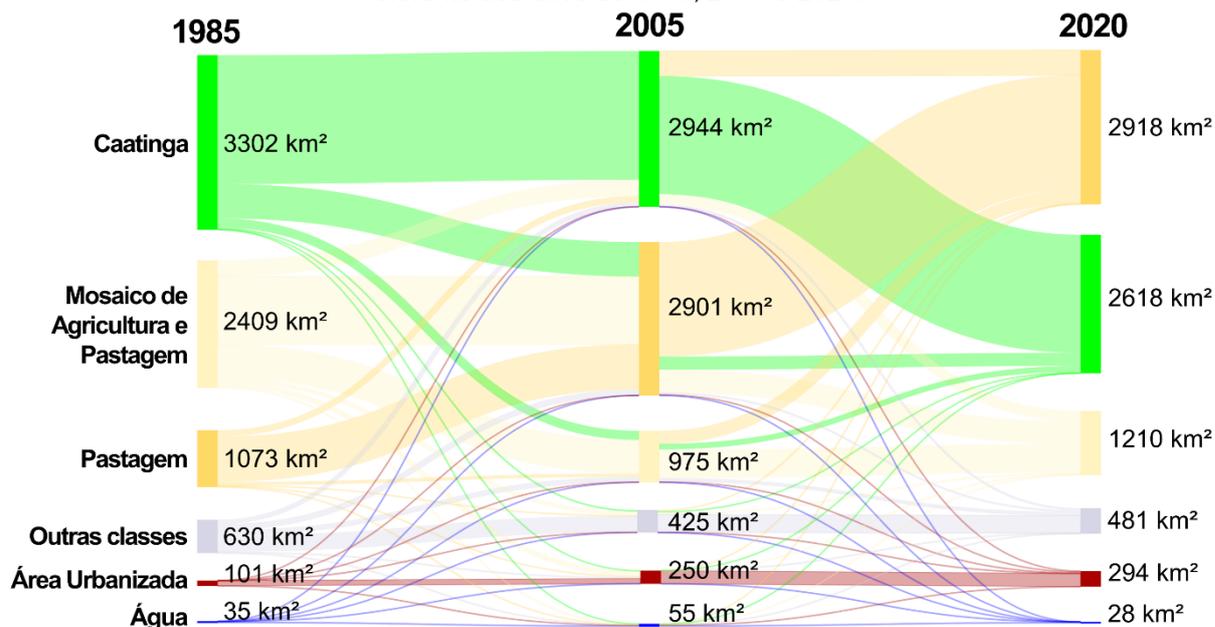
Em termos percentuais, analisando toda a bacia, as áreas de caatinga sofreram uma redução de 20,66% entre os anos de 1985 e 2020, dando espaço para outros tipos de fragmentos, em especial a pastagem, que teve um aumento de 172% nos mesmos anos. Essa classe passa a ser a predominante a partir do ano de 2020, conforme indica o diagrama de Sankey Figura 5. Já área urbanizada, que mostra um crescimento constante ao longo dos mosaicos, aumentou 192,11% em diferenças percentuais no intervalo entre 1985 e 2020, o que corresponde a uma ampliação da classe em torno de 101 km<sup>2</sup> (1985) para 294 km<sup>2</sup> (2020). As áreas de corpos d'água na bacia são em média iguais a 39 km<sup>2</sup> ao longo dos três anos. O ano de 2005 tem um valor maior dessa classe (55 km<sup>2</sup>) devido a contribuição do reservatório Jucazinho, que entrou em operação a partir de 1998. Em 2020 as áreas de corpos d'água são reduzidas devido, principalmente, ao mesmo reservatório, que entrou em colapso no ano de 2015 e desde então apresenta problemas com o aporte hídrico.

Figura 4 - Classes do uso e ocupação do solo da bacia do Capibaribe referente aos anos de 1985, 2005 e 2020.



Fonte: MapBiomias (2023).

Figura 5 - Transições das principais classes do uso e ocupação do solo da bacia do Capibaribe referente aos anos de 1985, 2005 e 2020.



Fonte: MapBiomias (2023).

## 3.2 O MODELO SWAT

O modelo SWAT inclui como principais componentes as propriedades do clima, a hidrologia, a temperatura do solo, o crescimento das plantas, os nutrientes, os sedimentos, o manejo do solo, além de pesticidas, bactérias e patógenos (Ferrigo, 2014). No modelo, o ciclo hidrológico é fundamentado em duas fases principais, a terrestre e a da água. A fase terrestre controla a quantidade de água, sedimentos, nutrientes e pesticidas transportados para o canal principal em cada sub-bacia. A fase da água é a fase do ciclo hidrológico que pode ser definida pela propagação dos elementos aquáticos por meio da rede de canais da bacia até o seu exutório (Neitsch *et al.*, 2011).

Nesta seção são descritas, de forma resumida, algumas das equações das fases terrestre e da água relacionadas aos processos de escoamento superficial. O detalhamento das equações do modelo SWAT pode ser consultado em Neitsch *et al.* (2011).

### 3.2.1 Fase da terra

O modelo utiliza quatro volumes de controle para fundamentar a sua estrutura no balanço hídrico. São esses os reservatórios superficial, sub-superficial, subterrâneo raso ou livre e subterrâneo profundo. Dessa forma, a equação do balanço hídrico no modelo é a seguinte:

$$SW_t = SW_0 \sum_{t=1}^t (P_d - Q_{sup} - E_a - w_{vad} - Q_{sub}) \quad (1)$$

sendo  $SW_t$  a quantidade de água no solo no fim do dia (mm);  $SW_0$  é a quantidade de água no início do dia (mm);  $t$  é o tempo (dias);  $P_d$  é a precipitação no dia (mm);  $Q_{sup}$  representa o escoamento superficial (mm);  $E_a$  é a quantidade de água que evapotranspirou no dia (mm);  $w_{vad}$  é a quantidade de água que entrou na zona vadosa no dia (mm); e  $Q_{sub}$  é a quantidade de água que alcança o aquífero subterrâneo (mm).

Nessa fase, o balanço hídrico é calculado para cada HRU identificada, proporcionando uma melhor precisão e, conseqüentemente, uma maior representatividade física dos processos que ocorrem na bacia.

### 3.2.2 Escoamento superficial

O modelo SWAT fornece dois métodos para o cálculo do escoamento superficial: o Método de Curva Número (CN) (SCS, 1972) e o método de infiltração de Green e Ampt (1911), utilizado quando existem dados subsidiários de precipitação. Nesta pesquisa, o método CN foi adotado devido a disponibilidade dos dados diários de chuva, além de ser o método mais utilizado em estudos com o modelo SWAT, em razão da sua simplicidade, estabilidade e eficiência das previsões (Carvalho NETO, 2018; Zhang *et al.*, 2009).

A equação do escoamento superficial utilizando o método da Curva Número (CN) é dada da seguinte forma:

$$Q_{sup} = \frac{(P_{dia} - 0,2S)^2}{(P_{dia} + 0,8S)} \quad (2)$$

em que,  $Q_{sup}$  é o escoamento superficial (mm),  $P$  é a precipitação (mm) e  $S$  é a capacidade máxima de armazenamento (mm).

O parâmetro  $S$  varia espacialmente, em função das mudanças no tipo, uso e cobertura, manejo e declividade do solo, e das condições prévias de umidade (Neitsch *et al.*, 2011). Para a sua determinação é necessário o fator CN, que é dado pela seguinte equação (em unidades métricas):

$$S = 25,4 \left( \frac{100}{CN} - 10 \right) \quad (3)$$

O fator CN é determinado diariamente, no modelo SWAT, variando numericamente de 1 a 100, sendo o limite inferior representativo de um solo totalmente permeável e o limite superior de um solo que converterá toda a precipitação em escoamento (totalmente impermeável) (Neitsch *et al.*, 2011).

O valor do CN pode ser corrigido em função da umidade antecedente do solo, em que a CN I indica uma condição de seca, CN II uma condição normal e CN III uma condição úmida (Neitsch *et al.*, 2011). O cálculo do CN II e III é obtido através das equações:

$$CN_I = CN_{II} - \frac{20(100 - CN_{II})}{(100 - CN_{II} + \exp[2,533 - 0,0636(100 - CN_{II})])} \quad (4)$$

$$CN_{III} = CN_{II} \cdot \exp[0,00673 \cdot (100 - CN_{II})] \quad (5)$$

Havendo a ocorrência do escoamento superficial, o modelo SWAT o propaga entre as sub-bacias e calcula a vazão de pico. Essa variável é considerada como o fluxo máximo do escoamento superficial, para um determinado evento de precipitação, sendo um indicador do potencial erosivo utilizado no cálculo da produção de sedimento para determinado evento (Neitsch *et al.*, 2011). No SWAT, a vazão de pico é calculada para cada sub-bacia através do método racional modificado, conforme a seguinte equação:

$$Q_{pico} = \frac{\alpha_{tc} \cdot Q_{sup} \cdot A}{3,6 \cdot t_{conc}} \quad (6)$$

em que,  $Q_{pico}$  é a vazão de pico ( $m^3 s^{-1}$ ),  $\alpha_{tc}$  a fração da precipitação diária que ocorre durante o tempo de concentração,  $Q_{sup}$  o escoamento superficial (mm),  $A$  é a área da sub-bacia ( $km^2$ ),  $t_{conc}$  é o tempo de concentração (h) e 3,6 o fator de conversão de unidades.

O tempo de concentração ( $t_{conc}$ ) da sub-bacia é calculado somando-se o tempo de concentração do escoamento sobre a superfície do solo (tempo necessário para o escoamento deslocar-se do ponto mais remoto da bacia até o curso d'água) e o tempo de concentração do escoamento no curso d'água (tempo para o escoamento se deslocar no curso d'água até a foz) (Carvalho Neto; Srinivasan; Rufino, 2011):

$$t_{conc} = t_{sup} + t_{canal} \quad (7)$$

sendo  $t_{sup}$  o tempo de deslocamento do escoamento sobre a superfície do solo (h) e  $t_{canal}$  o tempo de deslocamento do escoamento no curso d'água (h).

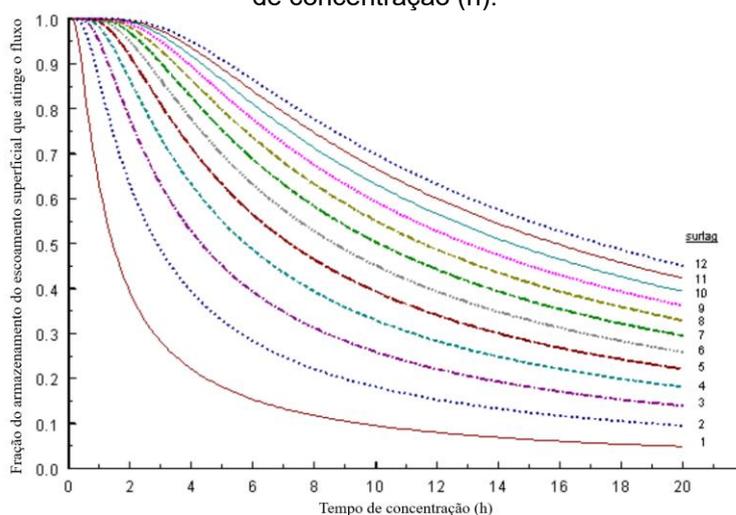
O modelo inclui um recurso de armazenamento do escoamento superficial com o intuito de simular seu retardamento até o canal principal. Como o escoamento superficial é determinado, o volume de água que chega ao canal principal é dado por:

$$Q_{sup} = (Q'_{sup} + Q_{arm,i-1}) \cdot \left[ 1 - \exp\left(-\frac{Surlag}{t_{conc}}\right) \right] \quad (8)$$

em que  $Q_{sup}$  é a quantidade de água que chega ao canal principal por escoamento superficial (mm);  $Q'_{sup}$  diz respeito à quantidade de água gerada em alguma sub-bacia no dia (mm);  $Q_{arm,i-1}$  a quantidade de água em atraso, gerada no dia anterior (mm); e  $Surlag$  o coeficiente de retardo do escoamento superficial, e  $t_{conc}$  é o tempo de concentração (horas).

O segundo termo do lado direito da equação representa a fração do total do volume ao qual será permitido alcançar o canal em um dia. O valor de *Surlag* rege tal fração de modo que quanto maior, menos água será mantida armazenada (Carvalho Neto; Srinivasan; Rufino, 2011). No gráfico abaixo são plotados diferentes valores de *Surlag* e  $t_{conc}$  utilizando o termo mencionado anteriormente.

Figura 6 - Diferentes valores de *Surlag* em função da retenção do escoamento superficial e o tempo de concentração (h).



Fonte: Adaptado de Neitch *et al.* (2011)

### 3.2.3 Evapotranspiração

O modelo SWAT expressa a evapotranspiração de forma completa, iniciando com a estimativa da evapotranspiração potencial (ETp), que posteriormente é ajustada para representar a evapotranspiração real (ETa), considerando a disponibilidade hídrica no solo. Dessa forma, incorpora processos como evaporação do solo e da copa das árvores, transpiração das plantas e sublimação.

A evapotranspiração potencial pode ser calculada pelo modelo utilizando os métodos de Penman-Monteith (Monteith, 1965), Priestley-Taylor (Priestley; Taylor, 1972) ou Hargreaves (Hargreaves; Samani, 1982). A obtenção de estimativas mais corretas dessa variável requer dados médios climáticos mensais referentes ao período da simulação. Há também a possibilidade de inserir os dados já observados da evapotranspiração, obedecendo o período da simulação. Neste estudo o método de Penman-Monteith foi adotado para a estimativa da evapotranspiração potencial, conforme recomendado por Smith (1991). A equação de Penman-Monteith é dada por:

$$\lambda E = \frac{\Delta \cdot (H_{net} - G) + \rho_{air} \cdot c_p \cdot [e_z^0 - e_z]/r_a}{\Delta + \gamma \cdot (1 + r_c/r_a)} \quad (9)$$

sendo  $\lambda$  o calor latente de vaporização ( $\text{MJ kg}^{-1}$ );  $E$  a profundidade da taxa de evaporação ( $\text{mm/dia}$ ),  $\Delta$  a declividade da curva de pressão de saturação do ar ( $\text{kPa } ^\circ\text{C}^{-1}$ ),  $H_{net}$  a radiação líquida ( $\text{MJ m}^{-2} \text{ d}^{-1}$ ),  $G$  o fluxo de calor no solo ( $\text{MJ m}^{-2} \text{ d}^{-1}$ ),  $\gamma$  é a constante psicrométrica ( $\text{kPa } ^\circ\text{C}^{-1}$ ),  $\rho_{air}$  a densidade do ar ( $\text{kg m}^{-3}$ ),  $C_p$  é o calor específico ( $\text{MJ kg}^{-1} ^\circ\text{C}^{-1}$ ),  $e_z^0$  a pressão de saturação do ar à altura  $z$  ( $\text{kPa}$ ),  $e_z$  a pressão de vapor atual à altura  $z$  ( $\text{kPa}$ ),  $r_c$  a resistência do dossel ( $\text{s m}^{-1}$ ) e  $r_a$  a resistência aerodinâmica ( $\text{s m}^{-1}$ ).

Após a determinação da evapotranspiração potencial, o modelo busca estimar a evapotranspiração real considerando três processos: a demanda evaporativa da precipitação interceptada pela cobertura vegetal, a transpiração dos vegetais e a evaporação do solo.

Quanto à interceptação, a copa dos vegetais é um fator que pode afetar diretamente a resposta dos processos de infiltração, escoamento superficial e evapotranspiração. Quando a chuva cai, a interceptação pelas plantas reduz a energia erosiva das gotas e armazena uma parte da precipitação no dossel (Santos, 2015). Essa variável é calculada considerando a densidade da cobertura vegetal e a morfologia das espécies de plantas. Desse modo, a quantidade máxima de água que pode ser armazenada nas copas é calculada por:

$$can_{dia} = Canmx \cdot \frac{IAF}{IAF_{max}} \quad (10)$$

sendo  $can_{dia}$  a quantidade máxima de água interceptada e armazenada no dossel em um determinado dia ( $\text{mm}$ ),  $Canmx$  a quantidade máxima de água que pode ser interceptada e armazenada no dossel quando este está totalmente desenvolvido ( $\text{mm}$ ),  $IAF$  o índice de área foliar para um determinado dia, e  $IAF_{max}$  o índice de área foliar máximo para a planta.

Toda a água presente no dossel encontra-se prontamente disponível para a remoção por evaporação. A quantidade de evapotranspiração real da chuva interceptada é especialmente significativa em florestas onde, em alguns casos, a evaporação da precipitação interceptada é maior do que a transpiração (Neitsch *et al.*, 2011).

O SWAT remove o máximo de água possível do armazenamento do dossel ao calcular a evaporação real. O modelo considera que o volume interceptado está disponível para evapotranspiração sob as seguintes condições (com todas as variáveis possuindo como unidade “mm”) (Santos, 2015):

1. Se evapotranspiração potencial ( $E_0$ ) for menor que a quantidade de água interceptada no dossel ( $R_{int}$ ), então a quantidade de água interceptada no dia ( $R_{int(f)}$ ) será resultado da subtração da quantidade de água interceptada no início do intervalo de tempo ( $R_{int(i)}$ ) pela evapotranspiração potencial (ou diretamente a evaporação da quantidade de água livre existente no dossel da planta em um determinado dia –  $E_{can}$ ):

$$E_a = R_{can} = E_0 \rightarrow R_{int(f)} = R_{int(i)} - E_{can} \quad (11)$$

sendo  $E_a$  a evapotranspiração real na bacia em um determinado dia (mm).

2. Na segunda condição, caso a evapotranspiração potencial for superior à quantidade de água armazenada na copa, toda lâmina interceptada será evaporada:

$$E_{can} = R_{int(i)} \rightarrow R_{int(f)} = 0 \quad (12)$$

Quando a equação de Penman-Monteith é selecionada como método de evapotranspiração potencial, como foi o caso desse estudo, a transpiração é calculada com base nas equações utilizadas pelo método (Neitsch *et al.*, 2011).

Já em relação a estimativa da evaporação de água no solo, o modelo utiliza uma função exponencial obedecendo a profundidade do solo e a quantidade de água existente. Quando existe uma demanda de evaporação da água do solo, o SWAT primeiro particiona a demanda evaporativa entre as diferentes (Ferrigo, 2014). A distribuição da profundidade utilizada para determinar a quantidade máxima de água a ser evaporada é dada por:

$$E_{solo,z} = E_z'' \cdot \frac{z}{(z + \exp(2,374 - 0,00713 \cdot z))} \quad (13)$$

sendo  $E_{solo,z}$  a demanda evaporativa (mm) na profundidade  $z$ ,  $E_z''$  a evaporação máxima do solo para o dia (mm) e  $z$  é a profundidade do solo (mm). A quantidade de demanda evaporativa para uma camada de solo é determinada pela diferença entre as demandas evaporativas calculadas nos limites superior e inferior da camada do solo:

$$E_{solo,ly} = E_{solo,zl} - E_{solo,zu} \quad (14)$$

sendo  $E_{solo,ly}$  a demanda evaporativa para a camada  $ly$  (mm),  $E_{solo,zl}$  a demanda evaporativa do limite inferior da camada do solo, e  $E_{solo,zu}$  a demanda evaporativa do limite superior da camada do solo.

Visando uma melhoria na estimativa da distribuição da evaporação, o coeficiente de compensação da evaporação do solo ( $E_{sco}$ ) foi incorporado à Equação (15), permitindo que o usuário faça modificações na distribuição da profundidade utilizada para atender a demanda evaporativa do solo, resultado no seguinte formato:

$$E_{solo,ly} = E_{solo,zl} - E_{solo,zu} \cdot E_{sco} \quad (15)$$

O coeficiente de compensação da evaporação do solo ( $E_{sco}$ ) rege a extração de demanda evaporativa das camadas inferiores do solo, de modo que, quanto menor seu for o valor, mais água será retirada de profundidades maiores de solo. Os valores desse parâmetro podem variar entre 0,01 e 1.

### 3.2.4 Percolação

O processo ocorre considerando duas condições, a primeira é a partir da propagação do armazenamento de água e a segunda pelo fluxo por fendas presentes no solo. A primeira condição é calculada para cada horizonte, uma vez que o volume de água excede a capacidade de campo do solo desde que a camada seguinte não esteja saturada. O volume de água disponível na camada do solo para a percolação deve obedecer às seguintes condições:

$$SW_{cam,excesso} = SW_{cam} = FC_{cam} \text{ se } SW_{cam} > FC_{cam} \quad (16)$$

$$SW_{cam,excesso} = 0 \text{ se } SW_{cam} \leq FC_{cam} \quad (17)$$

sendo  $SW_{cam,excesso}$  a quantidade de água disponível para percolar no dia (mm),  $SW_{cam}$  a quantidade diária de água em uma determinada camada do solo (mm) e  $FC_{cam}$  a quantidade de água na capacidade de campo (mm). A quantidade de água que efetivamente se moverá para a camada de solo inferior é estimada por:

$$W_{perc,cam} = SW_{cam,excesso} \left( 1 - \exp \left[ \frac{-\Delta T}{TT_{perc}} \right] \right) \quad (18)$$

em que,  $W_{perc,cam}$  é a quantidade de água que efetivamente percola no dia (mm);  $\Delta T$  é a duração do intervalo de tempo (h); e  $TT_{perc}$  é o tempo de percolação entre as camadas (h).

A obtenção do tempo de percolação entre as camadas do solo é calculada por:

$$TT_{perc} = \frac{SAT_{cam} - FC_{cam}}{K_{sat}} \quad (19)$$

onde,  $SAT_{cam}$  é a quantidade de água no solo completamente saturado (mm) e  $K_{sat}$  é a condutividade hidráulica saturada (mm/h). A água que percola abaixo da última camada do solo entra na zona vadosa, para só depois adentrar no aquífero subterrâneo.

### 3.2.4.1 Escoamento sub-superficial lateral

O fluxo lateral é estimado por meio de um modelo de armazenamento cinético, desenvolvido por Sloan *et al.* (1983), em paralelo com o processo de percolação, considerando uma profundidade de até 2 m. O cálculo se baseia na equação da continuidade de massa:

$$Q_{lat} = 0,024 \left( \frac{2 \cdot SW_{cam,excesso} \cdot K_{sat} \cdot slp}{\Phi_d \cdot L_{slp}} \right) \quad (20)$$

sendo  $Q_{lat}$  o escoamento lateral (mm/dia);  $SW_{cam,excesso}$  o volume de água drenável armazenada na zona saturada da encosta por unidade de área (mm);  $slp$  a declividade da encosta (m/m);  $\Phi_d$  a porosidade drenável do solo (mm/mm); e  $L_{slp}$  é o comprimento da encosta (m).

Lelis *et al.* (2012) destacam que o fluxo lateral pode ser significativo em áreas com solos de elevada condutividade hidráulica nas camadas superficiais e nas camadas impermeáveis, em profundidades rasas. Nesses sistemas, a precipitação percola verticalmente até atingir a camada impermeável, favorecendo o acúmulo de água e gerando uma zona saturada. A formação dessa zona pode contribuir para a vazão de rios através do aporte de água direcionado para o fluxo lateral subsuperficial.

### 3.2.5 Águas subterrâneas

Para a estimativa da quantidade de água que percola e pode recarregar os aquíferos rasos e profundos, sem que haja perdas por capilaridade, é utilizada a seguinte equação:

$$W_{rec} = \left( 1 - \exp \left[ \frac{-1}{\delta_{aq}} \right] \right) W_{seep} + \exp \left[ \frac{-1}{\delta_{aq}} \right] W_{rec,i-1} \quad (21)$$

sendo  $W_{rec}$  a quantidade de água que adentra os aquíferos no dia  $i$  (mm);  $\delta_{aq}$  o tempo de drenagem sob as camadas de solo (dia);  $W_{seep}$  a quantidade de água que percolou através da última camada de solo (mm); e  $W_{rec,i-1}$  a quantidade de água que entra no aquífero no dia  $i-1$  (mm).

Dessa forma, o SWAT regula a quantidade de água que recarrega o aquífero profundo através da seguinte relação:

$$W_{prf} = \beta_{prf} \cdot W_{rec} \quad (22)$$

onde  $W_{prf}$  é a quantidade de água (mm) que entra no aquífero profundo no dia  $i$  e  $\beta_{prf}$  é o coeficiente de percolação do aquífero. Assim, a quantidade de água destinada ao aquífero raso é dado por:

$$W_{rec,rs} = W_{rec} \cdot W_{prf} \quad (23)$$

sendo  $W_{rec,rs}$  a quantidade de água (mm) que entra no aquífero raso no dia  $i$ .

Por último, o balanço hídrico no aquífero raso é dado pela equação:

$$aq_{rs,i} = aq_{rs,i-1} + W_{rec,rs} - Q_{aq} - W_{revap} - W_{bomba,rs} \quad (24)$$

onde  $aq_{rs,i}$  é a quantidade de água armazenada no aquífero raso no dia (mm);  $aq_{rs,i-1}$  é a quantidade de água armazenada no aquífero raso no dia  $i-1$  (mm);  $W_{rec,rs}$  é a quantidade de água que recarrega o aquífero raso no dia (mm);  $Q_{aq}$  é o escoamento subterrâneo que recarrega o canal principal (fluxo de base) (mm);  $W_{revap}$  é a quantidade de água que ascende por franjas capilares (mm); e  $W_{bomba,rs}$  é a quantidade de água retirada através de bombas (mm).

Em relação ao volume de água no solo que ascende por capilaridade, em função da demanda evaporativa, o SWAT incorpora o processo “Revap” ( $W_{revap}$ ). Esse processo não é contabilizado no volume evapotranspirado pelo solo ou transpirado pelos vegetais, sendo de fundamental importância em bacias onde a zona saturada

encontra-se próxima a superfície ou há raízes profundas (Carvalho Neto, 2018). Dessa forma, a máxima quantidade de água que poderá ser retirada via *Revap* é dada por:

$$W_{revap,max} = \beta_{rev} \cdot E_0 \quad (25)$$

sendo  $W_{revap,max}$  a máxima quantidade de água (mm) que ascende em resposta ao déficit hídrico,  $\beta_{rev}$  o coeficiente de *Revap* e  $E_0$  o potencial de evapotranspiração (mm) daquele dia.

A quantidade de água na qual efetivamente passa por tal processo é determinada pelas seguintes condições.

$$1. W_{revap} = 0 \text{ se } aq_{rs} \leq aq_{lim,rv} \quad (26)$$

$$2. W_{revap} = W_{revap,max} - aq_{lim,rv} \text{ se } aq_{lim,rv} < aq_{rs} < (aq_{lim,rv} + W_{revap,max}) \quad (27)$$

$$3. W_{revap} = W_{revap,max} \text{ se } aq_{lim,rv} \geq (aq_{lim,rv} + W_{revap,max}) \quad (28)$$

onde  $aq_{rs}$  é a quantidade de água armazenada no aquífero raso (mm) e  $aq_{lim,rv}$  é o valor limite do nível de água a ser superado para ocorrer o processo *Revap* (mm).

### 3.2.6 Cobertura vegetal

No modelo SWAT, é utilizada uma versão simplificada do modelo EPIC (Environmental Policy Integrated Climate Model) para simular o crescimento das plantas, onde o desenvolvimento delas ocorre em função de unidades de calor, assumindo que cada espécie possui uma temperatura de base, abaixo da qual não se desenvolve; uma temperatura ótima; e uma temperatura máxima, que, quando alcançada, também faz cessar o crescimento (Freire, 2019). Um valor de unidades de calor é estipulado para que a planta alcance a maturidade. Esta será atingida quando a soma das diferenças entre as temperaturas médias diárias e a temperatura de base da planta alcançar o valor de unidade de calor estabelecido (Carvalho Neto, 2018). De acordo com Neitsch *et al.* (2011), o modelo de crescimento das plantas é utilizado para avaliar a retirada da água e dos nutrientes das zonas das raízes, transpiração e produção/resultado da biomassa.

### 3.2.7 Fase de água ou de propagação

#### a) Propagação da vazão líquida no canal

O modelo utiliza o método de armazenamento variável, desenvolvido por Williams (1969), que considera um canal com seção trapezoidal, a vazão e a velocidade calculadas a partir da equação de Manning. O tempo de propagação é obtido através da razão entre o comprimento do curso d'água e a velocidade de escoamento. Assim, o volume armazenado no trecho é dado por:

$$\Delta_{arm} = V_{in} - V_{out} \quad (29)$$

sendo  $\Delta_{arm}$  o volume armazenado no trecho ( $m^3$ );  $V_{in}$  e  $V_{out}$  são os volumes de entrada e saída no segmento ( $m^3$ ).

O volume de água que sai do trecho em um determinado intervalo de tempo é dado por:

$$V_{out,2} = SC(V_{in} + V_{arm1}) \quad (30)$$

onde  $V_{out,2}$  é o volume que sai do trecho no fim do intervalo de tempo ( $m^3$ );  $SC$  é o coeficiente de armazenamento;  $V_{in}$  é o volume de água que entra no início do intervalo de tempo ( $m^3$ ); e  $V_{arm,1}$  é o volume armazenado no início do intervalo de tempo ( $m^3$ ).

O coeficiente de armazenamento ( $SC$ ) é dado por:

$$SC = \left( \frac{2 \cdot \Delta T}{2 \cdot TT + \Delta T} \right) \quad (31)$$

sendo  $\Delta T$  o intervalo de tempo, e a variável  $TT$  (s) diz respeito ao “tempo de viagem”, encontrado através da divisão entre o volume armazenado e o fluxo de saída. A variável  $TT$  é indicada por:

$$TT = \left( \frac{V_{arm}}{q_{out}} \right) = \left( \frac{V_{arm,1}}{q_{out,1}} \right) = \left( \frac{V_{arm,2}}{q_{out,2}} \right) \quad (32)$$

em que  $V_{arm}$ ,  $V_{arm,1}$  e  $V_{arm,2}$  são os volumes armazenados no tempo ( $m^3$ );  $q_{out}$ ,  $q_{out,1}$  e  $q_{out,2}$  são as vazões de saída no tempo ( $m^3/s$ ).

#### b) Propagação da vazão sólida no canal

O transporte de sedimentos considera os componentes dos processos de deposição e degradação, operados simultaneamente no canal. Sucintamente, através da definição de potência de escoamento, a quantidade máxima de sedimentos que

pode ser transportada em um segundo é função da velocidade de pico no curso d'água. O modelo calcula esses processos a partir de uma adaptação do método de potência do fluxo proposto por Bagnold (1977). Inicialmente, a quantidade máxima de sedimentos que pode ser transportada pelo fluxo em algum trecho do rio é obtida por:

$$conc_{sed, mx} = c_{sp} \cdot V_{pc}^{spexp} \quad (33)$$

sendo  $conc_{sed, mx}$  a concentração máxima de sedimentos que pode ser transportada pela água (ton/m ou kg/L);  $V_{pc}$  é a velocidade de pico (m/s); e  $C_{sp}$  e  $spexp$  são coeficientes de ajuste. O coeficiente linear pode variar entre 0,0001 e 0,01, enquanto o  $spexp$  pode assumir valores entre 1 e 2.

Caso a concentração máxima de sedimentos ( $conc_{sed, mx}$ ) for menor que a concentração de sedimentos no início do processo,  $conc_{sed, 0} > conc_{sed, mx}$ , tem-se o começo de deposição predominado e estimado por:

$$sed_{dep} = (conc_{sed, 0} - conc_{sed, mx}) \cdot V_{pc} \quad (34)$$

sendo  $sed_{dep}$  (t) a quantidade de sedimentos depositado no segmento do canal,  $conc_{sed, 0}$  (kg/L ou t/m<sup>3</sup>) a concentração no início do intervalo de tempo,  $conc_{sed, mx}$  a concentração máxima de sedimentos que pode ser transportado pela água (t/m<sup>3</sup>), e  $V_{pc}$  o volume de água que passa no segmento (m<sup>3</sup>).

Quando a concentração atual é inferior à concentração máxima possível, predomina o processo de erosão, sendo esse estimado através de:

$$sed_{ero} = (conc_{sed, mx} - conc_{sed, 0}) \cdot V_{pc} \cdot K_{ca} \cdot C_{ca} \quad (35)$$

onde  $sed_{ero}$  é a quantidade de sedimentos que é degradada (t);  $K_{ca}$  é o fator de erodibilidade do canal (cm/hr<sup>-1</sup>Pa<sup>-1</sup>) e  $C_{ca}$  é o fator de cobertura do canal.

O fator de erodibilidade do canal é considerado normalmente com uma ordem de magnitude menor que o valor de erodibilidade do solo (Neitsch *et al.*, 2005), enquanto o fator de cobertura do canal busca estimar a proteção do leito devido à existência de vegetação. Após a estimativa da quantidade de sedimentos depositada e erodida, o SWAT estima a quantidade de partículas que propagam no trecho através das equações:

$$sed_{at} = sed_{sed, 0} - sed_{dep} + sed_{ero} \quad (36)$$

$$sed_{out} = sed_{at} \cdot \frac{V_{out}}{V_{ca}} \quad (37)$$

sendo  $sed_{at}$  a quantidade de sedimentos em suspensão no canal (ton),  $sed_{sed,0}$  a quantidade de sedimentos no início do processo no segmento (ton),  $sed_{dep}$  a quantidade de sedimentos depositado no segmento do canal (ton),  $sed_{ero}$  a quantidade de sedimentos erodido (ton),  $sed_{out}$  a concentração de sedimentos que sai do trecho (t),  $V_{out}$  o volume que sai no intervalo de tempo ( $m^3$ ) e  $V_{ca}$  diz respeito ao volume de água no trecho ( $m^3$ ).

### 3.2.8 Reservatórios

Quanto à presença de reservatórios para a representação da região hidrográfica na modelagem, são necessários alguns dados mínimos requisitados pelo SWAT. A partir desses dados, listados abaixo, são realizadas as estimativas a respeito da contribuição da precipitação incidente, da evaporação e da infiltração no leito dos reservatórios.

RES\_SUB: indicação a qual sub-bacia o reservatório é vinculado;

IYRES: ano ao qual o reservatório tornou-se operacional;

RES\_ESA: área do espelho d'água quando o reservatório possui a cota do sangradouro de emergência [ha];

RES\_EVOL: volume de água necessário para encher o reservatório até o nível do sangradouro de emergência [ $10^4 m^3$ ];

RES\_PSA: área do espelho d'água quando o reservatório possui a cota do sangradouro principal [ha];

RES\_PVOL: volume de água necessário para encher o reservatório até o nível do sangradouro principal [ $10^4 m^3$ ];

RES\_VOL: volume inicial para o período da simulação e,

RES\_RR: vazão média liberada pelo reservatório [ $m^3 s^{-1}$ ].

A partir da utilização desses parâmetros, o SWAT consegue estimar a quantidade de água liberada diariamente. Todavia, também é possível incluir dados da vazão regularizada, em escala diária ou mensal.

### 3.3 BANCO DE DADOS DA MODELAGEM NO SWAT

Para a etapa de modelagem utilizando o SWAT, é necessária uma grande quantidade de informações geoespaciais e dados referentes as condições climáticas da região de interesse. Dados de entrada, como o modelo digital de elevação (MDE), o mapa de tipo de solo e o mapa de uso e ocupação do solo, são exemplos das informações geoespaciais exigidas pelo modelo. Também é necessário a entrada de um banco de dados da série histórica climatológica da bacia, de forma organizada, com informações da precipitação (mm), da temperatura máxima e mínima (°C), da radiação solar ( $\text{MJ m}^{-2}$ ), da velocidade do vento ( $\text{m s}^{-1}$ ) e da umidade relativa (%). Ademais, neste estudo foram inseridos dados complementares da estrutura dos principais reservatórios da região, como forma de melhorar a representação hidrológica da bacia no SWAT.

A aquisição dos dados, a calibração e a validação do modelo, está sendo realizada em conjunto com o Sistema de Unidades de Respostas Hidrológicas para as bacias hidrográficas de Pernambuco (SUPer). O projeto corresponde a um sistema interativo de modelagem hidrológica e de qualidade de água que utiliza como mecanismo de modelagem a ferramenta de avaliação do solo e da água do SWAT. Foi desenvolvido através da parceria entre a UFPE, UFRPE, UFCG, ITEP e a Texas A&M University com o intuito de auxiliar na tomada de decisões econômicas e políticas, a partir de simulações em tempo real, e a curto, médio e longo prazo, diante dos possíveis impactos das mudanças climáticas nos recursos hídricos de Pernambuco.

Os tópicos seguintes apresentam as informações detalhadas dos diferentes dados de entrada que estão sendo utilizados para a modelagem da bacia do rio Capibaribe no modelo SWAT.

#### 3.3.1 Modelo digital de elevação (MDE)

Para a representação do relevo e delimitação automatizada da bacia, o projeto SUPer utiliza o modelo digital de elevação obtido do projeto TOPODATA (<http://www.dsr.inpe.br/topodata>) do Instituto Brasileiro de Pesquisas Espaciais (INPE), em formato de imagem, com resolução espacial de 30 m e valores de altitude (m).

O processo de delimitação automatizado foi realizado por meio do ArcSWAT, que divide a bacia em sub-bacias a partir do relevo e da geração da rede de drenagem. Com o MDE, também são calculadas as informações referentes aos parâmetros físicos das sub-bacias, como a área, a declividade média e a elevação (média, máxima e mínima).

### **3.3.2 Dados do solo e cobertura da terra**

O projeto SUPer utiliza dois bancos de dados especializados referentes às características dos solos da bacia: o mapeamento do banco de dados do Instituto Brasileiro de Geografia e Estatística (IBGE), que possui escala de 1:250.000, disponível em <https://downloads.ibge.gov.br/>; e o banco de dados do Sistema de Informação de Solos Brasileiros, da EMBRAPA Solos, que disponibiliza informações sobre as características morfológicas, físicas, químicas e mineralógicas para cada tipo de solo no Brasil (Farias *et al.*, 2023; Galvíncio, Queiroga Miranda, da Luz, 2024).

Quanto às informações especializadas referentes ao uso e cobertura do solo, o projeto utiliza a base de dados do IBGE referente ao ano de 2014, em formato de mapa, com escala de 1:100.000 e disponível em <https://www.ibge.gov.br/geociencias/downloads-geociencias.html>.

### **3.3.3 Dados climáticos**

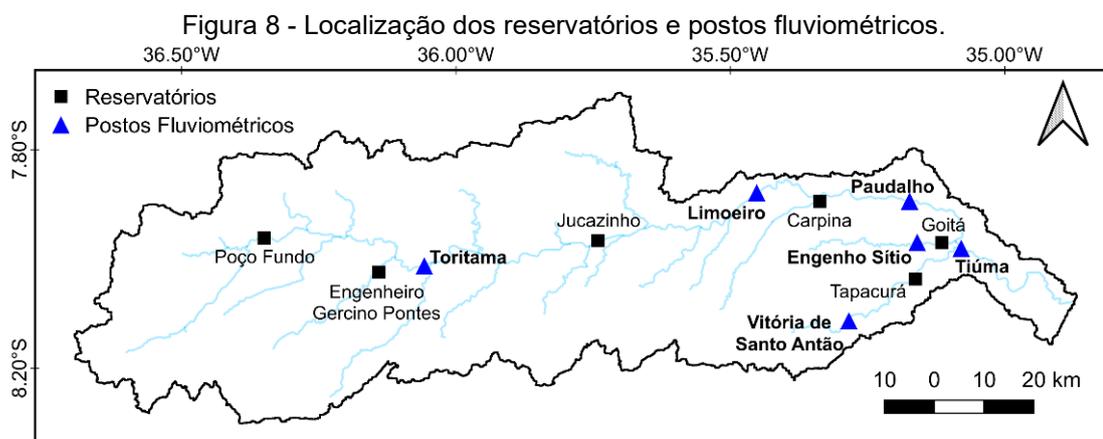
O banco de dados climáticos utilizado no projeto foi obtido da Agência Pernambucana de Águas e Clima (APAC), referente aos postos pluviométricos, e do Instituto Nacional de Meteorologia (INMET), para a série de dados meteorológicos (Figura 7). A série corresponde aos anos de 1961 a 2021, com resolução temporal diária. Dados de radiação global, umidade relativa do ar, temperaturas máxima e mínimas do ar e velocidade do vento, foram adquiridos das duas únicas estações meteorológicas do INMET, localizadas nos municípios de Surubim e Recife. Já para os dados de precipitação, os postos pluviométricos utilizados no projeto distribuem-se bem especializados por toda a área da bacia, como pode ser observado na Figura 7.



Fonte: O autor (2024).

### 3.3.4 Postos fluviométricos e reservatórios

Para o processo de calibração e validação do modelo hidrológico, foram utilizados dados de seis postos fluviométricos na bacia, de responsabilidade da Agência Nacional de Águas e Saneamento (ANA), indicados na Figura 8. Na bacia, ainda existem outros postos de monitoramento de vazão, contudo, devido às falhas e inconsistência das séries, optou-se neste estudo pela seleção de postos com dados com período histórico relativamente bom (maior que 20 anos) e com o mínimo de falhas. Informações adicionais sobre a código e o período dos postos utilizados são descritas na Tabela 2.



Fonte: O autor (2024).

Tabela 2 - Identificação das estações fluviométricas utilizadas.

<b>Código</b>	<b>Nome (sub-bacia)</b>	<b>Latitude</b>	<b>Longitude</b>	<b>Série utilizada</b>
39130000	Toritama (36)	-8,012	-36,057	(1974 – 2007)
39145000	Limoeiro (5)	-7,878	-35,451	(1973 – 2010)
39150000	Paudalho (3)	-7,894	-35,173	(1966 – 2016)
39155000	Engenho Sítio (21)	-7,969	-35,159	(1967 – 1993)
39170000	Vitória de Sto. Antão (48)	-8,113	-35,283	(1969 – 2011)
39185000	Tiúma (23)	-7,980	-35,079	(1973 – 2012)

Fonte: ANA e APAC (2024).

Além dos dados fluviométricos, também foram inseridos no projeto seis reservatórios localizados na bacia (Figura 8). As informações como o início de operação, área e volume do reservatório na cota principal e coroamento (Tabela 3), necessárias no modelo, foram obtidas do banco de dados da Agência Pernambucana de Águas e Clima (APAC). Os valores da condutividade hidráulica do fundo do reservatório, RES\_K, foram obtidos através do processo de calibração. Como o RES\_K representa as perdas por infiltração de cada reservatório, o ajuste do parâmetro foi realizado individualmente para as sub-bacias onde os reservatórios estão localizados.

Tabela 3 - Principais informações dos reservatórios utilizados no projeto.

<b>Reservatórios (Sub-bacia)</b>	<b>IYRES</b>	<b>RES_ESA (ha)</b>	<b>RES_EVOL (10<sup>4</sup> m<sup>3</sup>)</b>	<b>RES_PSA (ha)</b>	<b>RES_PVOL (10<sup>4</sup> m<sup>3</sup>)</b>	<b>RES_K (mm h<sup>-1</sup>)</b>
Carpina (4)	1978	2.482,52	28.372,88	2.362,4	27.000	0,44
Goitá (17)	1978	813,71	7.197,59	641,79	5.253,55	0,60
Jucazinho (22)	1998	1.986,25	44.899,84	1.599,65	32.703,58	0,13
Poço Fundo (25)	1987	1.543	9.722	764	2.775	0,53
Tapacurá (46)	1978	1.279,41	15.738,05	963,23	9.360	0,36
Eng. Gercino Pontes (51)	1958	171,74	1.444,94	145,33	1.122,47	0,63

Fonte: ANA e APAC (2024).

### 3.4 ETAPAS DE EXECUÇÃO DO MODELO SWAT

A série escolhida para o estudo dos processos hidrológicos na bacia do Capibaribe compreendeu os dados climáticos referentes aos anos de 1961 a 2020, com um período de aquecimento referente aos cinco primeiros anos da série. O processo de calibração foi realizado de maneira automática no *software* SWAT-CUP

(Abbaspour; Johnson; van Genuchten, 2004), através do algoritmo SUFI-2. Um conjunto de 12 parâmetros (Tabela 4) foi escolhido com base em estudos que utilizaram o SWAT em bacias hidrográficas do Nordeste brasileiro, seguindo a mesma abordagem desta pesquisa (Andrade *et al.*, 2019; Lins *et al.*, 2024; Rabelo *et al.*, 2021; Santos *et al.*, 2021; Silva *et al.*, 2022a; Viana *et al.*, 2021). Esses parâmetros representam diferentes componentes hidrológicos em escala de bacia, incluindo o escoamento superficial (CN2, CH\_N2, CH\_K2 e SLSUBBSN), as características do solo (SOL\_K e SOL\_AWC), o fluxo de base (ALPHA\_BF, GW\_REVAP e GW\_DELAY) e a evapotranspiração (CANMX, ESCO e EPCO).

Tabela 4 - Descrição dos parâmetros utilizados na modelagem.

Class.	Parâmetro	Descrição	Método*
.mgt	CN2	Curva número para condições normais de umidade anterior.	r
.rte	CH_N2	Coeficiente de Manning do canal principal.	v
	CH_K2	Condutividade hidráulica efetiva do canal (mm/h)	v
.hru	CANMX	Armazenamento máximo de água no dossel vegetativo (mm).	v
.gw	ESCO	Fator de compensação de evaporação do solo.	v
	EPCO	Fator de compensação de água pelas plantas.	v
	SLSUBBSN	Comprimento da declividade média (m).	v
	ALPHA_BF	Constante de recessão do fluxo de base (dias).	v
	GW_REVAP	Coeficiente de ascensão da água à zona não saturada.	v
.sol	GW_DELAY	Retardo do escoamento subterrâneo (dias).	v
	SOL_AWC	Capacidade de armazenamento de água no solo (mm de água/mm de solo).	r
	SOL_K	Condutividade hidráulica saturada do solo (mm h <sup>-1</sup> )	r

\*Os métodos aplicados foram *relative* (r), quando o valor de ajuste varia em percentual em relação aos valores iniciais, e *replace* (v), quando o valor inicial do parâmetro é substituído pelo valor de ajustado após a calibração.

Devido a heterogeneidade da bacia, a calibração foi realizada considerando áreas de contribuição das seis estações fluviométricas. Isso foi feito a partir da junção das sub-bacias a montante de cada estação, com base na rede fluvial gerada pelo modelo, abordagem conhecida como *multi-site* (Moussa; Chahinian; Bocquillon, 2007; Shrestha *et al.*, 2016). Assim, os parâmetros foram calibrados sequencialmente, iniciando com as sub-bacias de contribuição do posto Toritama, seguido por Limoeiro

e Paudalho e, em seguida, foram ajustadas, individualmente, as áreas que contribuem para as estações de Vitória de Santo Antão e Engenho Sítio, finalizando a calibração com as simulações na extremidade leste da bacia, referente a contribuição do posto Tiúma.

No processo de calibração, as primeiras simulações foram realizadas considerando toda a série histórica do projeto. Em todas as simulações foram utilizadas 500 simulações até atingir um ajuste satisfatório das vazões modeladas. Na etapa seguinte, os parâmetros ajustados foram utilizados em uma nova simulação, considerando a série dividida em dois períodos, calibração e validação. A divisão considerou quantidades percentuais das séries de vazões de cada posto, sendo 70% dos dados utilizados na calibração e 30% na validação. Isso foi feito devido às diferenças na disponibilidade do intervalo de dados das estações fluviométricas (Tabela 2).

Na análise de desempenho do modelo, foram avaliadas as fases de calibração (utilizando toda a série) e de calibração e validação (com a série dividida), com base nos hidrogramas observados e simulados. Os índices utilizados foram: Eficiência de Nash-Sutcliffe (NS) (Equação 38); Percentual de Tendência (PBIAS) (Equação 39) e o coeficiente de determinação ( $R^2$ ) (Equação 40). Tais índices têm sido aplicados em pesquisas que avaliaram a precisão do modelo SWAT (Andrade *et al.*, 2019; Bressiani *et al.*, 2015; Santos *et al.*, 2021b; Viana *et al.*, 2021).

$$NS = 1 - \left[ \frac{\sum_{i=1}^e (Y_{obs} - Y_{sim})^2}{\sum_{i=1}^e (Y_{obs} - \overline{Y_{obs}})^2} \right] \quad (38)$$

$$PBIAS = \left[ \frac{\sum_{i=1}^e (Y_{obs} - Y_{sim})(100)}{\sum_{i=1}^e (Y_{obs})} \right] \quad (39)$$

$$R^2 = \left[ \frac{\sum_{i=1}^e [(Y_{obs} - \overline{Y_{obs}})(Y_{sim} - \overline{Y_{sim}})]^2}{\sum_{i=1}^e (Y_{obs} - \overline{Y_{obs}})^2 \sum_{i=1}^e (Y_{sim} - \overline{Y_{sim}})^2} \right] \quad (40)$$

sendo  $Y_{obs}$  a variável observada;  $Y_{sim}$  a variável simulada;  $\overline{Y_{obs}}$  a média da variável observada;  $\overline{Y_{sim}}$  a média da variável simulada; e  $e$  a quantidade de eventos.

O NS é uma estatística normalizada que determina a magnitude relativa da variância residual quando comparado com a variação dos dados de medição. O índice varia entre  $-\infty$  a 1, sendo que valores menores do que zero indicam que a média dos

dados observados prevê melhor do que a simulação pelo modelo, enquanto valores próximos a 1 indicam um ajuste ótimo (Ferrigo, 2014).

O PBIAS mede a tendência média de cada período simulado, seja maior ou menor que sua contraparte observada (Moriasi *et al.*, 2007). Quanto menor o resultado do índice melhor é o ajuste, sendo o valor zero a representação de uma simulação perfeita da série observada. Os valores positivos dessa função objetivo indicam uma tendência de subestimação dos dados simulados, enquanto os negativos indicam superestimação (Venzon; Pinheiro; Kaufmann, 2018).

Já o  $R^2$  mede a associação linear entre duas variáveis, sendo o valor obtido adimensional, variando entre 0 e 1, onde quanto mais próximo de 1 o valor se apresentar, mais eficiente será a previsão (Melo Neto *et al.*, 2014). Apresentando grande sensibilidade em eventos extremos, o  $R^2$  se mostra insensível a diferenças proporcionais entre os eventos observados e simulados (Moriasi *et al.*, 2007).

A classificação sugerida por Moriasi *et al.* (2007), que leva em consideração a avaliação da modelagem em uma frequência mensal, será utilizada neste estudo. As classes são apresentadas na tabela 4.

Tabela 5 - Classificação da eficiência da modelagem através do NS, PBIAS e  $R^2$ .

<b>Classificação</b>	<b><math>R^2</math></b>	<b>NS</b>	<b>PBIAS (%)</b>
Muito boa	$0,80 < R^2 \leq 1,00$	$0,75 < NS \leq 1,00$	$PBIAS < \pm 10$
Boa	$0,70 < R^2 \leq 0,80$	$0,65 < NS \leq 0,75$	$\pm 10 < PBIAS \leq \pm 15$
Satisfatória	$0,60 < R^2 \leq 0,70$	$0,50 < NS \leq 0,65$	$\pm 15 < PBIAS \leq \pm 25$
Insatisfatória	$R^2 \leq 0,60$	$NS \leq 0,50$	$PBIAS \geq \pm 25$

Fonte: Adaptado de Moriasi *et al.* (2007).

### 3.5 ESTIMATIVA DA UMIDADE DO SOLO

Após a etapa de calibração e validação do modelo SWAT com as séries fluviométricas, foi realizada a extração de dados do teor de água no solo a nível de HRU e sub-bacia (Figura 9). As séries simuladas de umidade do solo foram validadas com banco de dados *in situ* de estações monitoradas pelo Centro Nacional de Monitoramento e Alerta Prévio de Desastres Naturais (CEMADEN) e pela Agência Pernambucana de Águas e Clima (APAC). Os dados monitorados pelo CEMADEN foram obtidos da base de dados validados e consistidos, disponibilizado por Zeri *et al.* (2020), no intervalo de tempo entre 2015 e 2019. As séries monitoradas pela APAC

foram obtidas diretamente com a agência. Esta etapa foi realizada apenas para avaliar o desempenho do modelo na simulação da umidade do solo.

Figura 9 - Localização das estações de umidade do solo e das sub-bacias do rio Capibaribe.



Fonte: O autor (2024).

Para que seja possível a comparação direta desses dados, algumas considerações são necessárias: (i) os sensores do CEMADEN e da APAC realizam medições contínuas da constante dielétrica do meio através da tecnologia de domínio de capacitância/frequência que são convertidas em conteúdo volumétrico de água no solo ( $m^3 m^{-3}$ ), utilizando o modelo EC-5 Decagon Devices, pelo CEMADEN, e o modelo PR2/4 Delta-T Devices, pela APAC (Jucá; Ribeiro Neto, 2022; Souza *et al.*, 2018; Zeri *et al.*, 2022), enquanto o teor de água no solo simulado pelo SWAT tem como resultado o conteúdo de água por profundidade do solo ( $mmH_2O$ ) (Andrade *et al.*, 2019; DeLiberty; Legates, 2003; Rajib; Merwade; Yu, 2016; Uniyal *et al.*, 2017) e; (ii) o monitoramento do conteúdo de água no solo pelos sensores é realizado pontualmente em profundidades de 10 e 20 cm pelo CEMADEN e APAC, bem como 30 e 40 cm pela APAC, registrando os dados a cada hora (Jucá; Ribeiro Neto, 2022; Souza *et al.*, 2018; Zeri *et al.*, 2022), contudo, os valores simulados pelo SWAT são realizados espacialmente, resultando em média correspondentes às HRUs (diferentes profundidades do solo) ou sub-bacias (profundidade total do solo), no intervalo de tempo da simulação (um dia) (Havrylenko *et al.*, 2016; Rajib; Merwade; Yu, 2016; Sehgal; Sridhar, 2019).

Como forma de relacionar corretamente esses dados, os valores diários do teor de água no solo ( $mmH_2O$ ), simulados no SWAT, foram convertidos para a unidade volumétrica ( $m^3 m^{-3}$ ) para cada sub-bacia. Para isso, inicialmente, foram calculadas

médias ponderadas dos resultados diários do teor de água no solo das HRUs na profundidade de 10 cm, considerando as respectivas áreas das HRUs em cada sub-bacia. Essa profundidade foi escolhida devido ao menor número de falhas nas séries do CEMADEN e da APAC, além de ser uma profundidade em comum entre as duas formas de aquisição de dados. A umidade volumétrica total foi então obtida a partir da divisão do resultado do teor médio de água no solo (mmH<sub>2</sub>O) pela profundidade do perfil (100 mm) e adicionado o valor do ponto de murcha permanente, que foi calculado em função do teor de argila e da densidade aparente de cada profundidade analisada (Curk; Glavan; Pintar, 2020; Zare; Azam; Sauchyn, 2022). A inclusão do ponto de murcha permanente foi necessária, uma vez que o modelo calcula e disponibiliza apenas o conteúdo de água no solo disponível para as plantas (Musyoka *et al.*, 2021; Rajib; Merwade; Yu, 2016) no arquivo output.swr. As sub-bacias utilizadas nesta etapa foram escolhidas conforme a localização das estações de monitoramento, sendo essas a 31 (estação Jataúba), 51 (estação Sanharó), 53 (estação Brejo da Madre de Deus), 11 (estação Taquaritinga do Norte), 2 (estação Vertente do Lério), 44 (estação Bezerras), 8 (estação Salgadinho) e 3 (estação Carpina).

Os dados observados pelos sensores foram convertidos para médias diárias e mensais de umidade volumétrica do solo. O período utilizado para cada estação variou de acordo com a disponibilidade e consistência dos dados, com as séries variando, de modo geral, entre 2015 e 2019. Para avaliar a comparação entre a umidade volumétrica simulada e observada foram utilizados o Coeficiente de Correlação de Pearson  $r$  (Equação 41), o BIAS (Equação 39) e a Raiz Quadrada do Erro Médio (RMSE) com dados médios diários e mensais (Equação 42).

$$r = \frac{\sum_{i=1}^n (SM_{insitu,i} - \overline{SM_{insitu}}) \cdot (SM_{SWAT,i} - \overline{SM_{SWAT}})}{\sqrt{\sum_{i=1}^n (SM_{insitu,i} - \overline{SM_{insitu}})^2} \cdot \sqrt{\sum_{i=1}^n (SM_{SWAT,i} - \overline{SM_{SWAT}})^2}} \quad (41)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (SM_{SWAT,i} - SM_{insitu,i})^2}{n}} \quad (42)$$

sendo  $SM_{insitu}$  a umidade do solo estimada pelo sensor;  $\overline{SM_{insitu}}$  a média da variável estimada pelo sensor;  $SM_{SWAT}$  a umidade do solo simulada no SWAT;  $\overline{SM_{SWAT}}$  a média da variável simulada; e  $n$  é o número de valores da série.

Os valores do coeficiente de correlação de Pearson variam entre -1 e 1. Quanto mais próximo de 1, melhor a correlação entre as séries, podendo ser positiva ou negativa. Já o RMSE indica a raiz do erro médio quadrático da diferença entre os resultados simulados no SWAT e os resultados observados nas estações, de tal forma que quanto mais próximo de 0 for o valor obtido, melhor é o desempenho dessa estatística.

Após a análise de concordância entre dados simulados e observados, as séries mensais de umidade do solo simuladas no SWAT foram utilizadas na avaliação temporal e espacial da seca na bacia. Dessa forma, foram utilizados os dados diários, convertidos em médias mensais, do teor de água no solo ( $\text{mmH}_2\text{O}$ ), extraídos por HRU e convertidos para cada sub-bacia, nas profundidades de 0-10, 0-30 e 0-60 cm. As múltiplas camadas foram escolhidas para avaliar a sensibilidade às diferentes características das secas. Segundo Sehgal e Sridhar (2019), a superfície do solo responde a mudanças rápidas da atmosfera, sensível às secas transitórias e de baixa intensidade, enquanto as maiores profundidades interagem com as águas subterrâneas, mais sensíveis às secas severas de longo prazo. Além disso, as camadas entre 30 e 60 cm são profundidades das zonas radiculares dos principais agrícolas na região, como a cana de açúcar, e cultivos de sequeiro como o milho, o feijão e a mandioca (Souza; Ribeiro Neto; Souza, 2021; Zeri *et al.*, 2022).

Para que as séries do teor de água no solo fossem relacionadas com os demais indicadores de seca utilizados neste estudo, os dados das sub-bacias e das três profundidades foram convertidos à anomalia de umidade do solo (SSMI), o que pode permitir constatar eventos de déficit ou excesso hídrico com maior precisão (Havrylenko *et al.*, 2016). Esse procedimento foi realizado utilizando a mesma abordagem para obtenção do SPI, conforme Chen *et al.*, 2019; Kamali *et al.*, 2017; Nguyen *et al.*, 2023 e Zeri *et al.*, 2022, detalhado nas próximas seções.

### 3.6 SÉRIES TEMPORAIS DE INDICADORES DE SECA

Para identificação e classificação das condições climáticas anômalas na bacia, além das observações de umidade do solo, foram utilizados índices de condições de seca, com base em produtos de sensoriamento remoto. Os índices escolhidos neste estudo foram o SPI e o NDVI, e os dados para cálculo dos índices foram obtidos através da plataforma *Google Earth Engine* (GEE).

### 3.6.1 Dados de precipitação por sensoriamento remoto

Os dados de precipitação para esta etapa foram extraídos do *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS). Esse produto, resultante da combinação de imagens de satélite com medições *in situ* e climatologia de alta resolução, foi desenvolvido pela United States Geological Survey (USGS) e pelo Climate Hazards Group at the University of California, Santa Barbara (UCSB) (Funk *et al.*, 2015), e reúne uma coleção global de registros de precipitação interpolados de longo prazo, desde 1981. O CHIRPS tem uma resolução alta ( $0,05^\circ$ ) quando comparado a outros produtos de precipitação baseados em satélite, que geralmente têm uma resolução espacial de  $0,25^\circ$  ou  $0,1^\circ$  (Guo *et al.*, 2017).

A coleção de dados do CHIRPS já foi validada em diferentes regiões brasileiras, com alguns trabalhos avaliando o desempenho do produto no Nordeste (Brito *et al.*, 2021; Andrade *et al.*, 2022; Paredes-Trejo; Barbosa; Lakshmi Kumar, 2017). Em uma comparação entre observações de 21 estações pluviométricas, distribuídas na região Nordeste, com o produto de precipitação do CHIRPS, Paredes-Trejo *et al.* (2017) observaram uma boa correlação ( $r = 0,94$ ), mas uma tendência de superestimação dos valores baixos e subestimação dos valores altos de chuva mensal ( $> 100$  mm). Já Andrade *et al.* (2022) avaliaram cinco produtos de precipitação (CHIRPS, ERA5-Land, TerraClimate, TRMM e IMERG) com dados observados de 11.473 pluviômetros no nordeste brasileiro, disponíveis em grade de resolução espacial de  $0,1^\circ$  (Xavier *et al.*, 2022), e encontraram bom desempenho dos produtos CHIRPS, IMERG e TRMM, com valores de correlação de Pearson médios acima de 0,93. Brito *et al.* (2021) analisaram o desempenho dos produtos PERSIANN-CDR e CHIRPS na estimativa da seca meteorológica em uma bacia do semiárido no nordeste do Brasil, e verificaram um desempenho aceitável na identificação de secas meteorológicas na região.

Uma avaliação da distribuição espacial e temporal da precipitação (mm) foi realizada utilizando os valores totais anuais por pixel em toda a bacia, para o período de 1981 a 2020. Foram extraídos também os totais anuais de chuva do contorno das 53 sub-bacias geradas no SWAT, considerando a média dos valores dos pixels de cada sub-bacia. Esses dados foram utilizados para avaliar a existência de possíveis tendências de precipitação ao longo dos anos nas quatro unidades de análise. A série de dados foi dividida em dois períodos, 1981 a 2000 e 2001 a 2020, e submetida ao

teste não paramétrico de Mann-Kendall (Kendall, 1948; Mann, 1945) e o método de declive de Sen (Sen, 1968). Os testes foram aplicados para detectar a existência de tendências, crescente ou decrescente, e a respectiva magnitude linear. Para determinar a existência de eventuais tendências, calculou-se a estatística  $S$  dada por:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x_j - x_k), \text{ e } \text{sgn}(x_j - x_k) = \begin{cases} +1; \text{ se } (x_j - x_k) > 0 \\ 0; \text{ se } (x_j - x_k) = 0 \\ -1; \text{ se } (x_j - x_k) < 0 \end{cases} \quad (43)$$

sendo  $n$  o tamanho do conjunto de dados; e  $x_j$  e  $x_k$  os valores sequenciais  $j$  e  $k$  do conjunto ( $j > k$ ).

Com base nessa análise comparativa, pode-se inferir que se  $S$  for superior a zero, existem sinais de uma possível tendência positiva na série, enquanto se  $S$  for inferior a zero, sugere-se uma possível tendência negativa na série. Caso a quantidade de dados em cada série histórica seja menor ou igual a nove, o valor absoluto de  $S$  é comparado diretamente ao valor da distribuição teórica  $S$  derivada por Mann-Kendall (Gilbert, 1987). Em contrapartida, quando o número de dados excede o valor de nove, emprega-se a estatística  $Z$  e a variância normal padrão  $Var$  para preencher essa lacuna:

$$Z = \begin{cases} \frac{S - 1}{\sqrt{Var(S)}}; \text{ para } S > 0 \\ 0; \text{ para } S = 0 \\ \frac{S + 1}{\sqrt{Var(S)}}; \text{ para } S < 0 \end{cases} \quad (44)$$

$$Var(S) = \frac{1}{18} \left[ n(n-1)(2n+5) - \sum_{p=1}^q t_p(t_p-1)(2t_p+5) \right] \quad (44)$$

onde  $t_p$  corresponde ao número de pontos de determinado grupo  $p$ ; e  $q$  representa o número de grupos.

Por fim, a magnitude das tendências é obtida através do método da inclinação de Sen ( $b$ ), conforme a mediana  $M_d$ , obtida por:

$$b = M_d \left[ \frac{x_j - x_k}{j - k} \right], \forall i < j \quad (45)$$

Para a representação dos resultados, foram plotadas as dispersões dos totais precipitados ao longo dos anos, juntamente com a linha de tendência e a curva de

suavização *locally weighted running line smoother* (LOESS), empregando o método *loess* do pacote *ggplot2* (Wickham, 2009) no *software* R Studio.

### 3.6.2 Índice de Precipitação Padronizada

O Índice Padronizado de Precipitação (SPI) foi calculado a partir das séries mensais de chuva do produto CHIRPS das 53 sub-bacias. Foram consideradas as escalas de tempo de um, três, seis e doze meses (SPI-1, SPI-3, SPI-6 e SPI-12), como forma de representar as secas de curto, médio e longo prazo. Em geral, o valor do SPI- $X$  para o mês  $Y$  compara a precipitação acumulada durante o período de  $X$  meses precedentes (e incluindo) o mês  $Y$  de um determinado ano com a precipitação acumulada para o mesmo período (Brasil Neto *et al.*, 2022). De acordo com Santos *et al.* (2013), o SPI correspondente a um curto período (mensal ou trimestral) é importante para o monitoramento de precipitações sazonais e seca agrícola; a escala semestral (SPI-6) representa eventos de média duração e é importante para monitoramento da transição entre as estações seca e chuvosa; e o SPI de maior duração, como o anual (SPI-12 ou maior), reflete padrões de precipitação de longo prazo, sendo utilizado para monitorar a variabilidade anual e interanual.

O cálculo do SPI inicia com a determinação de uma função de densidade de probabilidade, que descreve as séries temporais. A distribuição gama possui um bom ajuste para variáveis contínuas com limite inferior igual a zero e não têm limite superior, por isso é bastante utilizado para estudo de séries históricas de precipitação (Wilks, 2006). A função gama é obtida através da equação 46:

$$g(x) = \frac{x^{\alpha-1} e^{-\frac{x}{\beta}}}{\beta^{\alpha} \Gamma(\alpha)} \text{ para } x > 0 \quad (46)$$

sendo  $\alpha > 0$  um parâmetro de forma,  $\beta > 0$  um parâmetro de escala,  $x > 0$  a precipitação (mm) e  $\Gamma(\alpha)$  a função gama completa.

Para obtenção dos parâmetros  $\alpha$  e  $\beta$  da distribuição gama, é utilizada a seguinte equação:

$$\alpha = \frac{1}{4A} \left( \sqrt{1 + \frac{4A}{3}} \right) e \hat{\beta} = \frac{\bar{x}}{\alpha} \quad (47)$$

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n}$$

Sendo  $A$  uma medida de assimetria de distribuição,  $\bar{x}$  a precipitação média e  $n$  o número de observações.

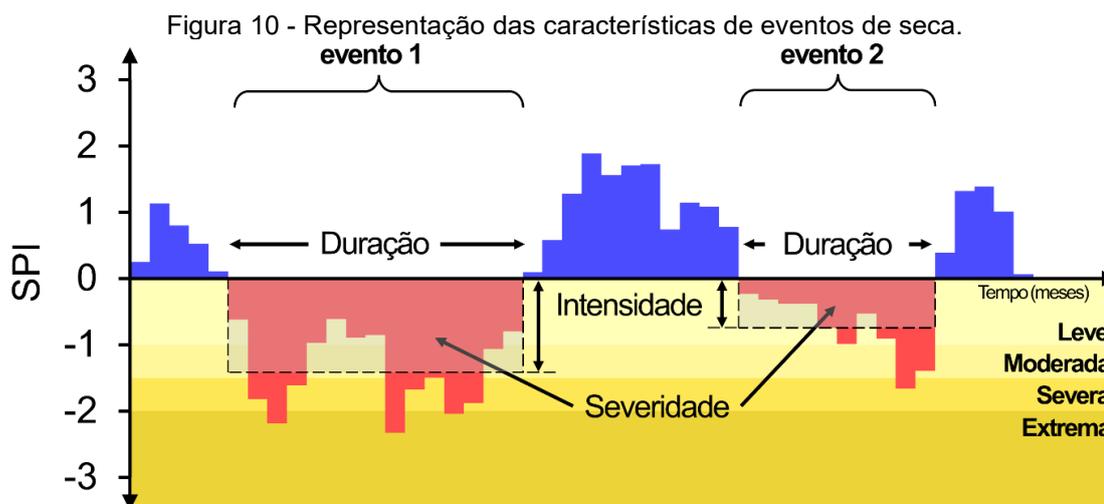
Dessa forma, a distribuição cumulativa é transformada em distribuição de probabilidade normal (média igual a zero e desvio padrão igual a 1). Em seguida, é estimada a probabilidade de ocorrência de cada valor mensal. O resultado é aplicado a função normal inversa para calcular o índice SPI, que é uma variável reduzida  $Z_i$  da distribuição normal da precipitação, descrita na equação 48:

$$SPI = Z_i = \frac{(P_i - \bar{P}_i)}{\sigma_i} \quad (48)$$

sendo  $i$  a escala de tempo (meses);  $P_i$  a precipitação observada (mm),  $\bar{P}_i$  e  $\sigma_i$ , respectivamente, a média e o desvio padrão da série ajustada.

A partir da obtenção das séries mensais de SPI para cada sub-bacia e escala, e considerando os períodos com valores continuamente iguais ou abaixo de zero como eventos secos, foram utilizados indicadores de seca para caracterizar os eventos ocorridos na bacia. De forma mais simples, inicialmente foram calculadas a média e o desvio-padrão dos meses com  $SPI \leq 0$ . Posteriormente, foram determinados o número, a duração, a severidade e a intensidade de cada evento, utilizando a teoria *Run Theory* (Figura 10), originalmente proposta por Yevjevich (1967).

A duração de um evento de seca corresponde ao número de meses em que os valores de SPI são negativos, considerando o início e o fim de um evento; a severidade é a soma absoluta de valores de SPI durante um evento de seca; e a intensidade obtida a partir da razão entre a severidade e a duração de um evento. Além dos indicadores, as secas podem ser classificadas em categorias que indicam a gravidade dos eventos, variando conforme os resultados do SPI, sendo: eventos leves ( $0,0 < SPI < -0,99$ ), eventos moderados ( $-1,49 < SPI < -1$ ), eventos severos ( $-1,99 < SPI < -1,5$ ) e eventos extremos ( $SPI < -2$ ).



Fonte: O autor (2024).

Neste estudo, as categorias moderada, severa e extrema foram utilizadas para avaliar a frequência de meses com diferentes magnitudes de secas e escalas temporais. Isso possibilita identificar regiões mais susceptíveis a ocorrência desses eventos. Para esta etapa, a frequência foi determinada através da razão entre o número de meses que apresentam as diferentes categorias e o número total de meses com valores de  $SPI \leq -1$ . O SPI-1 não foi considerado nessa abordagem pois, segundo Wu *et al.* (2007), em áreas com precipitação altamente sazonal, a aplicação do índice em escalas de tempo curtas pode levar erroneamente a altos valores positivos ou negativos. Dessa forma, para cada sub-bacia foram calculadas as frequências de eventos moderados, severos e extremos nas escalas de SPI-3, SPI-6 e SPI-12. Esses resultados demonstram com que frequência ocorreram tipos distintos de seca nas diferentes escalas em relação ao total de meses considerados.

### 3.6.3 Índice de vegetação

O índice de vegetação escolhido como indicador de impacto de secas neste trabalho foi o NDVI. Esse índice tem sido utilizado com sucesso no monitoramento e identificação de áreas afetadas pelas secas em escalas regionais e locais (Havrylenko *et al.*, 2016; Moussa Kourouma *et al.*, 2021; Sandeep *et al.*, 2021; Tamiminia *et al.*, 2020). Ademais, o NDVI pode ser utilizado no monitoramento ambiental e, particularmente, como indicador das condições e variações sazonais da saúde da vegetação ao longo do tempo (Havrylenko *et al.*, 2016; Xiong *et al.*, 2017). Os valores do índice variam entre -1 a 1, onde os resultados positivos, mais próximos de 1,

representam áreas com vegetação, e os valores negativos são interpretados como áreas sem vegetação, enquanto valores próximos a 0 representam áreas de solo descoberto (Gonçalves *et al.*, 2021; Havrylenko *et al.*, 2016).

A série temporal do NDVI foi obtida a partir do *Moderate-Resolution Imaging Spectroradiometer* (MODIS Terra), com resolução espacial de 250 m e gerados a cada 16 dias (MOD13Q1 V6.1). Nessa última versão, o produto NDVI do MODIS é calculado usando as refletâncias de superfície bidirecional, corrigidas atmosféricamente mascarando a água, as nuvens, os aerossóis pesados e as sombras de nuvens (Didan, 2021).

As imagens foram baixadas através do GEE para o período de 2001 a 2020. O contorno da bacia do Capibaribe foi utilizado para a obtenção dos valores do NDVI anual médio. Para as sub-bacias, além dos dados anuais médios, foram geradas séries temporais de NDVI médio mensal, utilizando o método de composição de valor máximo em cada pixel. Uma análise de tendência da cobertura vegetal foi aplicada nas séries médias anuais do NDVI das 53 sub-bacias através dos testes de Mann-Kendall e Sen, seguindo a mesma abordagem utilizada com os dados de precipitação do CHIRPS. Nessa etapa, foi considerado o período de 2001 a 2020, e a avaliação foi feita para as unidades de análise e para toda a bacia.

### 3.7 INFLUÊNCIA DO EL NIÑO OSCILAÇÃO SUL (ENSO)

O ENSO refere-se às mudanças em toda a bacia na interação oceano-atmosfera associada a mudanças nas temperaturas da superfície do mar da região tropical do Pacífico (Solander *et al.*, 2020). Os eventos ENSO podem ser classificados em El Niño, quando existe água excepcionalmente quente no leste do Oceano Pacífico tropical ao largo da costa sul-americana, e La Niña, quando existem piscinas de água anormalmente frias aproximadamente no mesmo local (Trenberth, 1997). Muitos estudos têm demonstrado que as secas meteorológicas, agrícolas e hidrológicas estão intimamente ligadas a esses tipos de eventos (Huang *et al.*, 2016), incluindo investigações avaliando o impacto do El Niño Oscilação Sul na umidade solo (Chen *et al.*, 2019; Solander *et al.*, 2020; Zeri *et al.*, 2022).

Os índices são registrados com base na temperatura da superfície do mar tropical do Pacífico (TSM). As regiões equatoriais centrais e orientais do Oceano Pacífico são geralmente divididas em quatro principais regiões de monitoramento

ENSO: Niño 1 (5° a 10° S, 90° a 80° W), Niño 2 (0° a 5°S, 90° a 80°W), Niño 3 (5°S a 5°N, 150° a 90°W) e Niño 4 (5° S a 5° N, 160° E a 150° W) (Lv; Fan; Zhang, 2022). De acordo com (Trenberth, 1997), pequenas mudanças de temperatura na região do Niño 3.4, localizada entre Niño 3 e Niño 4, já indicam um grande impacto no clima, podendo esse índice ser utilizado para monitorar e refletir com precisão as condições de El Niño. Muitos estudos têm utilizado apenas o índice Niño 3.4 como indicador do ENSO em diferentes regiões do planeta (Jiang *et al.*, 2021; Khaki; Awange, 2019; Kheyri; Sharafati; Neshat, 2023; Surmaini *et al.*, 2015).

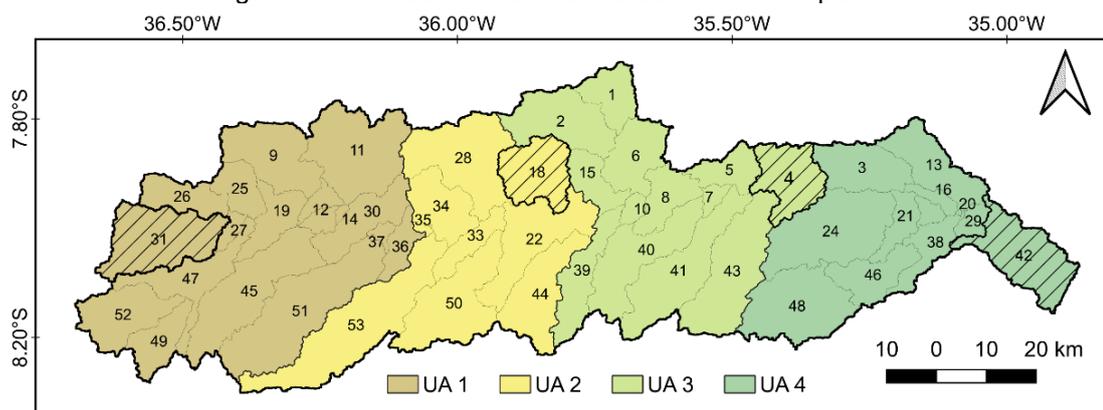
Dessa forma, o índice Niño 3.4 foi escolhido para representar os padrões de circulação ENSO na bacia. Os dados mensais da anomalia do Niño 3.4 foram obtidos da *National Oceanic and Atmospheric Administration* (NOAA) para o período de 1981 a 2020, disponível em <https://psl.noaa.gov/data/climateindices/list>. Para avaliar possíveis teleconexões entre a variabilidade da circulação oceano-atmosfera e as secas meteorológicas e agrícolas na bacia, os dados do índice Niño 3.4 foram correlacionados com as anomalias de precipitação e umidade do solo. A metodologia empregada é detalhada nos tópicos seguintes.

### 3.8 CORRELAÇÃO E ANÁLISE TEMPORAL ENTRE OS ÍNDICES

As séries temporais mensais referentes à anomalia de umidade do solo, índice de vegetação, SPI e ENSO foram correlacionadas a nível de sub-bacia, utilizando o coeficiente de correlação de Pearson a um nível de significância de 5%. Além da correlação por sub-bacia, também foram consideradas as quatro unidades de análise (UA) da região hidrográfica (Figura 11), estabelecidas conforme o agrupamento do Plano Diretor de Recursos Hídricos da bacia do Capibaribe.

Como essa delimitação considerou aspectos hidrológicos e climatológicos, a utilização das quatro áreas pode resultar em uma melhor compreensão a respeito da heterogeneidade ao longo do perfil longitudinal da bacia. Para análises mais detalhadas, descritas adiante, foram utilizadas quatro sub-bacias localizadas estrategicamente na região (Figura 11). As sub-bacias 31 e 42, localizadas no extremo oeste e leste, representam as UA 1 e UA 4, e as sub-bacias 18 e 4, nas áreas próximas aos reservatórios Jucazinho e Carpina, respectivamente, representam as UA 2 e UA 3.

Figura 11 - Unidades de análise da bacia do rio Capibaribe.



Fonte: O autor (2024).

### 3.8.1 Resposta da vegetação à variabilidade da precipitação

A relação entre a resposta da vegetação (NDVI) e a variabilidade da precipitação foi avaliada utilizando duas abordagens, inicialmente considerando defasagens mensais na vegetação e em seguida analisando o efeito cumulativo do SPI. Esse tipo de investigação é importante para compreender as interações entre os eventos de seca e o crescimento da vegetação, e para exercer estratégias de gestão da vegetação mais eficientes (Zhao *et al.*, 2020).

Na primeira abordagem, a comparação foi realizada utilizando uma padronização mais simplificada das séries, conforme a Equação 49. O intuito dessa aplicação foi eliminar possíveis tendências nos dados de NDVI e de precipitação, sem efeitos cumulativos, durante o período de 2001 a 2020, resultado em valores padronizados variando de 0 a 1 (Abbas; Nichol; Wong, 2021; Zhe; Zhang, 2021).

$$X^* = \frac{X - X_{min}}{X_{máx} - X_{min}} \quad (49)$$

sendo  $X^*$  o valor normalizado;  $X$  o valor original; e  $X_{máx}$  e  $X_{min}$  são os valores máximo e mínimo das variáveis correspondentes às séries avaliadas.

Nessa análise, além de considerar a correlação entre as duas variáveis sem ajustes na defasagem da resposta do NDVI (lag 0), também foram realizadas correlações com defasagens individuais de 1 a 3 meses para cada sub-bacia. Por exemplo, o lag 1 (atraso de 1 mês) representa a relação entre a precipitação de um determinado mês e o NDVI do mês consecutivo, indicando a reação da vegetação às chuvas ocorridas no mês anterior. Tal compreensão dos efeitos do desfasamento

temporal das alterações climáticas no NDVI é essencial para explorar os mecanismos implícitos à interação clima-vegetação (Zhe; Zhang, 2021).

Para verificar os efeitos cumulativos da precipitação nas variações sazonais e interanuais da seca, e demais relações com outras variáveis, as séries de NDVI foram transformadas em anomalias (aNDVI). Isso foi feito empregando o mesmo método para gerar o SPI dos dados de precipitação, de forma semelhante à aquisição da anomalia de umidade do solo. Como resultado, a nível de interpretação, os valores negativos indicam condição ou saúde da vegetação abaixo do normal, sugerindo secas predominantes, enquanto valores positivos indicam o contrário (Havrylenko *et al.*, 2016; Moussa Kourouma *et al.*, 2021).

Correlações entre a anomalia de NDVI de 1 mês (aNDVI) e diferentes escalas do SPI (1, 3, 6 e 12 meses) foram calculadas para cada sub-bacia. Como esse tipo de padronização apresenta valores negativos (secas) e positivos (períodos úmidos), as correlações capturam melhor os impactos dos eventos extremos de seca e de períodos mais úmidos. Em escalas sazonais, por exemplo, relações positivas com eventos de curto prazo (SPI 1) indicam que a vegetação responde rapidamente às mudanças nas condições de secas, já para eventos de médio prazo (SPI 3 e SPI 6) implica que a vegetação responde à tendências sazonais diante das condições acumuladas de precipitação ou secas, nas respectivas escalas. As relações positivas com o SPI 12 indicam a influência das condições de secas ou períodos úmidos prolongados no crescimento da vegetação, capturando variações interanuais.

#### 3.8.1.1 Propagação entre as secas

Com base no conjunto de dados dos índices de precipitação, umidade do solo em diferentes profundidades (0-10, 0-30 e 0-60 cm) e vegetação, foram analisadas as características referentes aos padrões de propagação de secas entre as variáveis. O tempo de propagação é definido como o período entre o início da seca meteorológica até o início da seca agrícola (Xu *et al.*, 2021). Para determinar o tempo de propagação da seca meteorológica para seca agrícola, e da seca agrícola para o início de impactos na vegetação, inicialmente foi utilizado o coeficiente de correlação de Pearson entre SSMI com tempos defasados (0 a 6 meses) e SPI com diferentes escalas de tempo (1 a 12 meses), bem como entre aNDVI com tempos defasados (0 a 6 meses) e séries

de SSMI em diferentes escalas (1 a 12 meses), conforme Chen *et al.* (2019), Oertel *et al.* (2018) e Zhou *et al.* (2021).

Xu *et al.* 2021 explicam que ao utilizar variações no SPI com diferentes escalas de tempo para avaliar a relação com anomalias de umidade do solo, por exemplo, possibilita uma melhor representação das condições ambientais reais. Ou seja, o SPI- $n$  pode indicar o déficit de chuva acumulada durante os  $n$  meses anteriores para induzir a escassez de umidade do solo e, de forma análoga, o déficit acumulado do SSMI- $n$  pode indicar o tempo de resposta da seca agrícola para a seca na vegetação. Além disso, os tempos de defasagem considerados nessa aplicação podem identificar atrasos nas variáveis resposta (Oertel *et al.*, 2018). De acordo com Xu *et al.* (2021), o tempo de propagação  $m$  é identificado ao atingir o coeficiente de correlação máximo mensal entre as séries analisadas. Isso significa que a maior correlação encontrada entre SPI- $m$  e o SSMI-1, por exemplo, representa a conexão entre a seca meteorológica e a agrícola, e o período de acumulação  $m$  indica o tempo de propagação da seca.

Seguindo a metodologia utilizada por Xu *et al.* (2021) e Xu *et al.* (2019) o tempo de propagação foi obtido calculando a média dos valores de  $m$  ao longo dos períodos utilizados. Dessa forma, a partir das correlações mensais de SSMI-1 e SPI- $m$ , e aNDVI-1 e SSMI- $m$ , foi determinado o tempo médio de propagação considerando as quatro estações do hemisfério Sul: período 1 (primavera: setembro, outubro e novembro), período 2 (verão: dezembro, janeiro e fevereiro), período 3 (outono: março, abril e maio) e período 4 (inverno: junho, julho e agosto). Por mais que o Nordeste brasileiro apresente apenas duas estações bem definidas, chuvosa e seca, a divisão em quatro períodos foi necessária para evitar possíveis tendências nos resultados médios, caso fossem adotados apenas dois períodos no ano. Portanto, foi utilizada a divisão sazonal da seca agrícola e da seca na vegetação para a análise da sazonalidade, focando no período de acumulação da seca meteorológica, que se propaga para a seca agrícola, e no período de acumulação da seca agrícola, que se propaga para possíveis impactos na vegetação. O tempo de propagação da seca sazonal foi obtido pela média do tempo de propagação ao longo de três meses de cada estação (Xu *et al.*, 2021).

### 3.8.1.2 Análise wavelet

Uma outra abordagem para avaliar a relação entre as variáveis foi realizada por meio da aplicação da wavelet. Essa ferramenta, desenvolvida por Hudgins; Friehe; Mayer (1993), combina variação de onda e análise espectral cruzada, permitindo uma melhor representação do período de ressonância, estrutura de fase e características detalhadas no domínio tempo-frequência entre duas séries temporais (Chen *et al.*, 2019; Zhang *et al.*, 2024). Do ponto de vista de séries temporais hidroclimatológicas, abrangem um amplo espectro de frequências dominantes (Alriah *et al.*, 2024). Para calcular a transformada wavelet cruzada (XWT) entre duas séries temporais  $x_t$  e  $y_t$ , pode-se proceder da seguinte maneira:

$$W_n^{xy}(s, t) = W_n^x(s, t)W_n^{y*}(s, t) \quad (50)$$

sendo  $s$  o fator de expansão de escala,  $t$  o fator de deslocamento de tempo e  $*$  a conjugação complexa. A amplitude das séries  $x_t$  e  $y_t$  da wavelet é representada por  $W_n^x(s, t)$  e  $W_n^{y*}(s, t)$ . Além disso, a potência wavelet cruzada é expressa como  $|W_n^{xy}(s, t)|$ .

A distribuição teórica da potência wavelet cruzada com o espectro de potência de fundo de duas séries temporais  $P_k^x$  e  $P_k^y$  é expresso da seguinte forma (Torrence; Compo, 1998):

$$D \left( \frac{|W_n^x(s)W_n^{y*}(s)|}{\sigma_x \sigma_y} < p \right) = \frac{Z_v}{v} \sqrt{P_k^x P_k^y} \quad (51)$$

onde  $Z_v(p)$  é o nível de confiança associado à probabilidade  $p$  para uma função de densidade de probabilidade, definida pela raiz quadrada do produto de duas distribuições  $\chi^2$  (Grinsted; Moore; Jevrejeva, 2004).

Conforme os resultados visuais da XWT, a linha preta em forma de 'V' indica o valor limite dos espectros eficazes, a área dentro dessa linha representa os valores espectrais eficazes, enquanto os valores fora da linha são considerados inválidos Chen, *et al.* (2019). As setas apontando da esquerda para a direita indicam que a variação entre secas e índices climáticos está em fase (correlação positiva), enquanto as setas apontando da direita para a esquerda indicam uma anti-fase (correlação negativa). Setas apontando em outras direções representam uma correlação não linear, detalhada na Tabela 6.

Tabela 6 - Relação dos ângulos de fase e direção das setas no espectro de potência da wavelet cruzada e no espectro de coerência da wavelet.

Ângulo de fase	Sinal	Indicação
0° (360°)	→	Os sinais $y_2$ e $y_1$ estão em fase e significativamente correlacionados de forma positiva ( $p < 0,05$ ).
45°	↘	O sinal $y_2$ antecede $y_1$ em 1/8 de ciclo.
90°	↓	O sinal $y_2$ antecede $y_1$ em 1/4 de ciclo.
135°	↙	O sinal $y_2$ antecede $y_1$ em 3/8 de ciclo.
180°	←	O sinal $y_2$ antecede $y_1$ em 1/2 ciclo, estando em fase reversa e negativamente correlacionados ( $p < 0,05$ ).
225°	↖	O sinal $y_2$ antecede $y_1$ em 5/8 de ciclo.
270°	↑	O sinal $y_2$ antecede $y_1$ em 3/4 de ciclo.
315°	↗	O sinal $y_2$ antecede $y_1$ em 7/8 de ciclo.

Fonte: Adaptado de Chang *et al.* (2023).

Além da XWT, foi determinada a coerência wavelet (WTC), que é eficaz para mostrar coerência significativa em áreas de baixa potência comum. Ou seja, para duas séries temporais, a WTC explica o quanto da variabilidade em uma variável pode ser explicada pela variabilidade na outra (Santos *et al.*, 2024). O coeficiente de coerência wavelet é determinado da seguinte forma:

$$R_n^2(s, t) = \frac{|S(s^{-1}W_n^{xy}(s, t))|^2}{S(s^{-1}|W_n^x(s, t)|^2) \cdot S(s^{-1}|W_n^y(s, t)|^2)} \quad (52)$$

Os valores de  $R_n^2$  variam entre 0 a 1, sendo uma equação análoga ao coeficiente de correlação tradicional, tornando a coerência wavelet uma medida do coeficiente de correlação tempo-frequência localizado.  $S$  denota um operador de suavização e pode ser calculado como:

$$S(W) = S_{scale}(S_{time}(W(s, t))) \quad (53)$$

sendo  $S_{scale}$  e  $S_{time}$  a suavização ao longo dos eixos da escala e do tempo das wavelets, respectivamente. Para a wavelet de Morlet, Torrence e Webster (1999) propuseram um operador de suavização:

$$S_{scale}(W)|_t = (W(s, t) \cdot c_2 \Pi(0, 6s))|_t \quad (54)$$

$$S_{time}(W)|_s = \left( W(s, t) \cdot c_1^{\frac{-t^2}{2s^2}} \right) \Big|_s \quad (55)$$

onde  $c_1$  e  $c_2$  são constantes de normalização e  $\Pi$  é a função retângulo.

Tanto a transformada wavelet cruzada como a coerência wavelet foram aplicadas às séries de SPI, SSMI (nas três profundidades) e aNDVI nas quatro sub-bacias representativas das unidades de análise. Além disso, foram consideradas as combinações entre as teleconexões do ENSO e as séries com os maiores períodos de observação, no caso, o SPI e o SSMI (na profundidade total do solo).

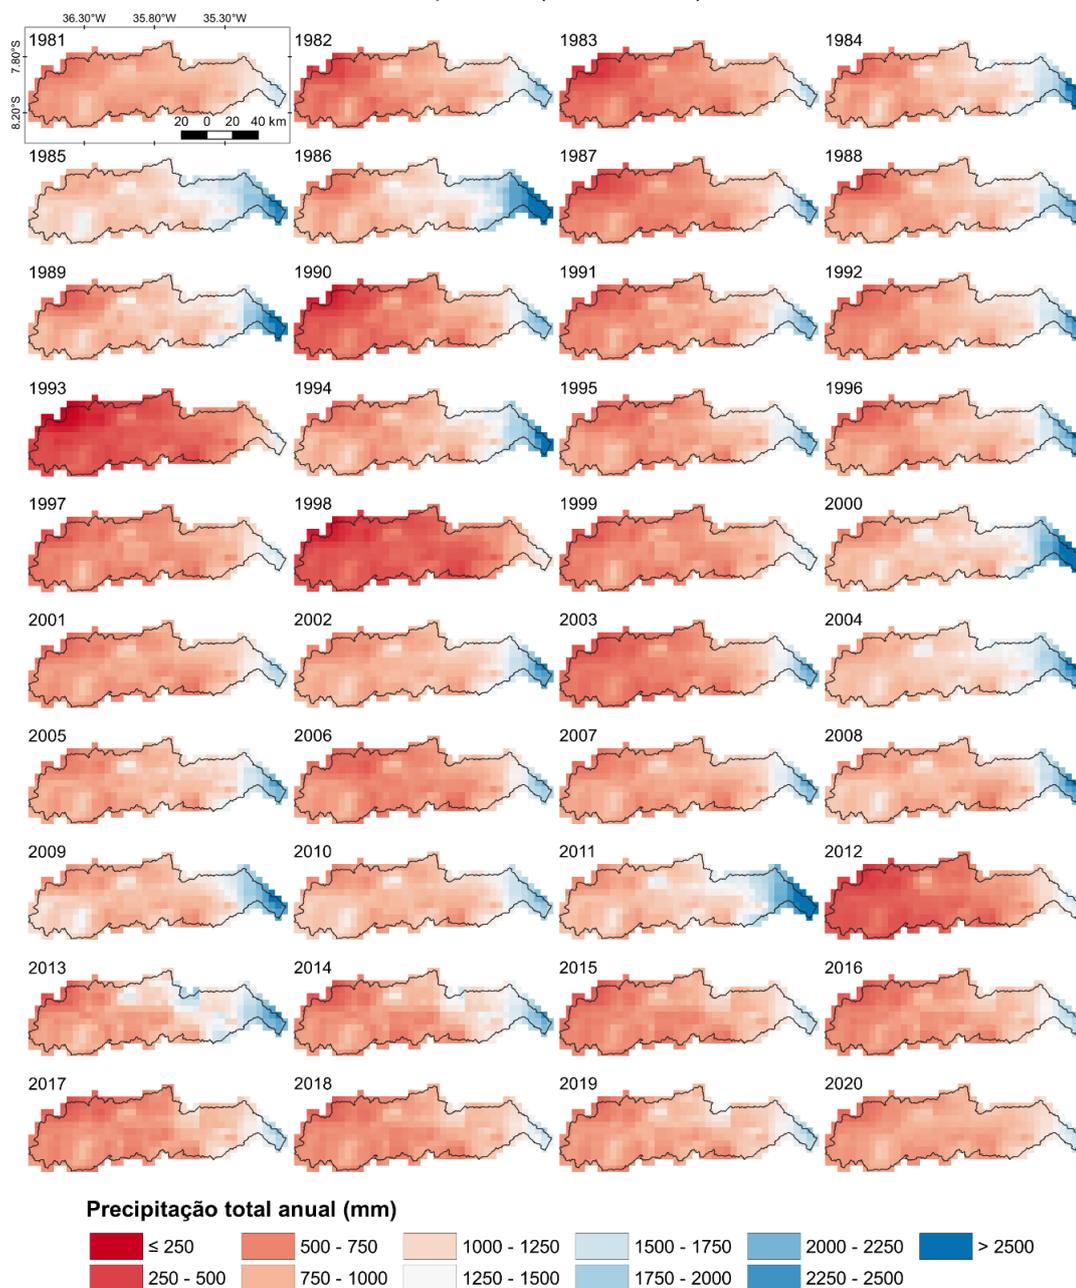
## 4 RESULTADOS

### 4.1 DINÂMICA DA PRECIPITAÇÃO ANUAL NA BACIA DO RIO CAPIBARIBE

Os valores diários de precipitação do CHIRPS foram utilizados para a elaboração dos mapas de precipitação total anual, pixel a pixel, conforme a série disponível do produto (1981 a 2020) (Figura 12). A partir dessa aplicação, é possível observar a distribuição espacial e temporal do total pluviométrico anual na bacia do Capibaribe. Considerando o perfil longitudinal, nota-se, de modo geral, que a distribuição da chuva aumenta na direção oeste (vermelho) para leste (azul), nitidamente visível no ano de 2011. A exemplo, esse foi um ano com um menor valor de pixel (528 mm) localizado no extremo leste da bacia, mais precisamente no agreste pernambucano, enquanto o valor do pixel mais alto foi cerca de seis vezes maior, com um total de 3036 mm, na região metropolitana de Recife, bem próximo ao oceano. Salgueiro *et al.* (2014) destacam que a variabilidade dos extremos pluviométricos na bacia pode ser explicada tanto pela influência dos efeitos orográficos, decorrentes das irregularidades do relevo, quanto dos sistemas meteorológicos vindos do leste. Também é possível associar, e até identificar nas cenas, a heterogeneidade na distribuição espacial da precipitação com a transição entre as zonas do Agreste pernambucano e a Zona da Mata.

Quanto aos valores médios de cada imagem da Figura 12, que correspondem à precipitação média anual considerando toda a área da bacia, foi verificado que o CHIRPS quantificou adequadamente os padrões de excesso ou déficit de chuva na região. Comparando os anos de ocorrências de secas históricas no semiárido brasileiro, os resultados com os menores valores de precipitação média foram 1983, 1990, 1993 e 1998 (secas severas) e 2012 (seca extrema). Ademais, após o ano de 2012, é possível identificar nas imagens a redução da precipitação resultante na recente seca que atingiu o semiárido, a qual, de acordo com Buriti e Barbosa (2018), foi o evento mais longo e um dos mais intensos do período correspondente a mais de um século. Já em relação aos períodos mais úmidos, os maiores valores médios observados na bacia ocorreram em anos com registros de eventos de cheias no rio, como é o caso dos anos 2000, 2004 e 2011 (Gomes, 2019), bem como o ano de 1986.

Figura 12 - Distribuição da precipitação total anual obtida do produto CHIRPS para a bacia do rio Capibaribe (1981 a 2020).

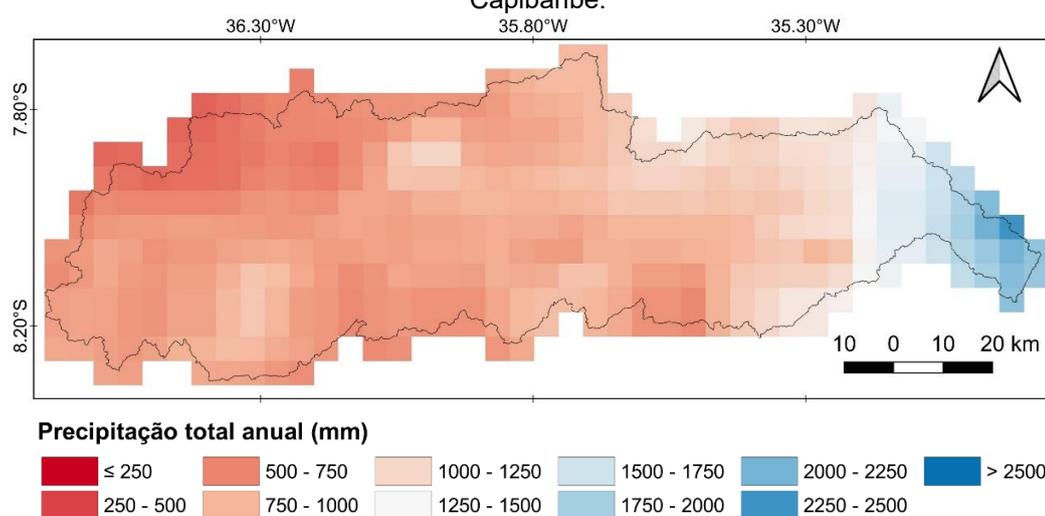


Fonte: O autor (2024).

As séries totais anuais foram utilizadas para calcular a média mensal da precipitação na bacia, e é ilustrada na Figura 13. Percebe-se que a distribuição espacial segue o mesmo padrão das imagens anuais, evidenciando a transição entre as zonas climáticas na bacia. A nível de comparação com a literatura, os padrões de distribuição da precipitação obtidos pelo CHIRPS mostraram-se similares aos registros de observações realizadas por pluviômetros, particularmente ao considerar as unidades de análise da bacia. Tendo como exemplo o estudo realizado por Ribeiro

Neto *et al.* (2014), em que os autores observaram valores de chuva média anual, em torno de 579, 621, 842 e 1228 mm nas UA 1, UA 2, UA 3 e UA 4, respectivamente. Da mesma forma, os resultados médios encontrados pelo produto CHIRPS nesta etapa, seguindo a mesma sequência das unidades de análise, foram 603, 679, 783 e 1197 mm.

Figura 13 - Distribuição da precipitação média anual obtida do produto CHIRPS para a bacia do rio Capibaribe.



Fonte: O autor (2024).

Os resultados da análise de tendência dos testes de Mann-Kendall e Sen para os dados do CHIRPS são exibidos na Figura 14. Na ilustração, a distribuição dos totais anuais de chuvas das sub-bacias é separada e avaliada para cada unidade de análise e para toda a área da bacia. As linhas de tendência, representadas de forma tracejada, e as linhas de suavização (*loess*) com intervalos de confiança de 95%, são também apresentadas. De modo geral, observa-se uma grande variabilidade da precipitação anual entre as unidades de análise, representada pelo comportamento da dispersão dos dados das sub-bacias ao longo dos anos. Isso é notório ao comparar a amplitude dos valores de chuva de um determinado ano. Por exemplo, analisando os dados de 1983 (Figura 14a), a amplitude da precipitação nas UA 1, UA 2 e UA 3 foi respectivamente de 297, 110 e 315 mm, enquanto na UA 4 alcançou 797 mm. A UA 4 apresentou uma alta variabilidade na chuva, como é evidenciado tanto pela maior amplitude dos intervalos de confiança (Figura 14a e b), referente à linha de regressão suavizada, quanto pelo formato da curvatura da linha, sendo a menos suavizada entre as áreas avaliadas. Esse comportamento é consistente com os resultados

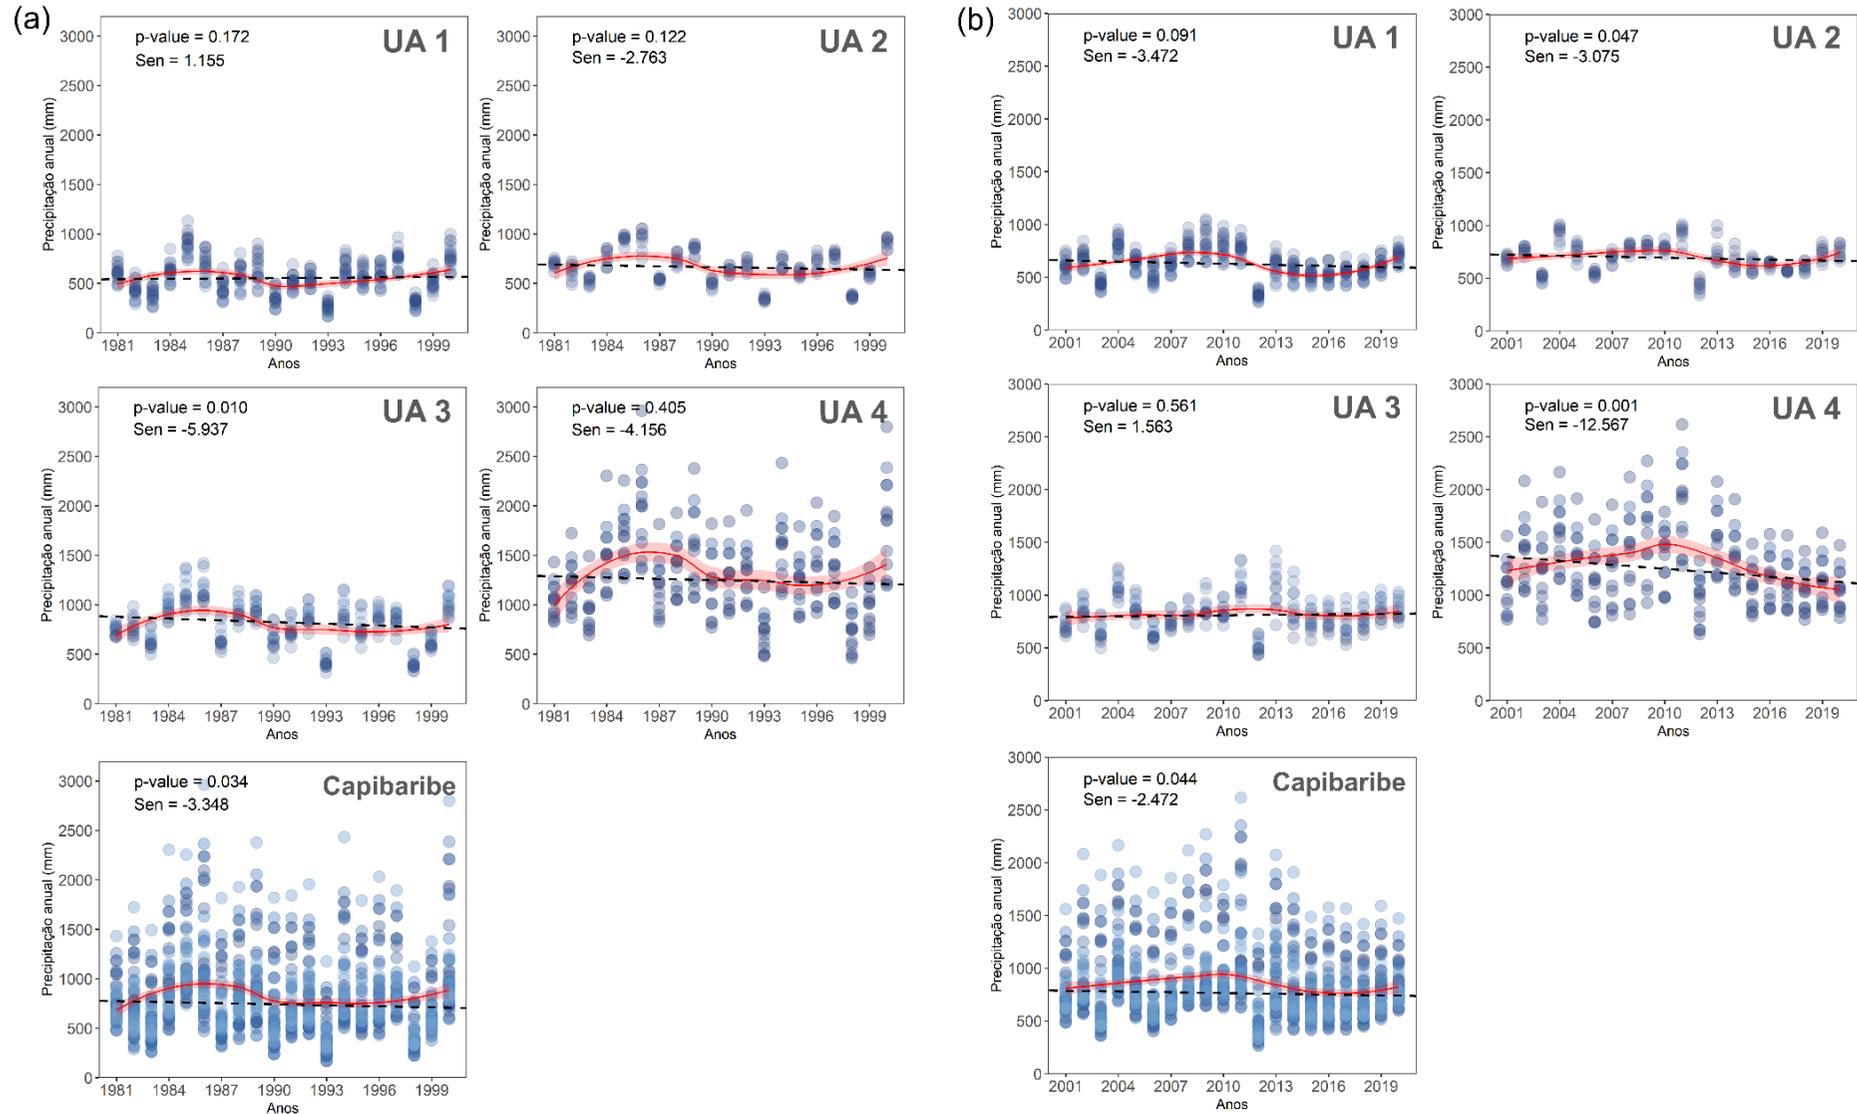
encontrados por Silva *et al.* (2016), que observaram uma variabilidade sazonal significativa da precipitação na RMR e proximidades. Já para a Zona da Mata, que também está inserida na UA 4, Silva *et al.* (2022b) identificaram regimes de chuvas anuais mais irregulares para o período de 1983 e 2012, em comparação com o Agreste e o Sertão do Estado de Pernambuco. Os autores associam essa variabilidade às interações complexas entre o relevo local e os fenômenos climáticos oceânicos.

Quanto aos resultados de tendência de precipitação, em geral, são observados padrões variados entre as diferentes áreas. Ao analisar individualmente as séries, considerando o primeiro período, 1981 a 2000 (Figura 14a), verifica-se que a maioria das unidades apresentaram tendências negativas de precipitação. Entretanto, dentre essas regiões, apenas a UA 3 apresentou uma tendência estatisticamente relevante (p-value de 0,010). A exceção às tendências de redução da chuva foi observada na UA 1, com um leve aumento da precipitação ( $1,155 \text{ mm ano}^{-1}$ ), embora não significativo. Já ao considerar todos os dados das 53 sub-bacias, ou seja, toda a bacia do Capibaribe, observa-se uma tendência significativa na redução da precipitação, indicando que nas duas décadas analisadas houve uma diminuição geral nos totais anuais em toda a área da bacia.

No período de 2001 a 2020, as tendências na bacia demonstraram uma intensificação da redução da chuva anual, principalmente na UA 4, que apresentou uma inclinação acentuada e estatisticamente significativa (p-value de 0,001). Essa forte tendência está associada ao longo período da seca recente no Nordeste, de 2012 a 2018 (Marengo *et al.*, 2020). A UA 2 também apresentou uma diminuição significativa da precipitação ( $-3,075 \text{ mm ano}^{-1}$  e p-value de 0,047), enquanto padrões menos definidos ocorreram nas UA 1 e UA 3. Ao considerar toda a bacia, a tendência significativa de redução da chuva é mantida, da mesma forma que no período anterior, porém com uma menor inclinação ( $-2,472 \text{ mm ano}^{-1}$ ).

A complexidade das variações nos resultados de tendência entre as unidades de análise pode estar relacionada à heterogeneidade espacial e temporal das chuvas na bacia, bem como às particularidades geográficas e climáticas das diferentes zonas. Todavia, a significância estatística negativa em toda a extensão da bacia demonstra que, por mais que ocorram efeitos locais de aumento ou redução da precipitação em escala de sub-bacia ou unidade de análise, a tendência geral resulta em uma redução da chuva nos dois períodos analisados.

Figura 14 - Análise de tendência de precipitação das sub-bacias obtida pelo produto CHIRPS nas unidades de análise e na bacia do rio Capibaribe para os períodos de (a) 1981 a 2000 e (b) 2001 a 2020. A linha vermelha indica a curva suavizada obtida por regressão local ponderada (LOESS).

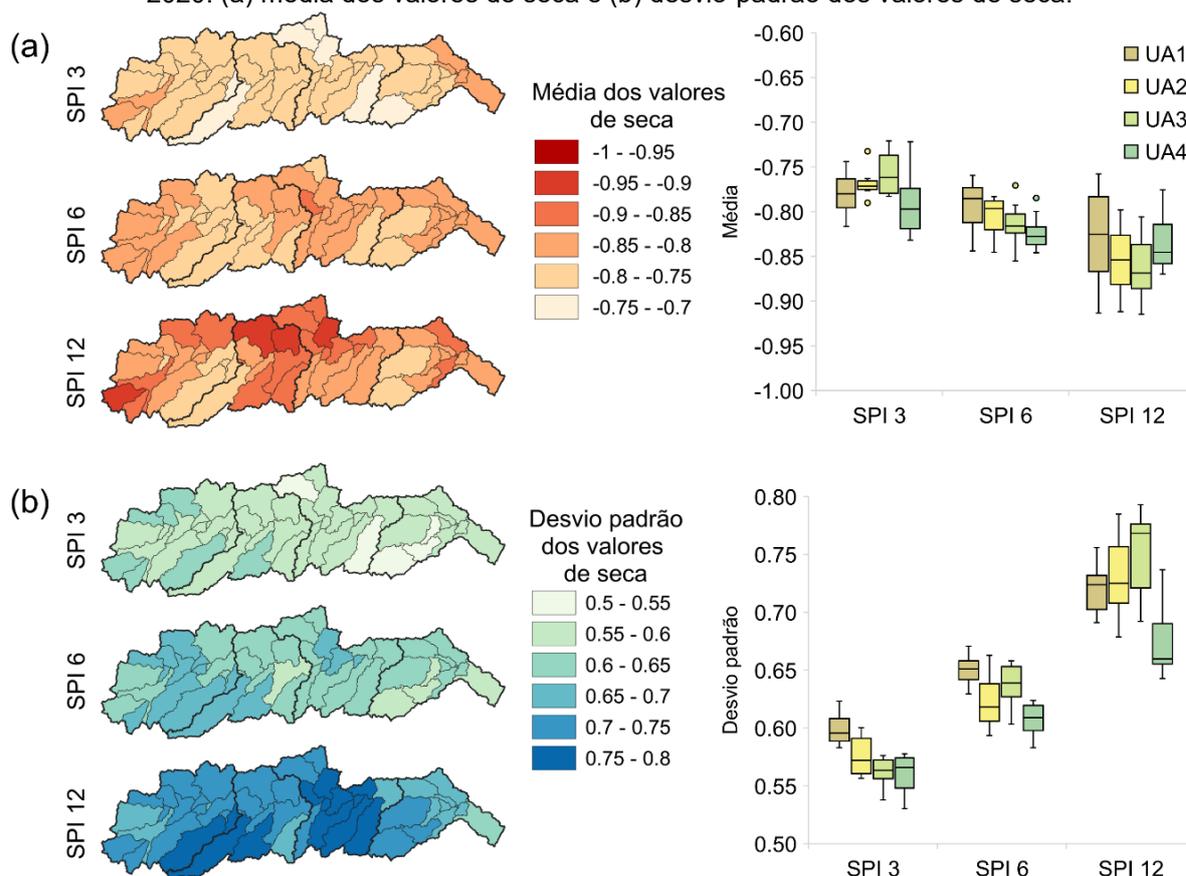


Fonte: O autor (2024).

## 4.2 CARACTERIZAÇÃO DA SECA COM BASE NO PRODUTO CHIRPS

Por meio das séries mensais do produto CHIRPS, considerando cada sub-bacia da região, foram calculados os valores e métricas do índice SPI com o intuito de compreender os padrões espaciais e temporais da seca meteorológica, de curto e longo prazo. Os resultados de SPI nas escalas de 3 e 6 meses podem ser úteis para analisar desde impactos básicos da seca até impactos agrícolas, já na escala de 12 meses contribui para a identificação de impactos hidrológicos (Svoboda; Fuchs, 2016). Esses dados foram analisados individualmente por sub-bacia e por unidades de análise, tendo em vista a média e o desvio padrão das secas (Figura 15a e b), além do número, duração, intensidade e severidade dos eventos por sub-bacia (Figura 16).

Figura 15 - Distribuição espacial e boxplot dos resultados de SPI no Capibaribe no período de 1981 a 2020: (a) média dos valores de seca e (b) desvio-padrão dos valores de seca.



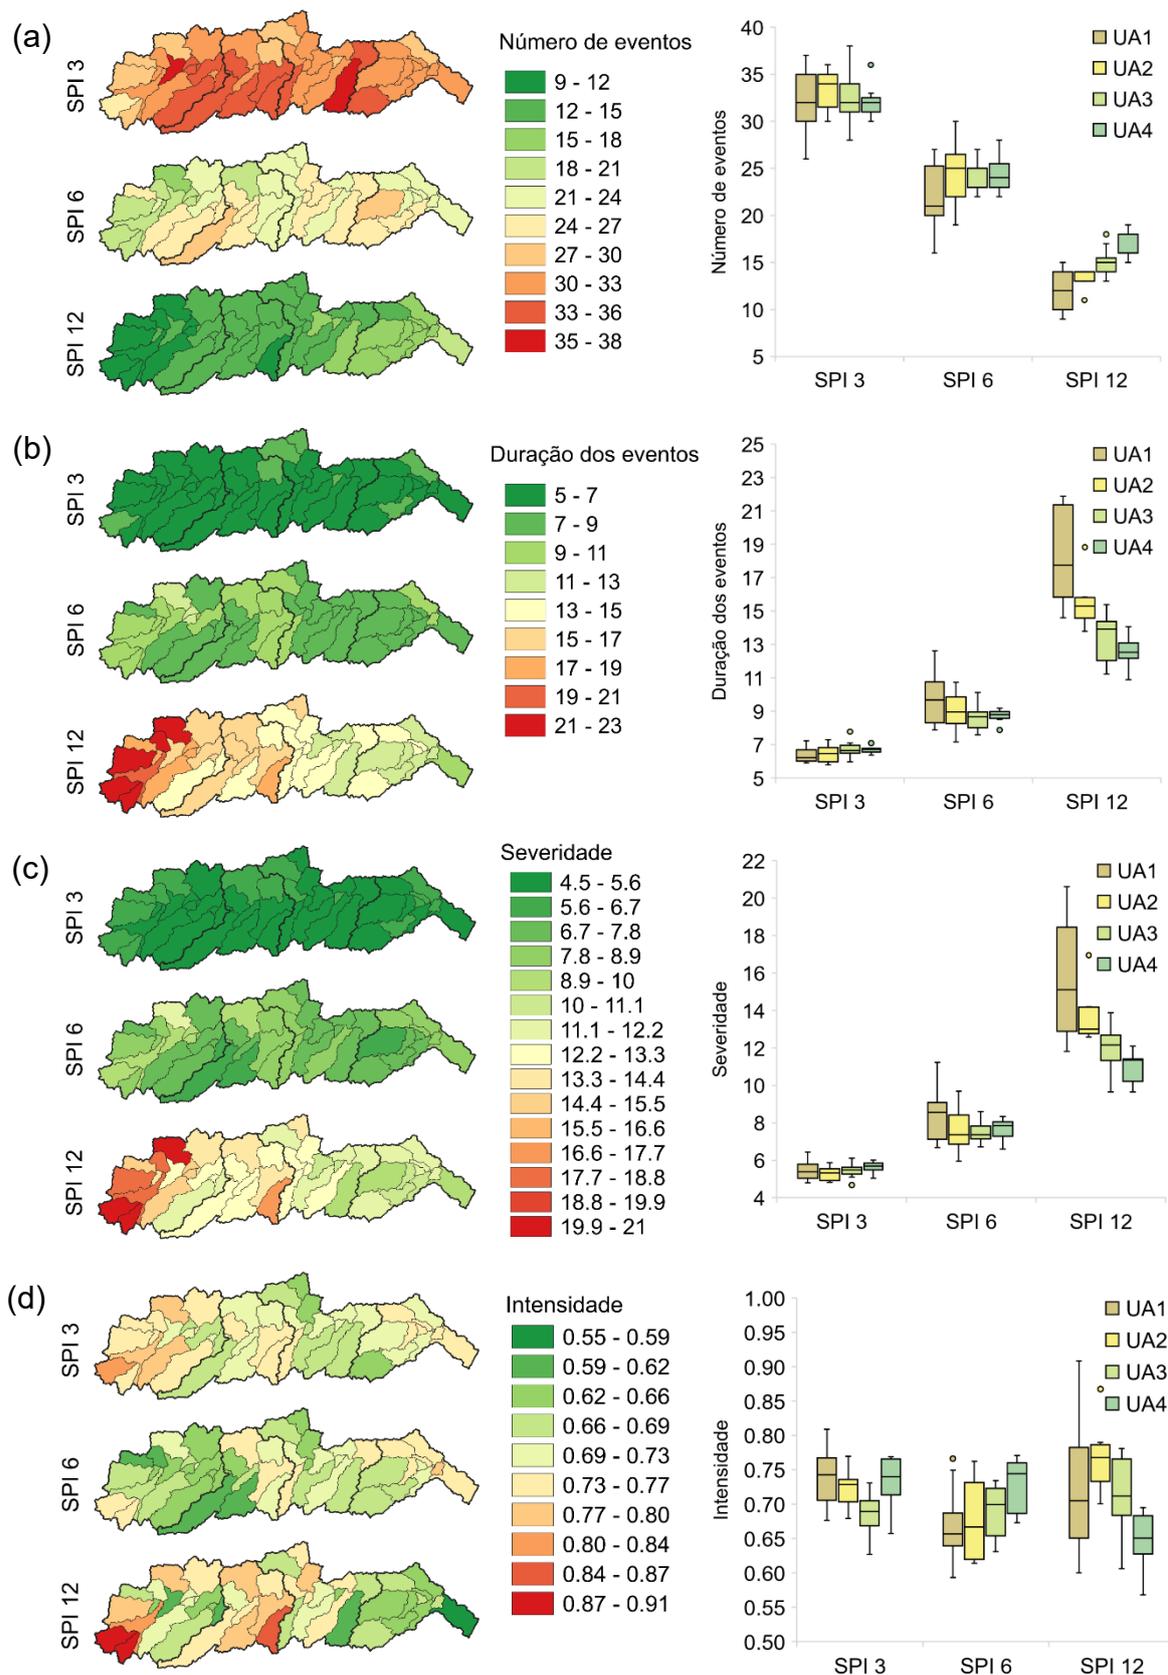
Fonte: O autor (2024).

As médias dos valores de seca SPI, apresentadas na Figura 15a, foram calculadas considerando apenas os valores de SPI menores que zero. Dessa forma, analisando a distribuição do índice na escala de tempo de 3 meses, nota-se uma certa similaridade entre as sub-bacias analisadas, com valores um pouco mais expressivos nas extremidades a oeste e leste da bacia. Com o aumento da escala de tempo do SPI (6 e 12 meses), os valores médios do índice de seca também aumentaram (mais próximos a -1), com os maiores resultados concentrando-se discretamente ao norte da região central. Quanto ao comportamento das sub-bacias agrupadas em unidades de análise por meio do boxplot, fica evidente que a média do SPI aumenta (mais próximos a -1) à medida que a escala de tempo aumenta. Tal comportamento é mais expressivo na UA 3, ao observar os valores da mediana representada pelo traço central no boxplot.

Comportamento semelhante ocorre com o desvio-padrão dos valores de seca na bacia, que aumenta à medida que a escala de tempo aumenta (Figura 15b). Detalhadamente, a distribuição do desvio-padrão para o SPI-3 apresenta predominantemente valores entre 0,55 e 0,6, com algumas bacias localizadas à oeste, na UA 1, com resultados discretamente mais elevados. Essa região apresentou os maiores valores nas escalas de 3 a 6 meses. Já para as secas de longo prazo, SPI-12, percebem-se duas aglomerações com valores elevados de desvio-padrão, sendo uma no sudoeste da bacia, agreste pernambucano, e outra na área vizinha à zona da Mata, maior parte da UA 3, que pode ser explicado pela alta variabilidade da precipitação nessas regiões. A região litorânea, especificamente a UA 4, apresentou os menores valores de desvio-padrão de SPI de curto, médio e longo prazo, estando associado a maior frequência de chuvas nessa área.

Em relação ao número de eventos de secas (Figura 16a), é possível observar que a ocorrência de eventos diminui à medida que a escala de tempo aumenta. Considerando as sub-bacias da UA 3, por exemplo, para o SPI-3, ocorreram entre 28 e 38 eventos, enquanto para a escala anual, SPI-12, há uma redução para 15 a 18 eventos. Isso está intimamente ligado ao período de acumulação dos dados e à metodologia de cálculo do SPI (Brasil Neto *et al.*, 2022). Os autores explicam que as escalas mais curtas de SPI são mais sensíveis às variações de precipitação que escalas de longo prazo, e por isso espera-se que a sucessão de eventos secos (SPI  $\leq 0$ ) seja interrompida e reinicie com uma frequência maior nas séries de SPI-3, por exemplo, do que SPI-12.

Figura 16 - Distribuição espacial e boxplot dos resultados de SPI no Capibaribe no período de 1981 a 2020: (a) número de eventos; (b) duração dos eventos; (c) intensidade das secas e (d) severidade das secas.



Fonte: O autor (2024).

A distribuição espacial da duração das secas é mostrada na Figura 16b. De modo geral, percebe-se que com o aumento da escala do SPI, é observado um aumento nos valores do prazo de duração (Roushangar; Ghasempour; Nourani, 2022). Ao analisar individualmente as escalas, os resultados especializados da duração do SPI-3 não permitiram identificar comportamentos relevantes ao longo nas unidades de análise. Para essa escala, os resultados indicaram intervalos de duração entre 5 e 8 meses, considerando toda a bacia. Já nas escalas de médio e longo prazo, percebe-se um aumento na duração dos eventos na região oeste, principalmente com o SPI-12. Nessa escala, ocorreram eventos mais longos na UA 1, com sub-bacias apresentando duração de até 22 meses, enquanto na UA 4 ocorreram eventos de secas mais curtos, alguns com durações em torno de 12 meses.

Os resultados da severidade da seca na bacia (Figura 16c) tiveram comportamento semelhante à duração dos eventos (Figura 16b). De acordo com Brasil Neto *et al.* (2022), isso é esperado pois os eventos com maior duração tendem a ser os mais severos. Já quando relacionados à quantidade de secas (Figura 16a), à medida que aumenta o número de eventos, menor será a duração e a severidade. Tal consideração é notória ao analisar as respostas das três características especializadas na bacia. Sobre os resultados da distribuição da severidade da seca, é possível verificar que os eventos mais severos ocorreram à medida que a escala de tempo aumentou, com valores em torno de 4,6 para o SPI-3 e até 20,6 para o SPI-12. Os dados de secas mais severas para o SPI-12 ocorreram principalmente na região oeste, em algumas sub-bacias da UA 1 (Figura 16a), com duração em torno de 20 meses e severidade média por volta de 20 unidades de SPI. Isso indica que algumas áreas da bacia são impactadas com os eventos de seca durando quase dois anos. De modo geral, observou-se uma forte relação entre a duração e a severidade dos eventos de seca na região, principalmente com o aumento da escala temporal, com algumas sub-bacias localizadas no Agreste sendo mais afetadas pela ocorrência desses eventos.

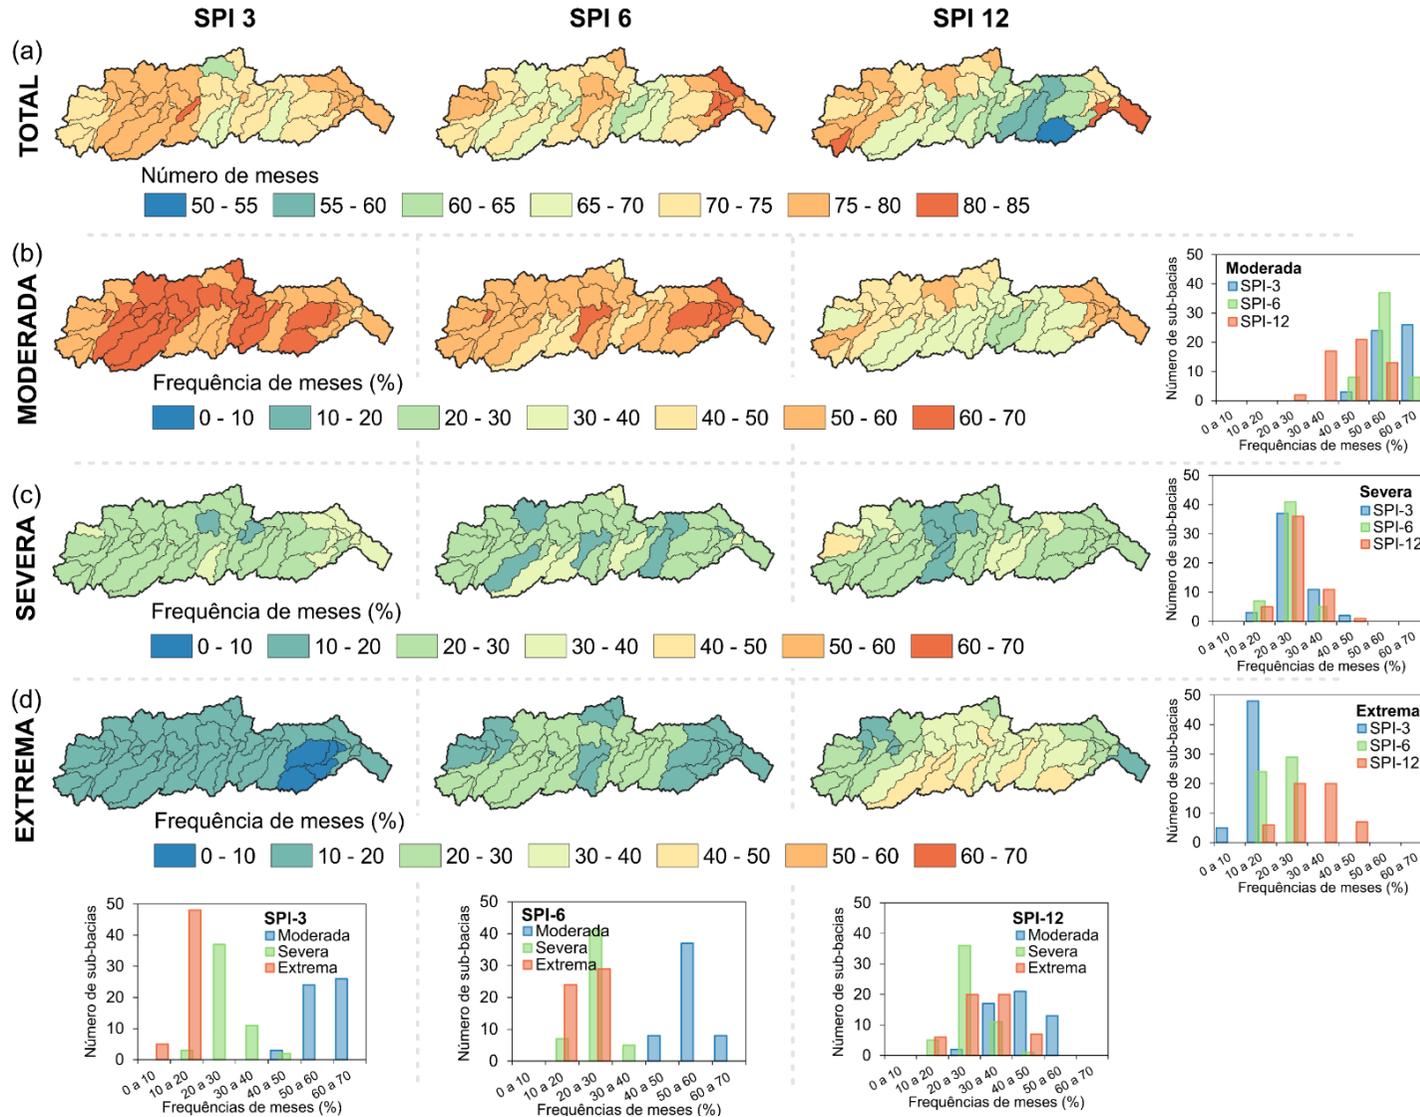
Valores de intensidade dos eventos de secas, ilustrados na Figura 16d, de modo geral, não apresentaram uma amplitude relevante ao longo da bacia nas diferentes escalas avaliadas. A distribuição dos dados por escalas e UAs, ilustradas no boxplot, também não demonstrou um comportamento relevante da intensidade entre as categorias analisadas. Para a seca de curto prazo, é possível verificar algumas sub-bacias localizadas na Zona da Mata, entre a UA 3 e UA 4, com menores

valores de intensidade média, entre 0,62 e 0,66/mês. Em contrapartida, no Agreste, UA 1, esses valores aumentam, com faixas variando entre 0,68 e 0,81/mês. Há uma redução perceptível da intensidade nas sub-bacias da UA 1 e UA 2 na escala de seca semestral, e um aumento discreto desses valores para as UA 3 e UA 4. Os resultados mais elevados de intensidade média ocorreram para o SPI-12, concentrando-se na UA 1, com valores chegando a 0,91/mês, e na UA 2, com o valor mais intenso médio de 0,87/mês.

Como forma de identificar possíveis regiões mais suscetíveis aos eventos de seca nas diferentes escalas de tempo (3, 6 e 12 meses), foi elaborada uma distribuição espacial do percentual de meses com secas em diferentes categorias (Figura 17), calculada com base no número total de meses com  $SPI \leq -1$  (Figura 17a), considerando os resultados de secas moderadas ( $-1,49 < SPI < -1$ ), severas ( $-1,99 < SPI < -1,5$ ) e extremas ( $< -2$ ). Os resultados também são apresentados por meio de histogramas, que mostram o número de sub-bacias em função das classes de frequência de meses com ocorrência de secas nas diferentes categorias e escalas de tempo. Destaca-se que nesta análise não foram utilizadas as durações dos eventos. Assim, tomando como exemplo o SPI-3 e a sub-bacia 42, localizada no exutório da bacia, foram identificados 79 meses com SPI iguais ou menores que -1, e 46, 25 e 8 meses nas categorias moderada, severa e extrema, respectivamente. Portanto, nesse caso, as frequências de meses com secas moderadas, severas e extremas foram aproximadamente 58, 32 e 10%.

De acordo com a espacialização dos dados, analisando a Figura 17a, observa-se que o número total de meses com secas de curto prazo, SPI-3, demonstra uma tendência de maior ocorrência na região à oeste e no leste da bacia, com valores em torno de 75 a 80 meses. Para as maiores escalas de tempo (6 e 12 meses) há uma redução dos meses com valores de  $SPI \leq -1$  em algumas regiões centrais da bacia, em torno de 50 e 65 meses. Entretanto, percebe-se um aumento na ocorrência de meses com secas em algumas sub-bacias localizadas próximo ao oceano. Para a distribuição percentual das diferentes categorias de seca, nota-se, através do histograma, que as maiores frequências ocorreram para eventos de secas moderadas, seguidas de severas e extremas. Esta última categoria apresentou uma exceção na escala do SPI-12, com algumas sub-bacias registrando percentuais mais elevados em comparação com a distribuição de classes das secas severas.

Figura 17 - Distribuição espacial do (a) número total de meses com  $SPI \leq -1$  e frequência de meses com seca nas categorias (b) moderada ( $-1,49 < SPI < -1$ ), (c) severa ( $-1,99 < SPI < -1,5$ ) e (d) extrema ( $< -2$ ) para o SPI 3, 6 e 12 com histogramas.



Fonte: O autor (2024).

Na categoria moderada (Figura 17b), a espacialização do percentual de meses com secas dessa magnitude apresentou uma distribuição semelhante aos resultados do número total de meses com  $SPI \leq -1$  (Figura 17a). Isso ocorre porque os eventos de secas moderadas são mais comuns em comparação às severas e extremas. Dessa forma, os percentuais de secas moderadas representam a maior parte do número total de meses com secas na bacia. Sobre as escalas de tempo analisadas, percebe-se que os percentuais de meses com secas moderadas reduziram à medida em que houve um aumento na escala do SPI, de curto a longo prazo.

Ainda sobre a mesma categoria, observa-se uma ampla dispersão percentual na ocorrência dos meses com secas moderadas, com variações entre 26% para o SPI-12 até 68% para secas de curta duração. Considerando a influência do SPI-3, as maiores ocorrências concentraram-se principalmente na região Agreste da bacia, com valores nas faixas entre 50 e 70%. Com o aumento das escalas, médio e longo prazo, há uma redução dos percentuais de meses com secas moderadas, especialmente nos eventos de SPI-12, nas sub-bacias localizadas próximos à zona da Mata, apresentando as menores frequências dessa categoria, entre 20 e 30%.

A frequência média de meses com eventos severamente secos (Figura 17c) representou em torno de 25% do número total de meses com secas. A distribuição espacial desses resultados mostrou que o percentual de meses com dados de SPI entre -1,99 e -1,5 reduziu gradativamente com o aumento das diferentes escalas de tempo, com exceção dos resultados de SPI-12 para algumas sub-bacias à noroeste. Ao analisar os dados das escalas individualmente, não é possível identificar um comportamento espacial relevante nas secas de curto e médio prazo na bacia. Conforme o histograma, o maior número de sub-bacias concentrou-se na classe de 20 a 30% de meses com eventos severamente secos, enquanto duas sub-bacias no SPI-3 (microbacias à montante do reservatório Goitá) e uma no SPI-12 (extremo oeste da bacia) apresentaram percentuais de ocorrência na classe mais elevada de secas severas, de 40 a 50%. Para os eventos de longo prazo, é possível observar alguns agrupamentos de sub-bacias com percentuais semelhantes, como ocorre na UA 2, à montante do reservatório Jucazinho, com valores entre 11 e 19%, e na UA 4, com valores entre 20 e 18%.

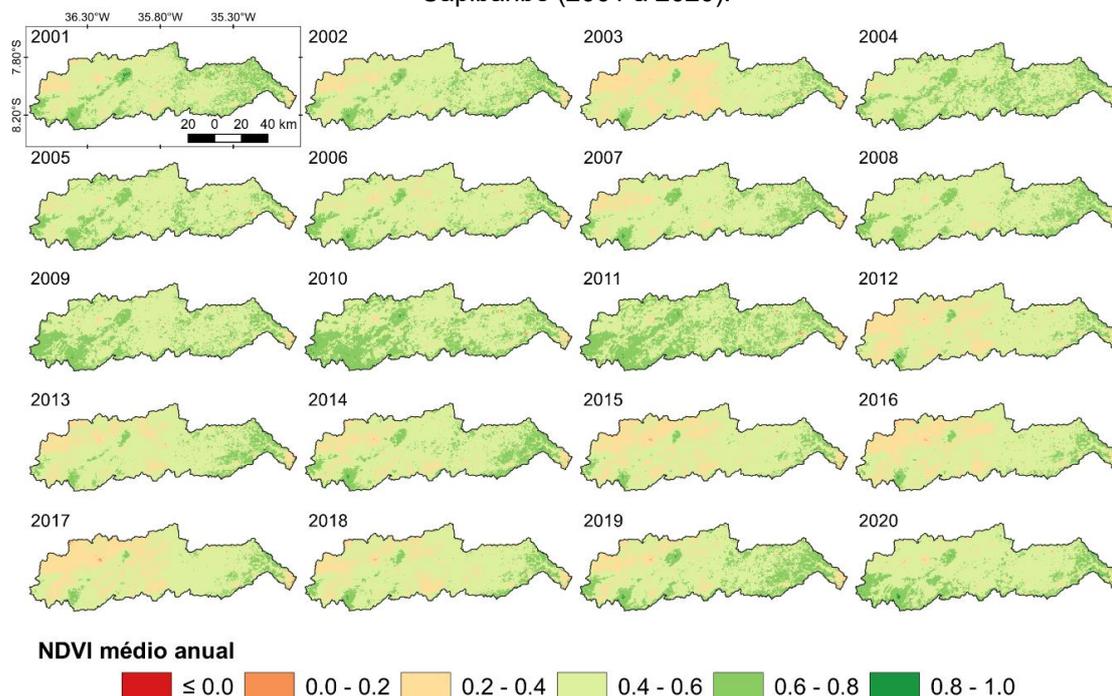
Quanto à variabilidade da frequência com meses de secas extremas na bacia (Figura 17d), observa-se uma tendência divergente das ocorrências com os meses de secas moderadas e severas, ou seja, há um aumento na frequência com o aumento

das escalas de tempo. Na escala de curto prazo, as secas extremas ocorreram em poucos meses em relação a série histórica de  $SPI \leq -1$ , com a maior parte da região apresentando percentual entre 10 e 20% de meses extremamente secos. Já os resultados da escala de médio prazo apresentam áreas intercaladas com percentuais entre 10 e 30%, com algumas regiões nas extremidades e centrais da bacia com as menores faixas. Na escala com secas de longo prazo, percebe-se uma concentração de maiores frequências de meses com secas extremas no centro sul da bacia, em especial nas UA 2 e UA 3. As sub-bacias com os maiores percentuais foram regiões com a presença de leitos afluentes ao rio Capibaribe, como o riacho Onça (41%), riacho Carapatós (47%), riacho das Éguas (42%), riacho Batatã (41%) e rio Tapacurá (46%). Nessa escala, a proporção de meses com secas extremas representou cerca de um terço do número meses de secas totais.

#### 4.3 DISTRIBUIÇÃO ESPAÇO-TEMPORAL DO NDVI COM BASE NO PRODUTO MODIS

Os resultados da variabilidade espacial e temporal das condições da vegetação na bacia do rio Capibaribe são apresentados na Figura 18. Para a espacialização dos valores de NDVI, foram mantidas as resoluções nativas do produto, a fim de permitir uma visualização mais realista dos padrões do índice. Dessa forma, foram identificados valores de NDVI entre -0,19 a 0,92 no período analisado. As mudanças na vegetação, ao longo dos anos, são consistentes com a variabilidade da precipitação (Figura 12). Nos anos com valores de chuva acima da média anual, calculada com base na série do produto CHIRPS, houve uma boa resposta da cobertura vegetal em grande parte da bacia, como é o caso de 2004 e 2009 a 2011. O inverso também é perceptível nos resultados, ou seja, em anos de precipitação abaixo da média foram identificados valores de NDVI relativamente baixos em algumas regiões da bacia, exatamente o que ocorre em 2003 e na seca mais recente, de 2012 a 2018. A transição entre anos secos e úmidos também influenciou na resposta do vigor vegetativo às chuvas, o que pode ser observado nas imagens dos anos de 2003 (seco) e 2004 (úmido), onde a faixa de NDVI referente à maior cobertura vegetal aumentou conforme os valores de chuva acima da média que ocorreram nesse último ano.

Figura 18 - Distribuição do NDVI médio anual obtidas do produto MOD13Q1 para a bacia do rio Capibaribe (2001 a 2020).



Fonte: O autor (2024).

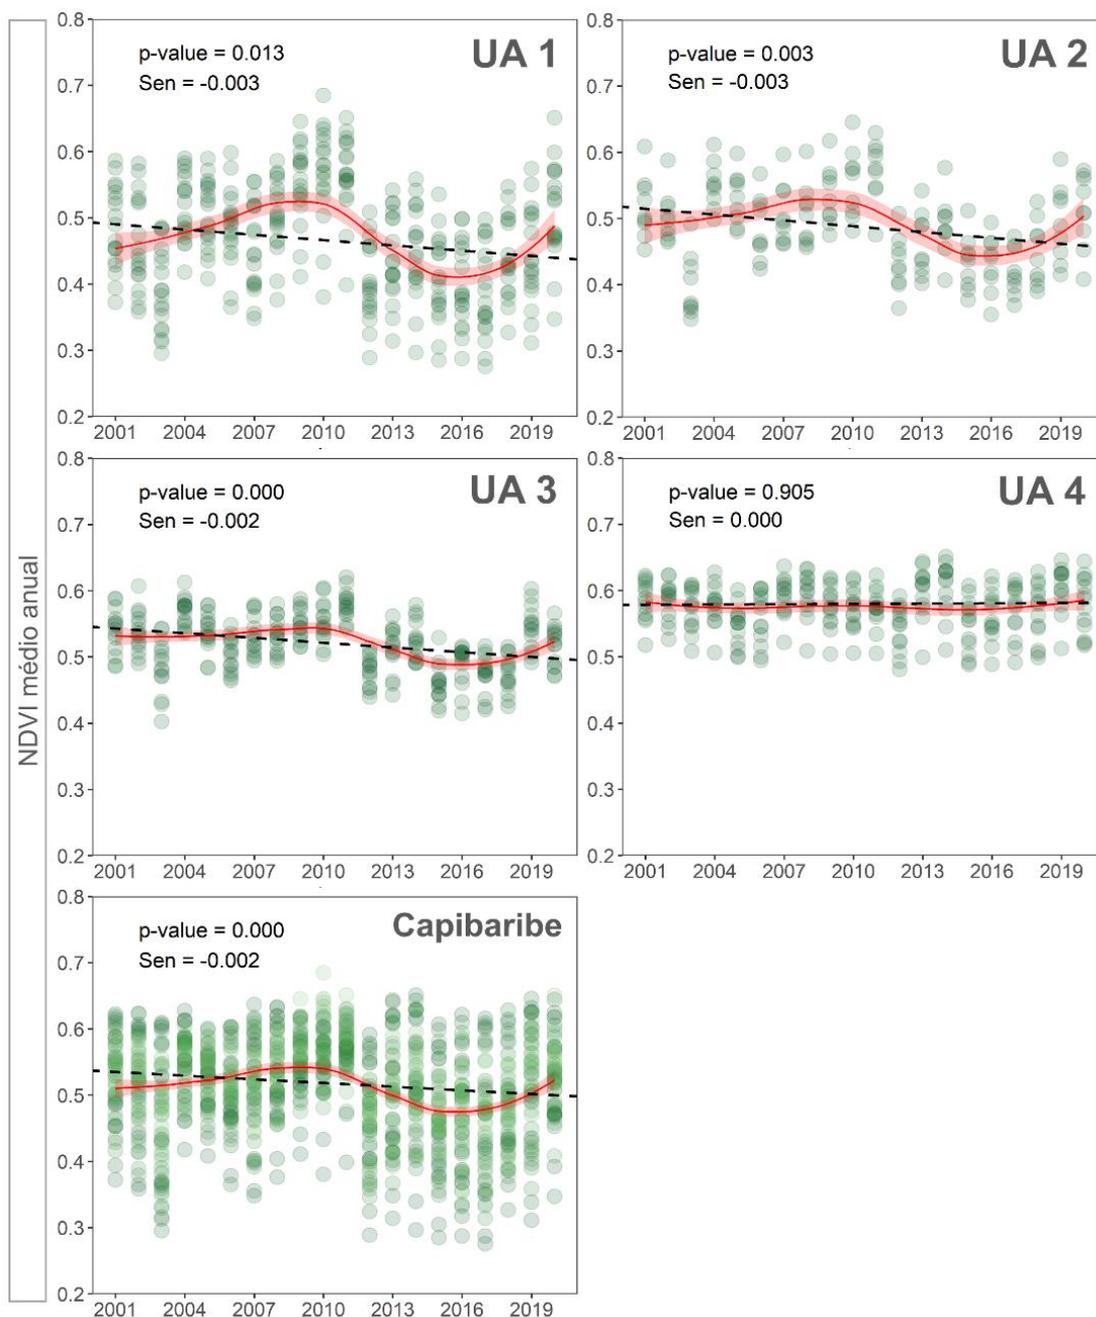
Considerando as unidades de análise da bacia, as imagens (Figura 18) não apresentam um padrão espacial perceptível bem distribuído da resposta da vegetação ao longo de toda a série anual nessas regiões. Entretanto, analisando os resultados em anos secos e úmidos, é possível identificar comportamentos relevantes que ocorrem em algumas unidades de análise. Em períodos secos, por exemplo, as regiões mais à oeste da bacia, UA 1 e UA 2, apresentaram uma grande limitação de crescimento vegetativo, possivelmente associada à ausência de chuvas e à elevada demanda evaporativa da atmosfera. No entanto, em partes dessas regiões, mais precisamente no Agreste Setentrional, a topografia parece influenciar positivamente nos valores de NDVI mesmo nos períodos secos, como é o caso das áreas de maior altitude na APA Serras e Brejos do Capibaribe, com valores do índice mantidos entre 0,6 e 0,8. Conforme a chuva anual retorna a valores acima da média, após anos secos, os resultados de NDVI aumentam nas UA 1 e UA 2, reduzindo consideravelmente as faixas de valores entre 0,4 e 0,6 e revertendo os impactos do déficit hídrico na vegetação. Silva *et al.* (2023a) explicam que em regiões semiáridas, como é o caso das UA 1, UA 2 e UA 3, a dinâmica espectral do NDVI está diretamente associada aos padrões da vegetação, podendo ser diretamente influenciada pelos regimes de chuvas e pelas condições de umidade local.

A dispersão dos valores médios anuais do NDVI (Figura 19) demonstra a heterogeneidade na distribuição do índice ao longo da bacia durante o período de 2001 a 2020. Percebe-se uma maior dispersão na resposta da vegetação entre as sub-bacias situadas a oeste, UA 1 e UA 2, evidenciada pela curvatura e amplitude do intervalo de confiança da linha suavizada. Enquanto nas UA 3 e UA 4, houve uma menor amplitude entre os valores das sub-bacias ao longo dos anos. Esse padrão é consistente com as observações de Dong *et al.* (2021) que identificaram uma variabilidade maior do NDVI em áreas semiáridas quando comparadas a áreas mais úmidas. Tais variações podem estar relacionadas não apenas as condições meteorológicas locais, mas também a práticas agrícolas intensivas e às mudanças de uso e ocupação do solo.

Tendências de redução significativa do índice de vegetação médio anual foram observadas na maior parte das unidades de análise ao longo do período avaliado (Figura 19). Isso ocorreu em toda a região Agreste da bacia, com as UA 1 e UA 2 apresentando uma inclinação de  $-0,003/\text{ano}$  e a UA 3 com  $-0,002/\text{ano}$ . Por outro lado, as condições da vegetação na UA 4 permaneceram estáveis ao longo dos 20 anos, com uma inclinação nula e sem significância. A extensão total da bacia apresentou uma tendência negativa extremamente significativa Zhe e Zhang (2021) do NDVI (p-value de 0,000), com uma inclinação de  $-0,002/\text{ano}$ , indicando uma redução geral na vegetação ao longo da série. Resultados parecidos foram encontrados por Bezerra *et al.* (2022) ao analisarem diferentes zonas do Estado de Pernambuco no intervalo de 2000 a 2019. Os autores identificaram tendências decrescentes, mas não significativas, das médias anuais de NDVI para o semiárido, a Zona da Mata e ao considerar toda a região.

Barbosa, Huete e Baethgen (2006) observaram oscilações e diferentes tendências do índice NDVI ao longo dos anos de 1984 a 1990 na região Nordeste do Brasil. Foi identificada uma tendência consistente de aumento na vegetação entre 1984 e 1990, seguida por uma forte reversão significativa entre 1991 e 1998, especialmente em períodos de seca prolongada. Em uma análise recente, de 2004 a 2022, Barbosa (2023) observou uma tendência decrescente no NDVI superior a 17% na região Nordeste. Os dados mostraram mudanças abruptas no comportamento da vegetação entre as variações de períodos secos e úmidos.

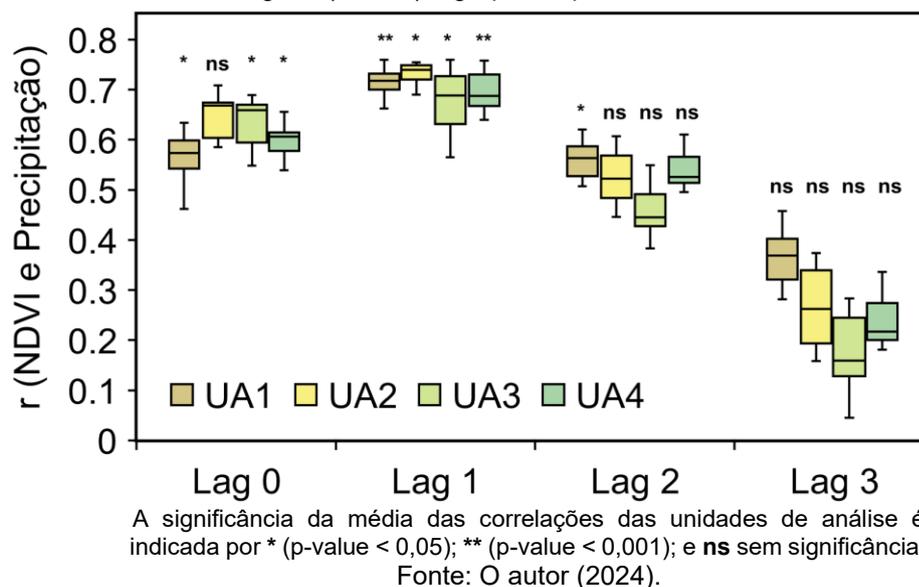
Figura 19 - Análise de tendência do NDVI médio anual das sub-bacias nas unidades de análise e na bacia do rio Capibaribe no período de 2001 a 2020. A linha vermelha indica a curva suavizada obtida por regressão local ponderada (LOESS).



Fonte: O autor (2024).

Para verificar a relação entre a precipitação, por sensoriamento remoto, e o NDVI na bacia do Capibaribe, as séries temporais das variáveis foram correlacionadas a nível de sub-bacia e os resultados separados por unidade de análise (Figura 20). Essa relação é caracterizada por uma resposta defasada do NDVI em relação aos eventos de chuva, uma vez que a vegetação é afetada tanto por eventos atuais quanto por eventos anteriores (Zhou *et al.*, 2015).

Figura 20 - Boxplot da correlação entre a precipitação e NDVI padronizados das sub-bacias com diferentes defasagens (meses), agrupados por unidades de análise.



A relação entre as variáveis sem defasagem temporal apresentou correlações positivas moderadas a altas nas unidades de análise da bacia. Esse tipo de comparação, utilizando produtos de sensoriamento remoto, inclusive com o CHIRPS, tem sido avaliada e os resultados indicam correlações altas e significativas (Georganos *et al.*, 2017; Gessesse; Melesse, 2019; Retalis *et al.*, 2017). Os resultados variaram de 0,46 a 0,71, com os maiores valores ocorrendo na UA 2. No entanto, essa foi a única região com uma relação sem significância estatística (p-value de 0,058). Nas demais unidades de análise, UA 1, UA 3 e UA 4, as correlações foram moderadas e estatisticamente significativas. As UA 3 e UA 4 apresentaram variações de correlação similares, com a UA 3 variando entre 0,55 e 0,69, e a UA 4 entre 0,54 e 0,66. Já a UA 1 apresentou os menores valores, entre 0,46 e 0,63. Em toda a bacia, as correlações demonstraram uma resposta inicial relativamente rápida, indicando que no início da estação chuvosa, o esverdeamento da vegetação ocorre quase simultaneamente ao início das chuvas (Erasmi *et al.*, 2014).

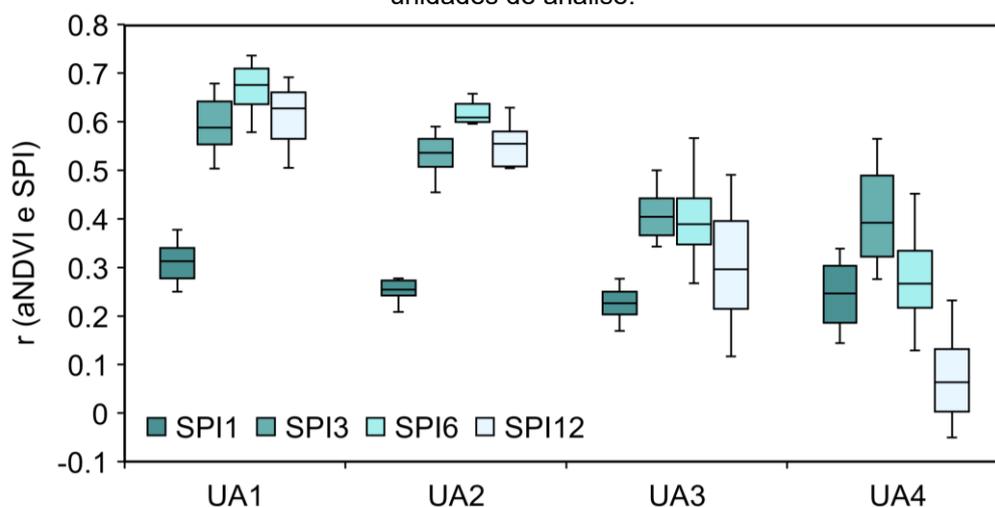
Quanto aos efeitos dos intervalos de tempo, percebe-se que os maiores valores foram alcançados no tempo lag 1 (defasagem de um mês), com correlações moderadas e fortes, estatisticamente significativas. Esse pico da correlação em um tempo de atraso de um mês é consistente com as observações de Erasmi *et al.* (2014) e Medeiros *et al.* (2022) ao analisarem regiões do semiárido brasileiro. Da mesma forma, Sanogo *et al.* (2021) identificaram que as respostas máximas da vegetação às chuvas ocorreram em cerca de 30 dias em uma região do semiárido africano. Na bacia

do Capibaribe, analisando individualmente os resultados (Figura 20), verifica-se que os coeficientes máximos de correlação foram similares entre as áreas, com valores de 0,76 nas UA 1, UA 2 e UA 4, e de 0,75 na UA 3. Nesta região, observou-se uma maior dispersão dos valores entre as sub-bacias, com a presença do menor valor de correlação (0,56) do lag 1. Isso possivelmente está associado a heterogeneidade espacial da UA 3, considerando a presença de uma região com transição entre o Agreste e a Zona da Mata, que pode responder de forma diferente às chuvas. Outros fatores como a temperatura do ar e a umidade do solo também influenciam positivamente e espacialmente na resposta da vegetação em diferentes tempos de atrasos (Medeiros *et al.*, 2022; Niu *et al.*, 2018; Sun *et al.*, 2021; Zhe; Zhang, 2021).

Após o tempo de atraso de um mês, à medida que a defasagem aumenta, observa-se uma redução nos valores de correlação entre as diferentes áreas, principalmente no lag 3. Com dois meses de atraso, lag 2, as correlações na UA 1 foram as únicas com tempo de atraso significativo, variando entre 0,51 e 0,60. É interessante notar que, nessa área, os intervalos de correlação foram próximos aos observados no lag 0, ou seja, houve uma resposta prolongada da vegetação às chuvas ocorridas dois meses antes. Essa observação pode estar associada à capacidade de retenção de água no solo (Sanogo *et al.* 2021) nas cotas mais elevadas na região, bem como pode refletir à resiliência da vegetação à disponibilidade hídrica. Nas demais regiões, as respostas defasadas não foram significativas, embora grande parte das correlações tenha sido moderada, como nas UA 2 e UA 4. Portanto, na bacia, com exceção a UA 1, a sensibilidade da vegetação à precipitação diminui significativamente após dois meses e, substancialmente, após três meses.

A resposta da vegetação às variações sazonais e interanuais da seca meteorológica, considerando os efeitos cumulativos da precipitação, é ilustrada na Figura 21. Os resultados apontaram que as áreas à oeste, UA 1 e UA 2, apresentaram padrões similares e as maiores correlações, com valores aumentando de SPI 1 a SPI 6 e reduzindo levemente no SPI 12. O mesmo ocorreu na UA 3, porém, com correlações menores e com dados mais dispersos para o SPI 6 e SPI 12. A dispersão também foi presente na UA 4 em todas as escalas analisadas, possivelmente devido a diversidade de tipos e uso solo e da heterogeneidade da vegetação.

Figura 21 - Boxplot da correlação entre as escalas de SPI e aNDVI das sub-bacias, agrupados por unidades de análise.



Fonte: O autor (2024).

A respeito das escalas do SPI, os menores valores de correlação ocorreram com o SPI 1 na maior parte da bacia. Isso indica que a menor escala de tempo não é capaz de monitorar o crescimento da vegetação (Törnros; Menzel, 2014), principalmente nas UA 1, UA 2 e UA 3. Há um aumento considerável na correlação com o SPI 3 na região ao comparar com a escala menor, com os maiores valores médios ocorrendo na UA 1 (0,59) e UA 2 (0,53). Já na escala de 6 meses, as UA 1 e UA 2 tiveram a correlação média mais alta na bacia (0,67 e 0,61, respectivamente), com o valor máximo encontrado na UA 1 (0,74). Nessa escala, há uma redução gradativa no sentido oeste à leste nas unidades de análise, com a menor correlação média ocorrendo na UA 4. O mesmo padrão aconteceu com a relação entre o SPI 12 e o aNDVI, tendo correlações negativas em 3 sub-bacias na UA 4, com o valor mínimo encontrado de -0,05.

Esses resultados apontam que, ao considerar toda a bacia, as escalas de 3 e 6 meses explicaram melhor a variabilidade sazonal da anomalia mensal do NDVI na bacia. Na maior parte da região Agreste, as correlações mostraram que os défices hídricos cumulativos podem afetar o crescimento da vegetação na escala cumulativa de três a doze meses. Já na Zona da Mata e Região Metropolitana, os valores das diferentes escalas de SPI e aNDVI foram menores correlacionados e mais dispersos entre as sub-bacias, e a vegetação demonstrou maior sensibilidade ao efeito cumulativo de três meses de seca.

#### 4.4 ESTIMATIVA DA UMIDADE DO SOLO

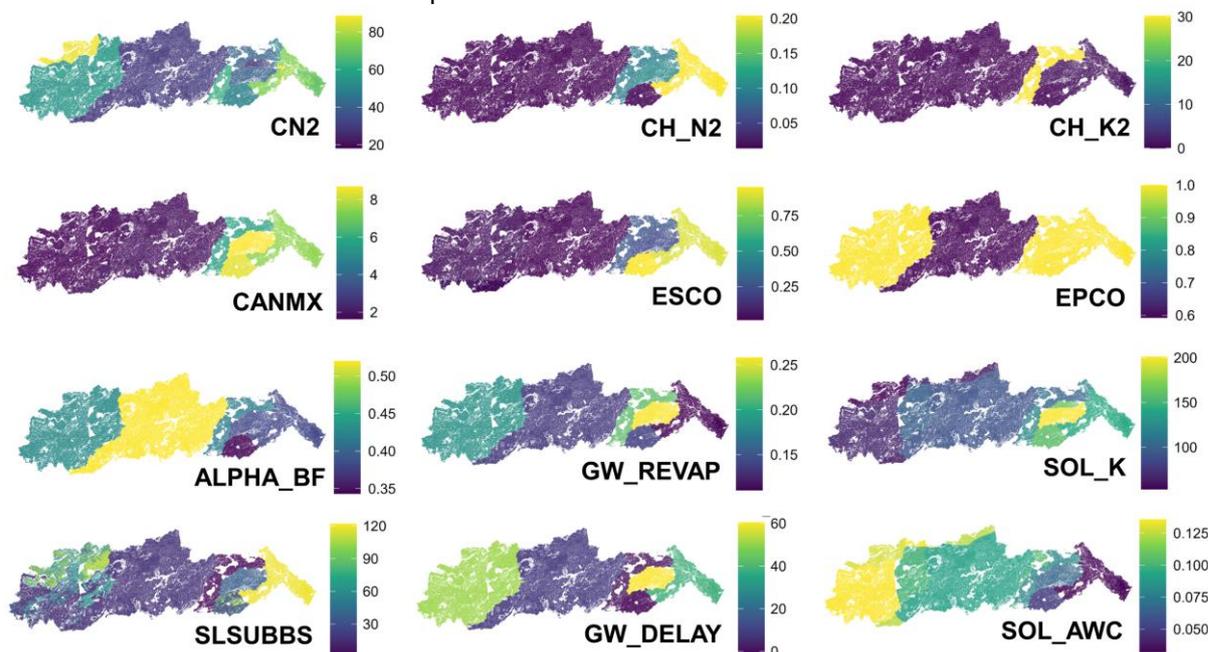
Nos tópicos seguintes, são abordadas as etapas para obtenção da umidade do solo em diferentes profundidades, simulada através do SWAT. São apresentados e discutidos em sequência: (i) os resultados da modelagem, com calibração e validação da vazão nos postos fluviométricos na bacia; e (ii) a comparação entre os dados simulados de umidade do solo com dados diários e mensais observados de umidade nas estações de monitoramento.

##### 4.4.1 Calibração e validação das vazões simuladas pelo modelo SWAT

A Figura 22 apresenta a espacialização dos parâmetros com valores ajustados e calculados a partir dos diferentes métodos de alteração: *replace*, *relative* e *absolute*. A variabilidade espacial dos resultados reflete a influência de fatores como o relevo, o uso e ocupação do solo e o tipo de solo na resposta hidrológica da bacia. Por exemplo, a estimativa do escoamento superficial, através do CN2, resultou em valores um pouco mais altos em regiões urbanizadas. Esse aumento indica maiores vazões para determinadas quantidades de precipitação diante das condições de cobertura do solo. O ajuste do CN2 resultou em uma redução média de 13,8% em relação aos valores iniciais, favorecendo a redução das vazões de pico simuladas previamente pelo modelo. Já a distribuição espacial da condutividade hidráulica saturada do solo, SOL\_K, apresentou um acréscimo gradual de oeste para leste da bacia, com os maiores valores no posto fluviométrico Engenho Sítio. Os valores médios do SOL\_K na bacia foram reduzidos em 19,6% com a calibração.

Outro parâmetro que influencia a geração do escoamento superficial é o SOL\_AWC que, espacialmente, apresentou uma redução gradativa de montante à jusante na bacia. Em relação ao ajuste, houve um acréscimo percentual médio de 34,2% a partir dos valores iniciais do SOL\_AWC, refletindo uma maior retenção de água no solo e, com isso, uma redução do escoamento superficial. Comportamento semelhante das variações percentuais após ajuste dos parâmetros, redução do CN2 e SOL\_K e aumento do SOL\_AWC, foi encontrado por Santos *et al.* (2021) na bacia do rio Tapacurá, sub-bacia do rio Capibaribe.

Figura 22 - Espacialização dos valores dos parâmetros ajustados para as áreas de contribuição dos postos fluviométricos da bacia.



Fonte: O autor (2024).

Em relação aos componentes de perdas por evaporação e interceptação vegetal, o parâmetro CANMX, que representa a capacidade máxima de interceptação quando o dossel está completamente desenvolvido, apresentou os maiores resultados nas áreas com maiores coberturas vegetais. As variações dos valores calibrados do CANMX (1,63 a 8,43) aproximam-se de resultados reportados em calibrações de bacias próximas e com características semelhantes à do rio Capibaribe, como a bacia do Pirapama (Viana, 2019), com valores desse parâmetro entre 0,15 e 9,25, e a bacia do rio Una (Carvalho Neto, 2018), com CANMX calibrado variando de 0 a 4,1.

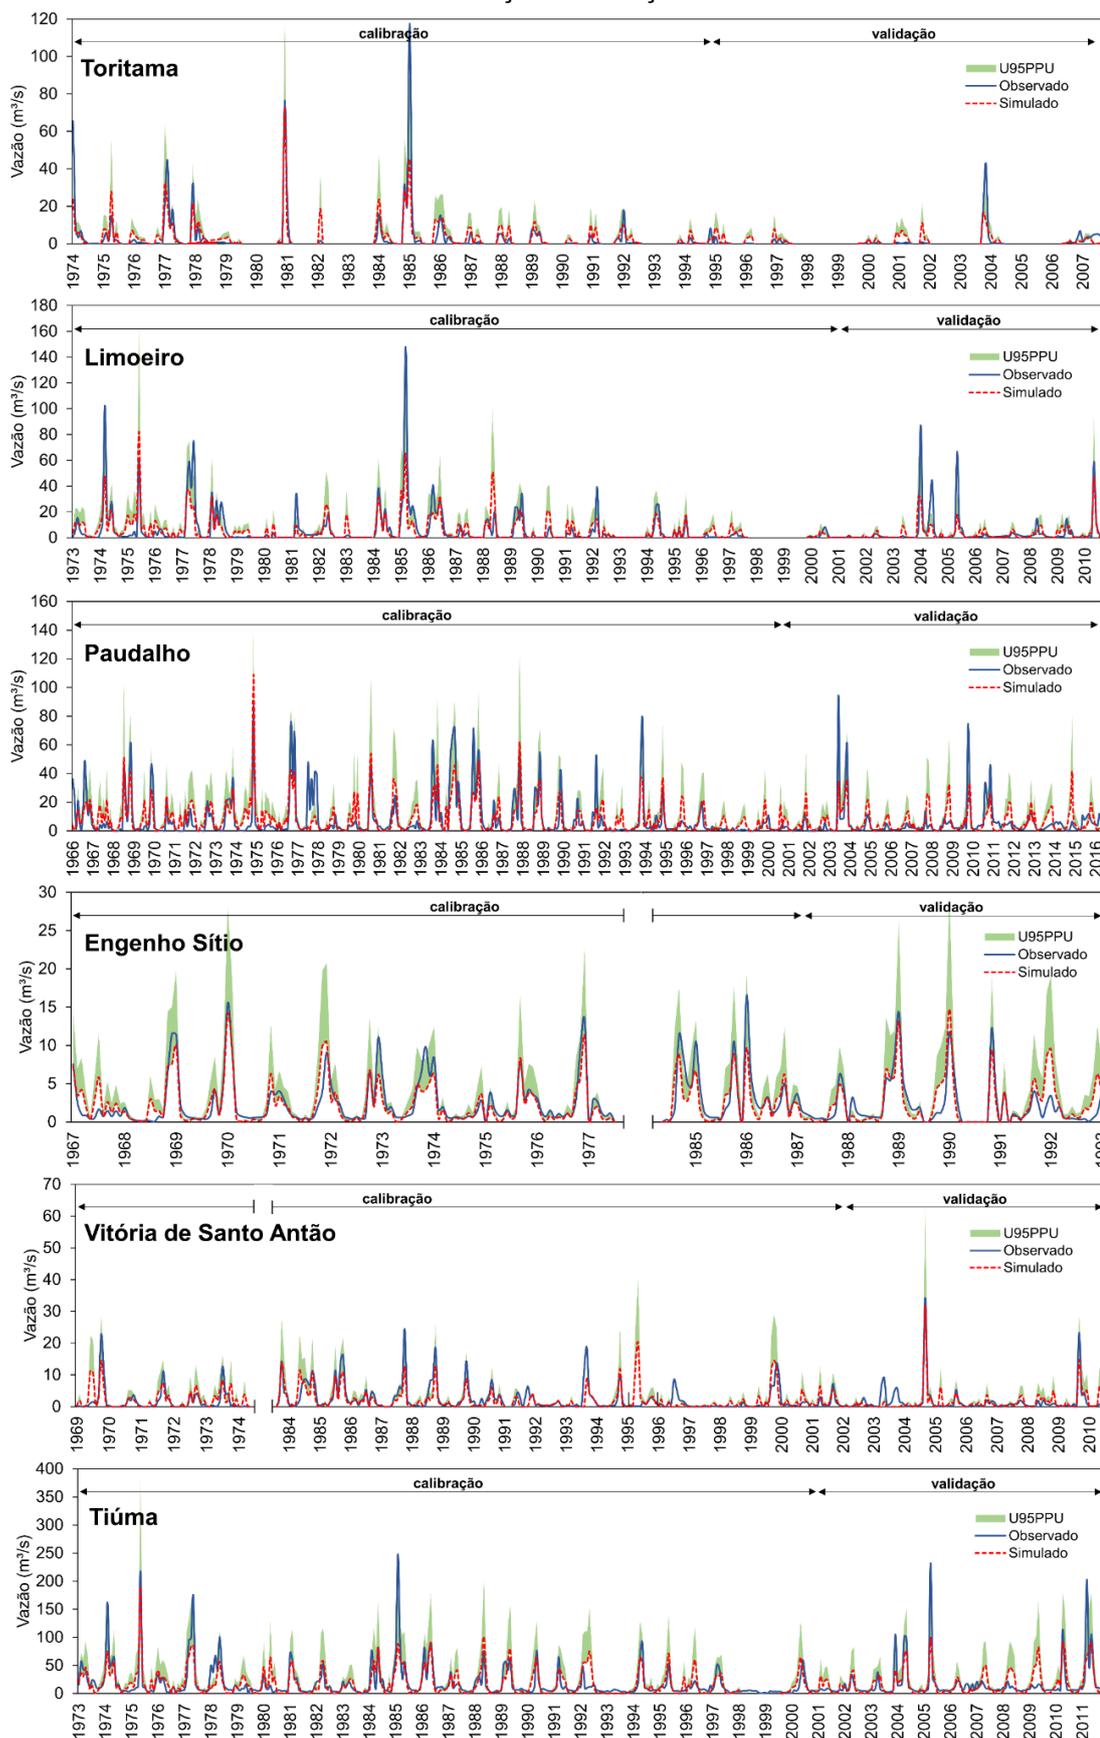
Já a distribuição do fator de compensação da evaporação do solo, ESCO, apresentou os menores valores na região semiárida da bacia e maiores no litoral. Baixos valores do ESCO correspondem a uma maior extração de água das camadas profundas do solo para atender as demandas evaporativas, o que reduz a contribuição para o escoamento superficial (Boongaling; Faustino-Eslava; Lansigan, 2018; Kaffas; Hrisanthou; Sevastas, 2018). Quanto à interação entre o aquífero raso e a zona radicular, GW\_REVAP, os valores calibrados foram maiores nas áreas situadas na Zona da Mata, indicando uma menor restrição da ascensão da água do aquífero às camadas superficiais do solo.

A partir do ajuste dos parâmetros utilizados no processo calibração, foram simuladas as vazões para todos os postos da bacia. A Figura 23 ilustra os hidrogramas simulados e observados das seis estações, e os valores das incertezas do processo de modelagem, representados pela largura do U95PPU (incerteza de probabilidade de 95%). Além disso, os valores dos índices de desempenho da simulação para a calibração inicial, considerando total a série, e para calibração e validação, série particionada, são ilustrados na Figura 24. De modo geral, as vazões mensais simuladas conseguiram capturar a variabilidade temporal dos hidrogramas observados, com as vazões mínimas bem representadas pelo modelo. No entanto, algumas diferenças são notáveis, sobretudo nas vazões de pico que foram subestimadas na calibração e validação.

Nos postos com regimes intermitentes, como é o caso de Toritama e Limoeiro, o modelo conseguiu representar razoavelmente bem as vazões em períodos secos. Entretanto, não foi capaz de reproduzir satisfatoriamente as cheias, notável principalmente em 1974, 1985 e 2004. Nas áreas de contribuição com leitos afluentes e independentes do fluxo do rio principal, como é o caso dos postos Engenho Sítio e Vitória de Santo Antão, as simulações apresentaram uma boa correspondência com os dados observados, mas ainda ocorrem subestimativas dos picos, embora sejam as menos acentuadas. Já na região com os maiores regimes pluviométricos e, conseqüentemente, maiores vazões, como em Paudalho e Tiúma, o modelo capturou bem a sazonalidade do regime fluviométrico, com uma melhor concordância nos períodos com vazões menos acentuadas.

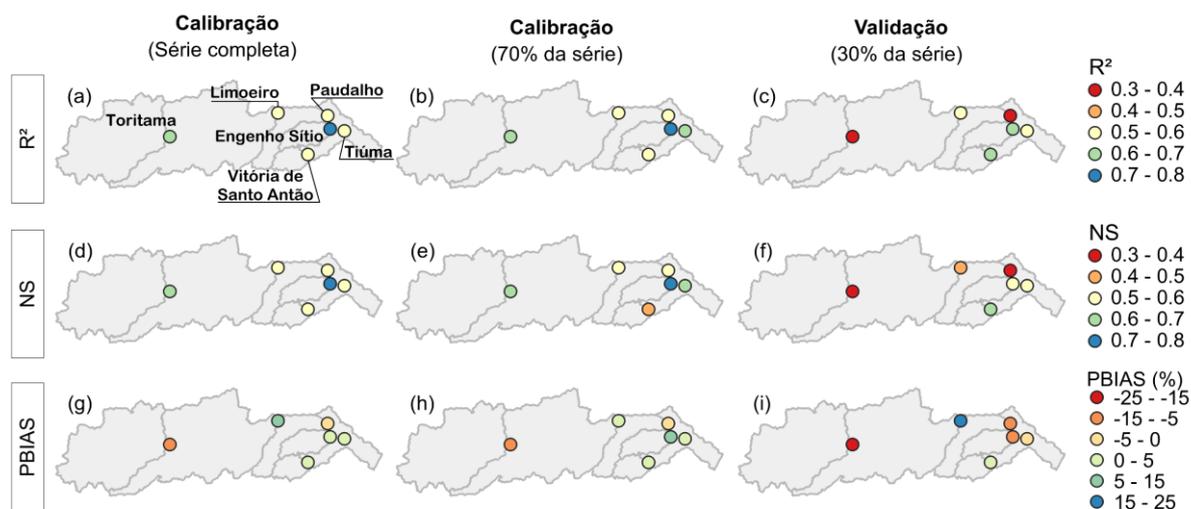
Quanto ao resultado de desempenho das simulações (Figura 24), as eficiências entre a calibração inicial foram equivalentes à calibração utilizando 70% da série. Entre essas simulações, alguns índices melhoraram sutilmente com a série particionada, como é o caso das estações Tiúma ( $r$  e NS) e Limoeiro (PBIAS), enquanto houve uma pequena redução do desempenho em Vitória de Santo Antão (NS) e Engenho Sítio (PBIAS). A calibração com 70% da série resultou, de modo geral, em um bom desempenho, com valores de  $R^2$  entre 0,5 e 0,76, e valores de NS entre 0,47 e 0,75, indicando uma consistência razoável nos postos. O PBIAS demonstrou que a calibração foi muito boa ( $< \pm 10\%$ ) na maioria das estações. Já na validação, houve uma redução no desempenho dos índices, com o  $R^2$  variando entre 0,32 e 0,66, NS entre 0,30 e 0,65 e PBIAS entre -17,3 a 24%.

Figura 23 - Comparação entre as vazões mensais simuladas e observadas nos períodos de calibração e validação.



Fonte: O autor (2024).

Figura 24 - Valores dos índices de desempenho para os seis postos fluviométricos.



Fonte: O autor (2024).

A calibração e validação resultaram em eficiências distintas entre os postos. Especificamente, o posto Engenho Sítio destacou-se na calibração com os melhores resultados, apresentando um  $R^2$  de 0,76 e NS de 0,75, embora tenha subestimado a vazão observada em 11,3%. Em Toritama, o desempenho da calibração foi satisfatório, com um  $R^2$  de 0,68 e NS de 0,64, superestimando um pouco a vazão com o PBIAS de -5,4%. Para o posto Tiúma, que recebe contribuição de todos os postos à montante, o valor de  $R^2$  e NS foi de 0,62, enquanto PBIAS foi de 2,7%, demonstrando um desempenho razoável e uma leve subestimativa da vazão. Paudalho e Limoeiro apresentaram valores intermediários na calibração, com NS de 0,56 e 0,55, respectivamente, e  $R^2$  de 0,56 para os dois postos. No posto Paudalho, o resultado do PBIAS, de -3,8%, indicou uma pequena superestimativa da vazão observada, enquanto na estação Limoeiro houve uma subestimativa de 1,5%. O menor desempenho da calibração foi obtido no posto Vitória de Santo Antão, com  $R^2$  de 0,5 e NS de 0,47, embora o PBIAS de 0,1%, menor valor obtida na calibração, tenha indicado uma boa simulação das médias mensais.

A respeito da validação, o posto Engenho Sítio manteve um resultado satisfatório para o  $R^2$  e NS, de 0,66 e 0,58, respectivamente, mas o PBIAS de -11,6% demonstrou uma tendência de superestimativa do hidrograma observado. Toritama e Paudalho apresentaram os menores desempenhos da simulação, com  $R^2$  de 0,32 e NS de 0,3 para as duas estações, considerados insatisfatórios segundo a classificação de Moriasi *et al.* (2007). Nesses dois postos, apesar dos valores do PBIAS indicarem as maiores superestimativas, com -17,3% em Toritama e -13,9% em

Paudalho, o desempenho do índice ainda é considerado satisfatório. Limoeiro resultou em um desempenho insatisfatório dos valores de  $R^2$  (0,54) e NS (0,48), apresentando um aumento considerável na subestimativa da vazão, com PBIAS de 24%. O posto Tiúma manteve um desempenho razoável, com  $R^2$  e NS de 0,51, e o PBIAS de -2,5%. Já o posto Vitória de Santo Antão foi o único que apresentou um aumento no valor do  $R^2$  e NS, ambos de 0,65, enquanto o PBIAS resultou em uma pequena subestimativa de 3,9%.

O desempenho da simulação foi avaliado como satisfatório na maioria dos postos. Entretanto, essas estações são altamente influenciadas por reservatórios situados a montante, principalmente em Paudalho e Tiúma. Ainda que tenham sido incluídos dados referentes à parametrização dos principais reservatórios na modelagem, o processo de calibração foi dificultoso para atingir um desempenho razoavelmente satisfatório em algumas estações. A falta de dados de monitoramento das vazões liberadas e a retirada de água nos reservatórios, bem como a heterogeneidade e mudanças no uso e ocupação do solo, não capturadas pelo modelo, interferiram numa maior precisão da simulação.

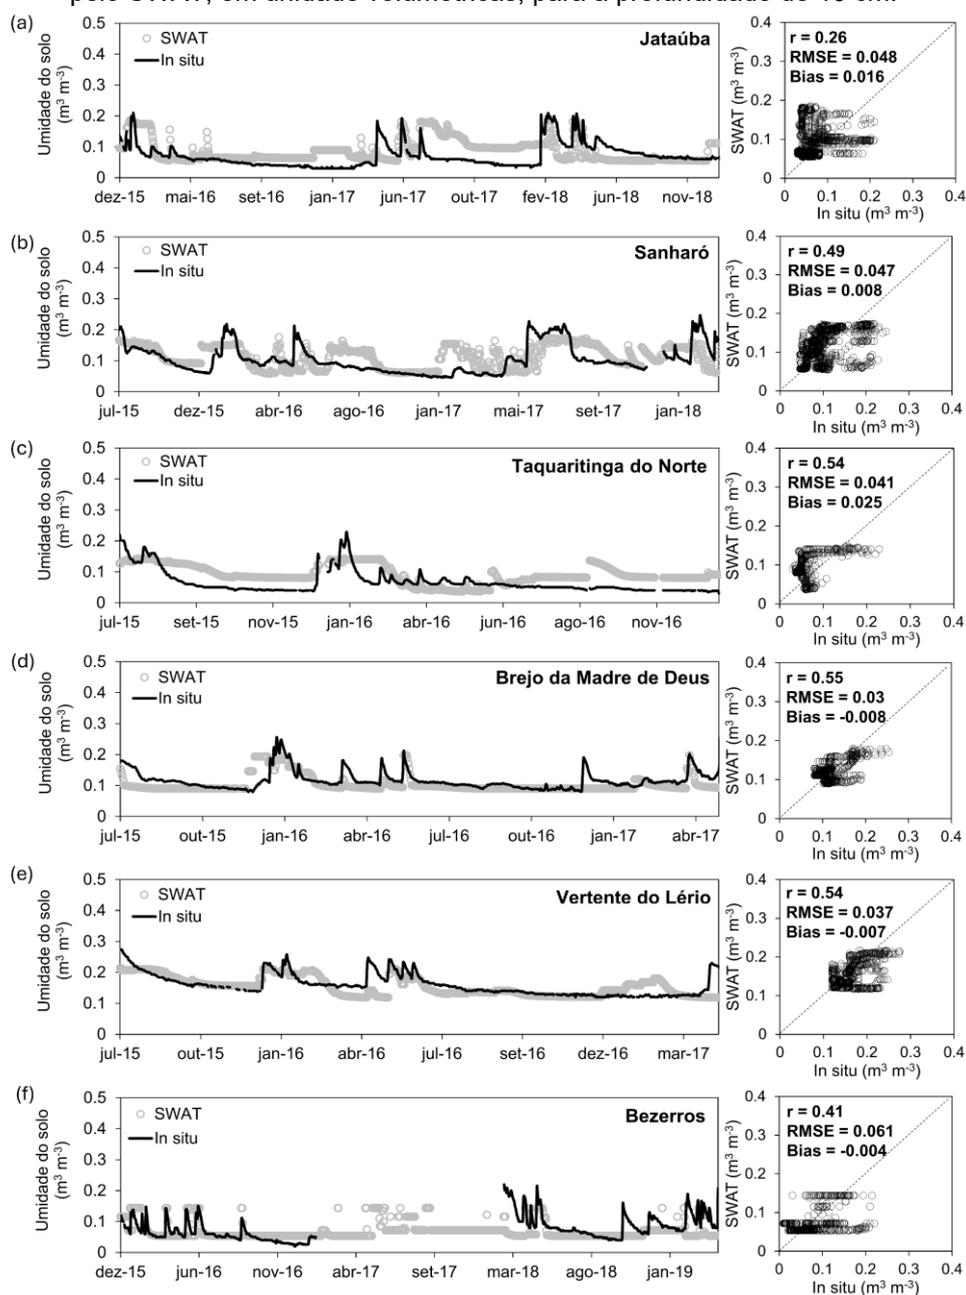
Quanto aos resultados insatisfatórios, que ocorreram principalmente na validação, a inclusão de dados mais detalhados poderia melhorar o desvio dos valores simulados do conjunto de dados observados. No entanto, para o objetivo desta pesquisa, o desempenho do modelo foi considerado adequado, uma vez que a variável utilizada, a umidade do solo, foi agregada em médias mensais para a análise das secas. Além disso, a umidade do solo tende a apresentar uma maior persistência em comparação com a vazão, ou seja, possui uma menor variabilidade ao longo do tempo, o que contribui para uma maior precisão na modelagem hidrológica.

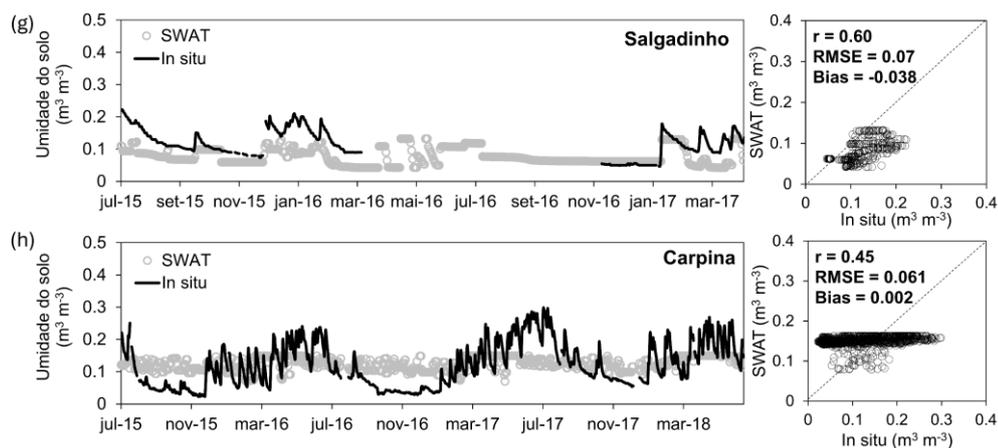
Outros estudos, realizando simulação hidrológica em sub-bacias do Capibaribe, obtiveram eficiências semelhantes à de alguns postos desta pesquisa, como Ribeiro Neto *et al.* (2014), utilizando o modelo MODHAC, e Montenegro e Ragab (2012) e Santos *et al.* (2021), utilizando o DiCaSM e o SWAT, respectivamente, para modelar a bacia do rio Tapacurá.

#### 4.4.2 Validação dos dados modelados de umidade do solo

Após a calibração e validação do modelo, os dados diários de umidade do solo foram extraídos por HRUs e, em sequência, ponderados para sub-bacia, convertidos em unidade volumétrica e, por fim, comparados com as observações *in-situ*. A Figura 25 apresenta a comparação entre a umidade do solo diária simulada e observada na profundidade de 10 cm, com respectivos diagramas de dispersão e métricas de erro ( $r$ , RMSE e Bias).

Figura 25 - Comparação da umidade do solo diária observada *in-situ* e da umidade do solo simulada pelo SWAT, em unidade volumétricas, para a profundidade de 10 cm.





Fonte: O autor (2024).

A variabilidade da umidade diária observada foi capturada pelo modelo em alguns períodos da série, como ocorre, por exemplo, nos postos Brejo da Madre de Deus, Vertente do Lério e Bezerros. Nas estações Jataúba, Sanharó e Taquaritinga do Norte, o modelo demonstrou um retardo na recessão da umidade simulada em alguns períodos. No SWAT, essa dinâmica de aumento e diminuição graduais da umidade do solo ocorrem, particularmente, após processos de umedecimento e secagem por chuva e evapotranspiração (Zare; Azam; Sauchyn, 2022). Evidentemente, os parâmetros utilizados na calibração, as características físicas e hidráulicas do solo medidas em campo, e informações precisas do manejo agrícola também interferem na resposta do modelo ao simular o conteúdo de água no solo (mm) (Choudhary; Athira, 2021; Curk; Glavan; Pintar, 2020; Lins *et al.*, 2024; Sehgal *et al.*, 2018). Dentre esses fatores, a parametrização do solo pareceu não ser suficientemente adequada para o SWAT simular a amplitude (valores extremos altos e baixos) da umidade na região leste da bacia, como pode ser visualizado pela limitação da variabilidade no posto Carpina.

Em relação ao desempenho do modelo, a maioria das estações foi classificada como moderada (0,4 a 0,69) para o  $r$  de Pearson, com exceção de Jataúba, que obteve o menor desempenho ( $r = 0,26$ ). O RMSE apresentou a melhor precisão no posto Brejo da Madre de Deus ( $0,03 \text{ m}^3 \text{ m}^{-3}$ ), onde é visível a correspondência da variação da umidade do solo simulada em relação a observada. A menor precisão do RMSE foi observada no posto Salgado ( $0,07 \text{ m}^3 \text{ m}^{-3}$ ), seguido de Bezerros e Carpina ( $0,061 \text{ m}^3 \text{ m}^{-3}$ ). Os resultados positivos e negativos do bias indicam superestimativas e subestimativas nos dados simulados. Em algumas estações os valores próximos a zero podem indicar uma boa precisão do modelo, como em

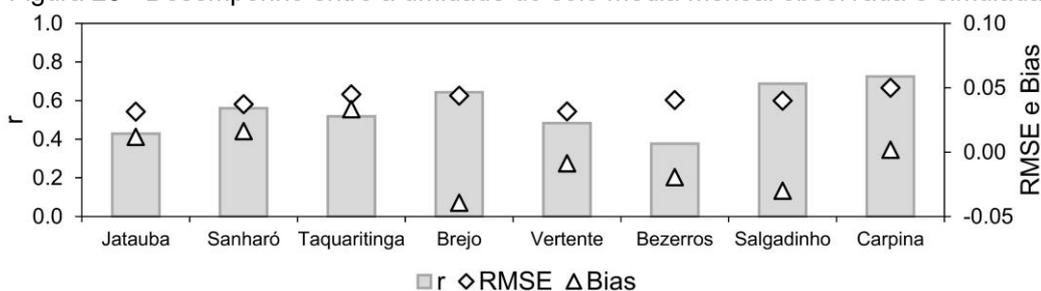
Carpina ( $0,002 \text{ m}^3 \text{ m}^{-3}$ ) e Bezerros ( $-0,004 \text{ m}^3 \text{ m}^{-3}$ ). No entanto, é preciso analisar a flutuação dos dados, visto que baixos valores do bias podem ser resultantes de picos positivos e negativos da umidade observada ou simulada, exatamente o que ocorre no posto Carpina. Superestimativas do modelo foram mais evidentes na estação Taquaritinga do Norte ( $0,025 \text{ m}^3 \text{ m}^{-3}$ ) e Jataúba ( $0,016 \text{ m}^3 \text{ m}^{-3}$ ), enquanto a maior subestimativa foi observada em Salgadinho ( $-0,038 \text{ m}^3 \text{ m}^{-3}$ ).

Seguindo a mesma abordagem desta pesquisa, Sehgal *et al.* (2018) utilizaram dados de vazão para calibrar 50 bacias do sudeste dos EUA no SWAT, e avaliaram a correspondência da umidade do solo modelada com dados de nove estações *in-situ*. Para uma profundidade de 10 cm, os autores obtiveram correlações variando de 0,32 a 0,72, e valores de RMSE entre 0,029 e 0,290  $\text{m}^3 \text{ m}^{-3}$ . Martínez-Fernández *et al.* (2023) utilizaram sensoriamento remoto (SMOS e SMAP) para avaliar a umidade do solo simulada pelo SWAT, calibrado apenas com dados de vazão, na bacia do rio Henares, na Espanha. Na camada superficial (0-30 cm), os autores obtiveram valores medianos de  $r$  entre 0,63 e 0,66 para o SMOS, e entre 0,7 e 0,71 para o SMAP. Os valores medianos de bias variaram entre  $-0,015$  e  $-0,026 \text{ m}^3 \text{ m}^{-3}$  para o SMOS, e entre  $-0,019$  e  $-0,030$  para o SMAP. Sem realizar a calibração do modelo, Qi *et al.* (2018) testaram o desempenho da umidade simulada em diferentes profundidades utilizando o SWAT sem modificações e integrando um algoritmo baseado na equação de Richards. Mesmo sem calibração e sem ajuste do modelo, foram observados, na camada de 10 cm e em dez estações localizadas no estado de Maryland, USA, valores absolutos de bias entre 0 e  $0,14 \text{ m}^3 \text{ m}^{-3}$ , e  $R^2$  variando de 0,22 a 0,55. Com o ajuste, os valores absolutos do bias reduziram, em média,  $0,04 \text{ m}^3 \text{ m}^{-3}$ , enquanto o  $R^2$  aumentou, em média, 0,11. Com base nos resultados nas camadas de 10 e 50 cm, os autores afirmam que o SWAT é capaz de simular razoavelmente a dinâmica geral da água no solo dessas profundidades.

Considerando que neste estudo as análises de seca são realizadas em escala mensal, uma outra avaliação de desempenho foi aplicada aos dados médios mensais da umidade do solo simulada (Figura 26). De modo geral, os resultados demonstraram uma melhora na umidade do solo modelada em relação à observada na maioria das estações. Isso é notório ao avaliar os valores de  $r$  nos postos Carpina (0,72), Salgadinho (0,69) e Brejo da Madre de Deus (0,64). Outro destaque na melhoria foi o posto Jataúba, que apresentou um aumento de 0,17 no  $r$  em relação a correlação diária. As estações Vertente do Lério, Bezerros e Taquaritinga do Norte mostraram

redução do coeficiente de correlação, embora com uma diferença média relativamente pequena, de -0,037. Além disso, os valores do RMSE diminuíram na maioria dos postos, indicando uma melhoria na precisão dos dados mensais simulados. As tendências de superestimativas e subestimativas foram mantidas em todas as estações, com apenas os postos Jataúba, Salgadinho e Carpina demonstrando uma melhoria nos valores do bias.

Figura 26 - Desempenho entre a umidade do solo média mensal observada e simulada.



Fonte: O autor (2024).

Vale destacar que as comparações diárias e mensais foram realizadas utilizando a umidade do solo média da área das sub-bacias, através dos dados de HRUs, e a umidade capturada pontualmente nos postos. Essa diferença de escala entre as medições *in-situ* e a umidade do solo simulada o SWAT pode ter introduzido um desvio sistemático nos dois conjuntos de dados (Sehgal *et al.* 2018), juntamente com os fatores associados à complexidade da simulação do conteúdo de água no solo pelo modelo, conforme citado anteriormente. Além disso, este estudo utilizou um processo de calibração padrão dos parâmetros hidrológicos do SWAT apenas com dados de vazão, o que pode ter interferido na precisão da simulação da umidade do solo. Embora alguns resultados da análise de desempenho tenham apresentado precisões razoáveis, o modelo conseguiu capturar as flutuações sazonais e interanuais da umidade do solo para algumas estações na bacia.

Outros estudos seguiram a mesma abordagem de calibração para obtenção da umidade do solo no SWAT e a utilizaram adequadamente em análises de secas em diferentes regiões globais, como no semiárido brasileiro (Silva *et al.*, 2024) e iraniano (Kamali *et al.*, 2017), no Pampa argentino (Havrylenko, *et al.* 2016), o Nordeste da China (Chen *et al.*, 2019), e no Sudeste dos EUA (Sehgal; Sridhar, 2019) e da Ásia (Nguyen *et al.*, 2023). Dessa forma, considerando que adiante as séries mensais de umidade do solo são transformadas em anomalias e, juntamente com outros índices,

utilizadas para análise de secas, ressalta-se que os dados simulados foram satisfatórios para o objetivo deste estudo.

#### 4.5 RELAÇÃO ENTRE A SECA METEOROLÓGICA, SECA AGRÍCOLA E SECA DA VEGETAÇÃO.

A partir da obtenção dos dados de umidade do solo no SWAT, foram calculadas as séries do índice de seca agrícola, SSMI, em várias escalas mensais (1 a 12 meses) e para diferentes profundidades. Com isso, a relação entre os tipos de secas foi avaliada por meio da correlação de Pearson, considerando os diferentes meses (janeiro a dezembro) (Zhou *et al.*, 2021), defasagens e escalas entre as séries (Chen *et al.*, 2019; Oertel *et al.*, 2018). Os resultados da correlação entre o SPI-*n* com diferentes defasagens e o SSMI-1 (1982 a 2020), assim como entre o SSMI-*n* com defasagens e o aNDVI-1 (2002 a 2020), para as quatro sub-bacias representativas das unidades de análise, são mostradas através de heatmaps nas Figura 27 a 30.

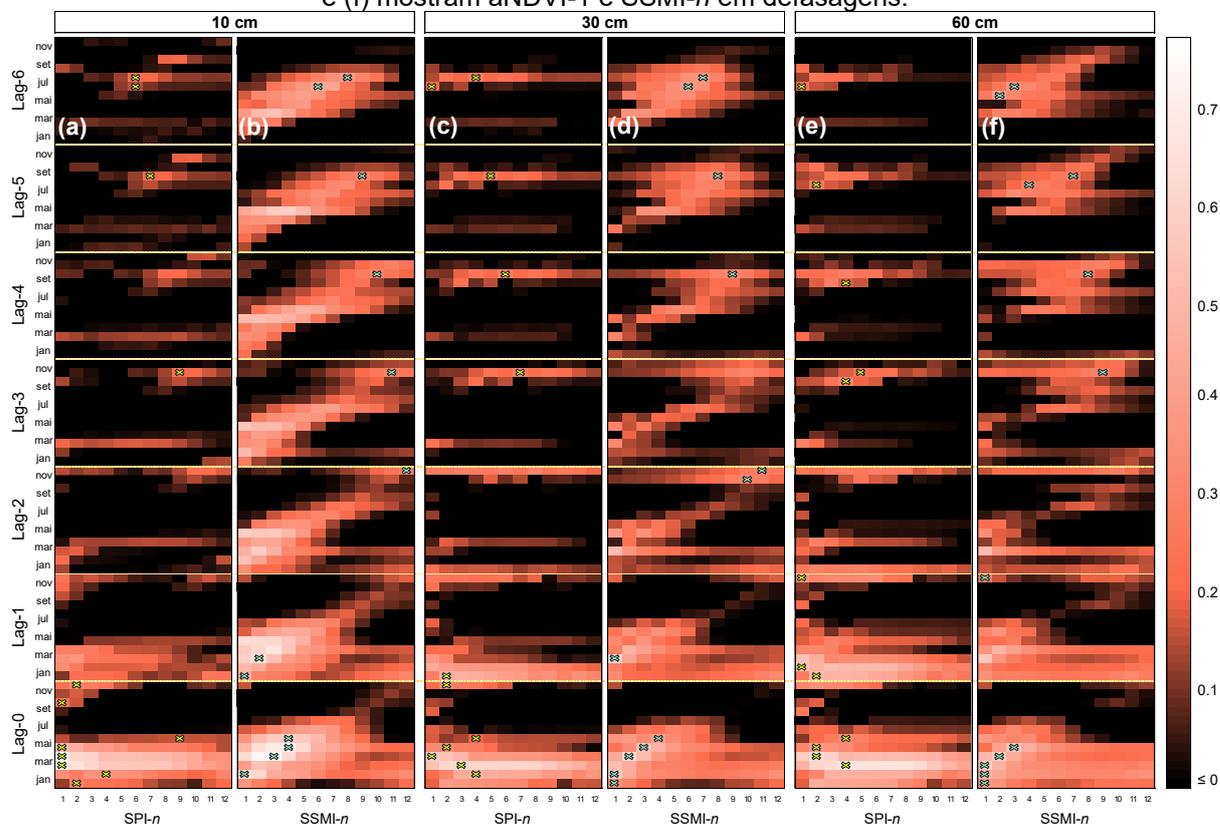
É possível observar que as correlações mais altas, indicadas por um x, concentraram-se predominantemente nas análises sem defasagens temporais (lag-0), indicando que em alguns meses há uma resposta rápida entre os índices. No lag 0, os meses de abril e maio são comuns entre as quatro sub-bacias, apresentando uma boa interação entre a seca agrícola e seca meteorológica. Já em relação à vegetação, maio é o mês em comum nas sub-bacias 31, 18 e 42, onde ocorre alta interação entre o aNDVI e o SSMI. A respeito das melhores relações entre os índices, de modo geral, percebe-se padrões distintos entre as sub-bacias analisadas. Por exemplo, a correlação entre o SPI e SSMI mostrou-se mais robusta na sub-bacia 42, com valores notavelmente altos, principalmente durante meses chuvosos na região, como abril e maio (Silva *et al.*, 2022b). Por outro lado, a relação entre a seca na vegetação e a seca agrícola foi mais pronunciada na sub-bacia 18, com o valor máximo de correlação no mês de julho, na profundidade total do solo (0-60 cm), refletindo uma resposta acentuada do aNDVI ao SSMI após o período chuvoso.

Em relação às multicamadas da umidade do solo, verifica-se que as maiores correlações entre SPI-*n* e SSMI-1 ocorreram na profundidade superficial, entre os meses de março a abril e na escala de 1 mês, demonstrando uma relação mais direta e sensível à precipitação. Na camada intermediária (0-30 cm) e na profundidade total também ocorreram correlações altas (> 0,6), mas em escalas de SPI entre 2 e 6 meses

para as sub-bacias 31, 18 e 4. Isso sugere que, no Agreste e na transição da Zona da Mata, embora seca meteorológica influencie a umidade do solo em camadas mais profundas, a resposta está associada à deficiência ou acúmulo de precipitação durante os 2 a 6 meses anteriores. Na sub-bacia 42, as maiores correlações ( $> 0,8$ ), em todas as profundidades, ocorreram no outono (março a maio) com o SPI-1, indicando uma resposta imediata as condições de chuva em todo o perfil do solo.

Quanto ao aNDVI-1 e SSMI- $n$ , observa-se que as maiores correlações ocorreram nos meses de abril a julho e, majoritariamente, nas profundidades superficiais e intermediárias. No entanto, a sub-bacia 18 apresentou a máxima correlação de toda a análise (0,91) na profundidade total. As escalas do SSMI diminuíram com o aumento da profundidade do solo, em especial na sub-bacia 42, indicando que a seca da vegetação corresponde à deficiência de umidade do solo acumulada de maneira mais imediata nas camadas profundas e mais gradual nas camadas superficiais.

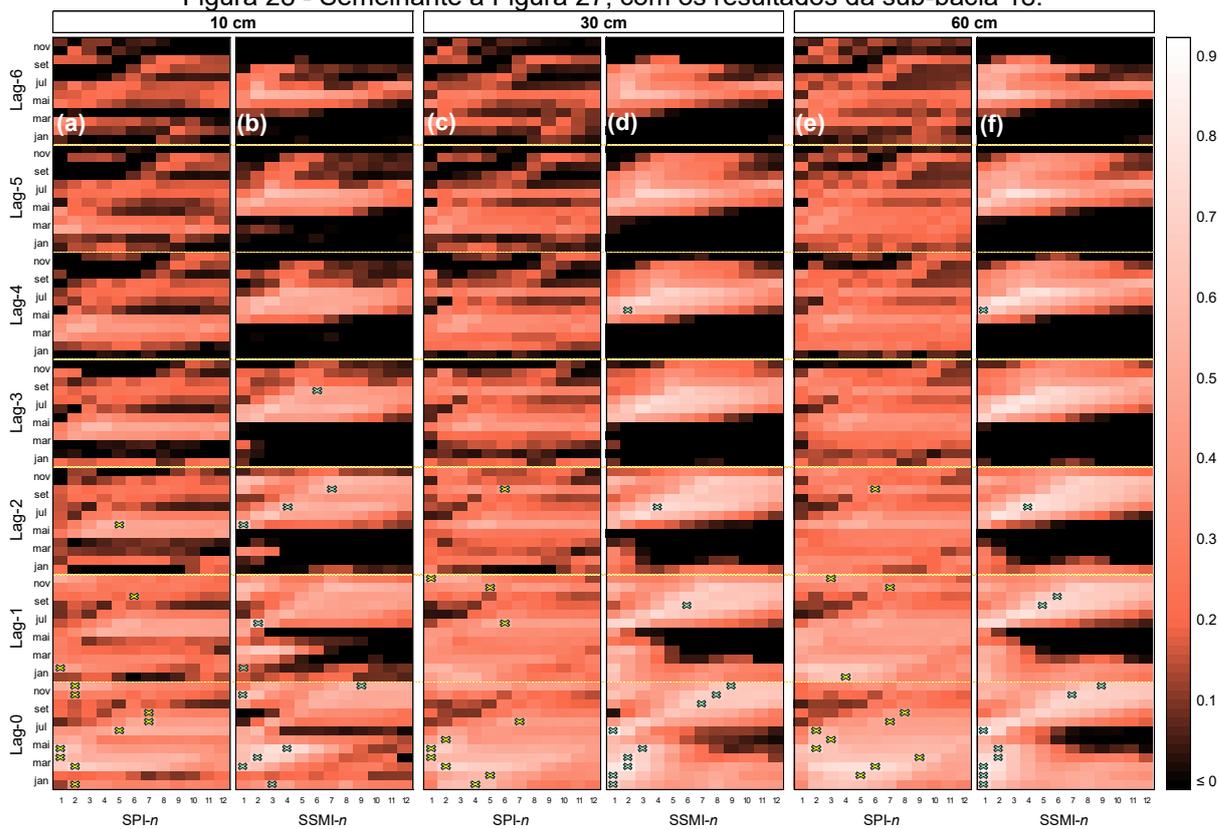
Figura 27 - Heatmap da correlação média mensal entre índices em diferentes defasagens e profundidades do solo da sub-bacia 31: (a), (c) e (e) mostram SSMI-1 e SPI- $n$  em defasagens; (b), (d) e (f) mostram aNDVI-1 e SSMI- $n$  em defasagens.



O símbolo x indica valores máximos de correlação para cada mês.

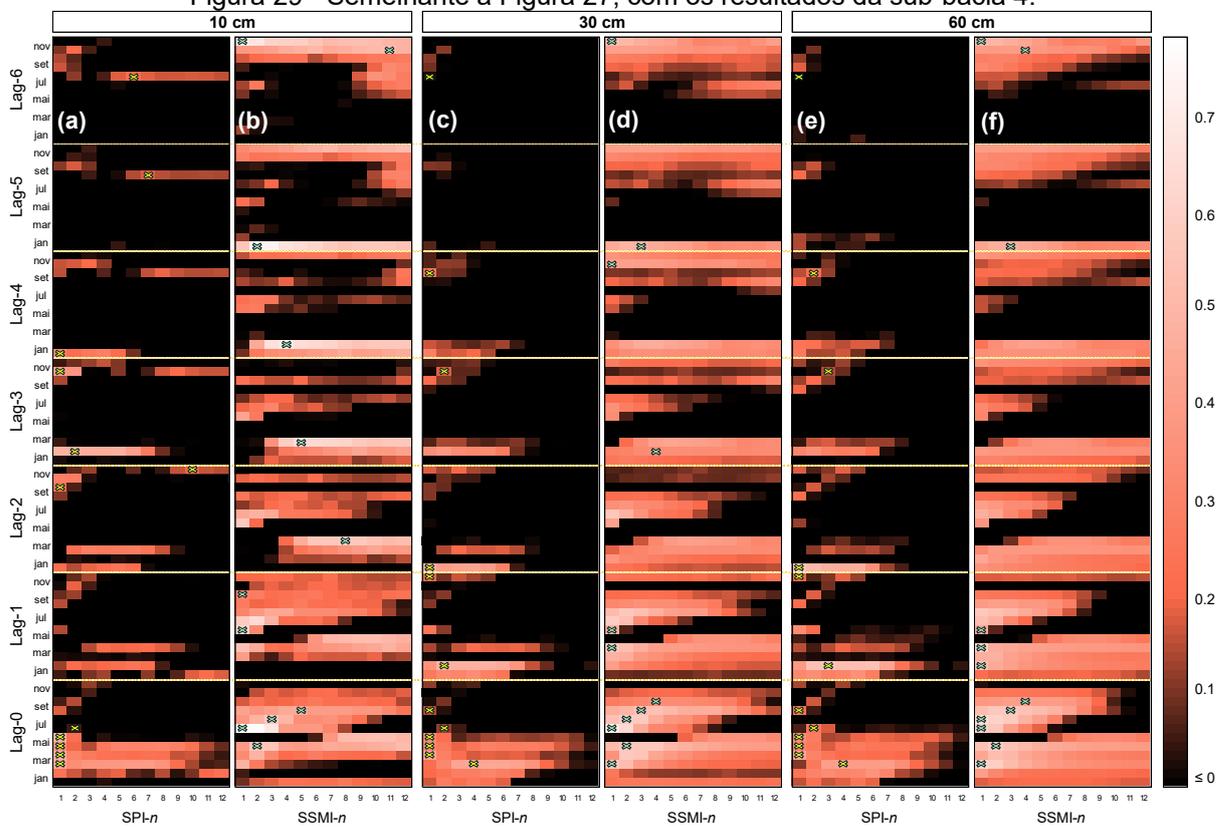
Fonte: O autor (2024).

Figura 28 - Semelhante à Figura 27, com os resultados da sub-bacia 18.



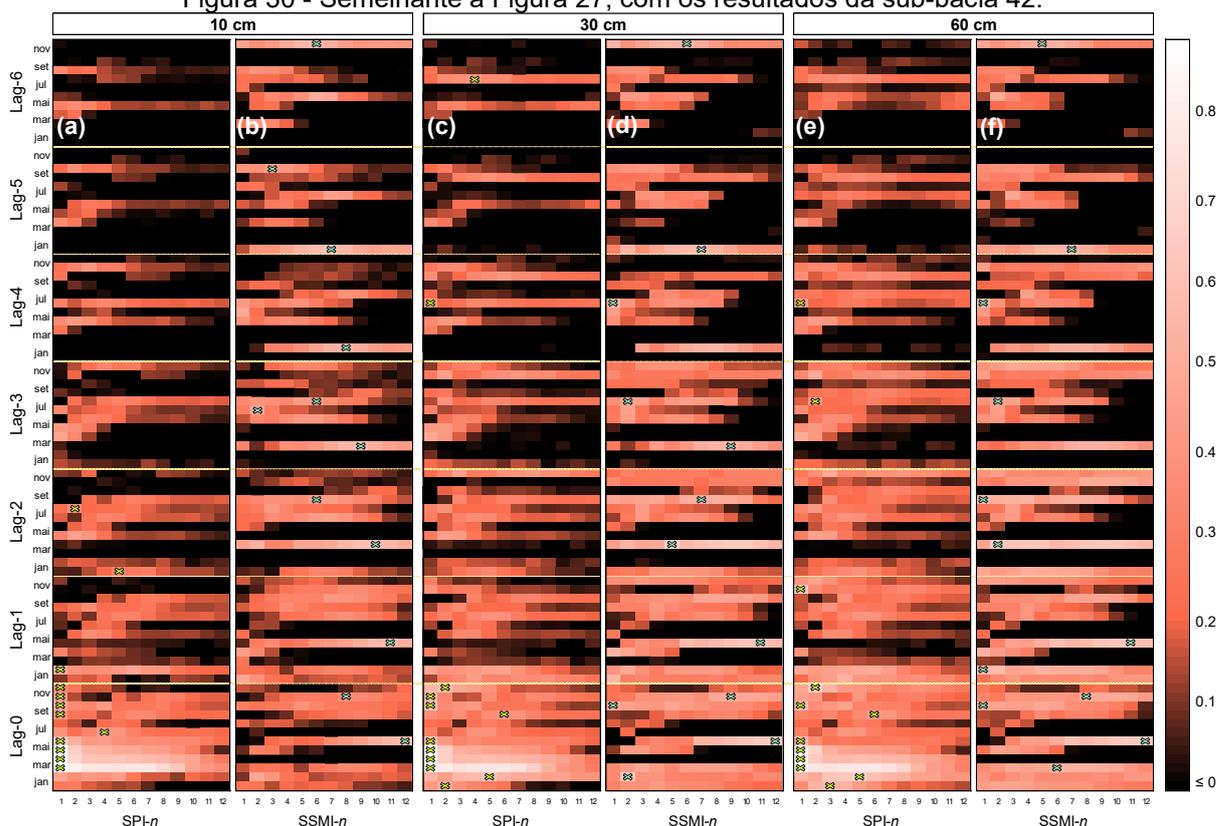
Fonte: O autor (2024).

Figura 29 - Semelhante à Figura 27, com os resultados da sub-bacia 4.



Fonte: O autor (2024).

Figura 30 - Semelhante à Figura 27, com os resultados da sub-bacia 42.



Fonte: O autor (2024).

Os períodos de retardo correspondentes às maiores correlações apresentaram comportamentos distintos entre os tipos de transições das secas e entre as sub-bacias. De modo geral, as maiores defasagens com correlações máximas ocorreram entre o SSMI- $n$  e o aNDVI-1, principalmente na região leste da bacia, nos meses de dezembro e janeiro. A influência do retardo da seca meteorológica na seca agrícola também apresentou correlações máximas em lags maiores, porém com baixos valores.

Os valores das escalas com as máximas correlações foram utilizados para identificar os tempos de propagação da seca meteorológica para a seca agrícola e da seca agrícola para a seca na vegetação, considerando todas as defasagens e profundidades da umidade do solo (Tabela 7). Exemplificando, de acordo com os resultados da profundidade de 0-30 cm na sub-bacia 31, Figura 27(a) e (b), as maiores correlações na primavera (SON) ocorreram nas escalas de tempo de 5, 6 e 7 meses (SPI- $n$  e SSMI-1) e nas escalas de 8, 9 e 10 meses (SSMI- $n$  e aNDVI-1); no verão (DJF), a correlação máxima ocorreu nas escalas de 2 e de 4 meses (SPI- $n$  e SSMI-1) e nas escalas de 11 meses e de 1 mês (SSMI- $n$  e aNDVI-1); no outono (MAM), as

correlações máximas ocorreram nas escalas de 3, 1 e 2 meses (SPI-*n* e SSMI-1) e nas escalas de 1, 2 e 3 meses (SSMI-*n* e aNDVI-1); e no inverno (JJA), as correlações máximas ocorreram nas escalas de 4, 1 e 4 meses (SPI-*n* e SSMI-1) e nas escalas de 4, 6 e 7 meses (SSMI-*n* e aNDVI-1). Dessa forma, os tempos médios de propagação da seca meteorológica para a agrícola e depois para a seca na vegetação nas estações foram, respectivamente, de 6 e 9 meses, 3 e 4 meses, 2 e 2 meses e 3 e 6 meses.

Tabela 7 - Tempos médios de propagação da seca meteorológica (SPI) para a seca agrícola (SSWI) e da seca agrícola para a seca da vegetação (aNDVI).

Sub-bacia	Profundidade (cm)	primavera		verão		outono		inverno	
		M-A	A-V	M-A	A-V	M-A	A-V	M-A	A-V
31 (Agreste)	0-10	6	10	3	5	1	3	7	6
	0-30	6	9	3	4	2	2	3	6
	0-60	4	8	1	1	3	2	2	3
18 (Agreste)	0-10	3	5	2	4	2	2	6	2
	0-30	4	7	4	4	1	2	7	2
	0-60	6	6	5	4	5	2	6	2
4 (Transição)	0-10	3	6	4	2	1	4	3	2
	0-30	1	3	1	2	2	1	1	1
	0-60	2	4	1	2	2	1	1	1
(RMR)	0-10	1	6	2	7	1	10	2	7
	0-30	2	6	3	5	1	8	2	5
	0-60	3	3	3	4	1	6	1	5

M-A representa o tempo de propagação médio, em meses, da seca meteorológica para agrícola, e A-V o tempo de propagação médio da seca agrícola para a seca da vegetação, em meses.

No Agreste, os tempos de propagação entre a seca meteorológica e a agrícola tendem a ser mais curtos no outono (MAM), especialmente na camada superficial do solo. Nessa região, a propagação é mais longa durante o inverno (JJA) e a primavera (SON) nas diferentes camadas do solo, levando de 2 até 7 meses para responder aos déficits meteorológicos. Isso pode estar associado aos efeitos de amortecimento da água armazenada nos solos durante os meses anteriores (Huang *et al.*, 2015), prolongando o tempo de resposta à precipitação reduzida.

No leste da bacia, as transições entre a seca meteorológica e a agrícola são relativamente mais curtas, ou seja, se propagam mais rápido, principalmente no verão,

outono e inverno, nas camadas intermediárias e na profundidade total do solo. Na RMR (sub-bacia 42), por exemplo, ao analisar todas as profundidades, o tempo de propagação foi o mais curto entre todas as sub-bacias, com uma transição média de um mês durante o outono. Isso indica que, em regiões com maiores regimes pluviométricos, leva menos tempo para a seca meteorológica se desenvolver para seca agrícola. Essas respostas rápidas estão associadas à alta frequência de chuva que ocorrem na estação favorecendo o aumento rápido no teor de água do solo (Chen *et al.*, 2019; Huang *et al.*, 2015).

A propagação da seca agrícola, baseada na variação da umidade do solo, para a seca baseada nas condições da vegetação, variou bastante entre as estações e regiões analisadas. Quando ocorre uma seca, a umidade do solo diminui e a condição da vegetação deteriora-se (Zhou, *et al.*, 2021). Dessa forma, a partir do método utilizado, foram observados valores de propagação muito maiores que os encontrados na análise entre as secas meteorológicas e agrícolas. Esses valores foram geralmente maiores na primavera e no verão, em especial nas extremidades oeste e leste da bacia. Nessas regiões, o inverno também apresentou períodos mais longos de propagação, principalmente nas camadas superficiais, com tempo de 6 meses na sub-bacia 6 e de 7 meses na 42. Já nas sub-bacias 18 e 4, os tempos de propagação foram menores e mais uniformes, principalmente durante o verão ao inverno.

Em todo o Agreste, a profundidade total do solo apresentou os menores tempos de propagação, sugerindo uma resposta mais rápida da vegetação à umidade acumulada de todo o perfil do solo nas condições de precipitação anteriores. Na RMR foram observados tempos mais longos de propagação entre as secas, especialmente na camada superficial, atingindo até 10 meses. Esse padrão pode estar associado a capacidade de armazenamento de água no solo, bem como as condições de precipitação intensa nessa região, o que pode afetar na correlação entre o SSMI e o aNDVI nas diferentes escalas e defasagens.

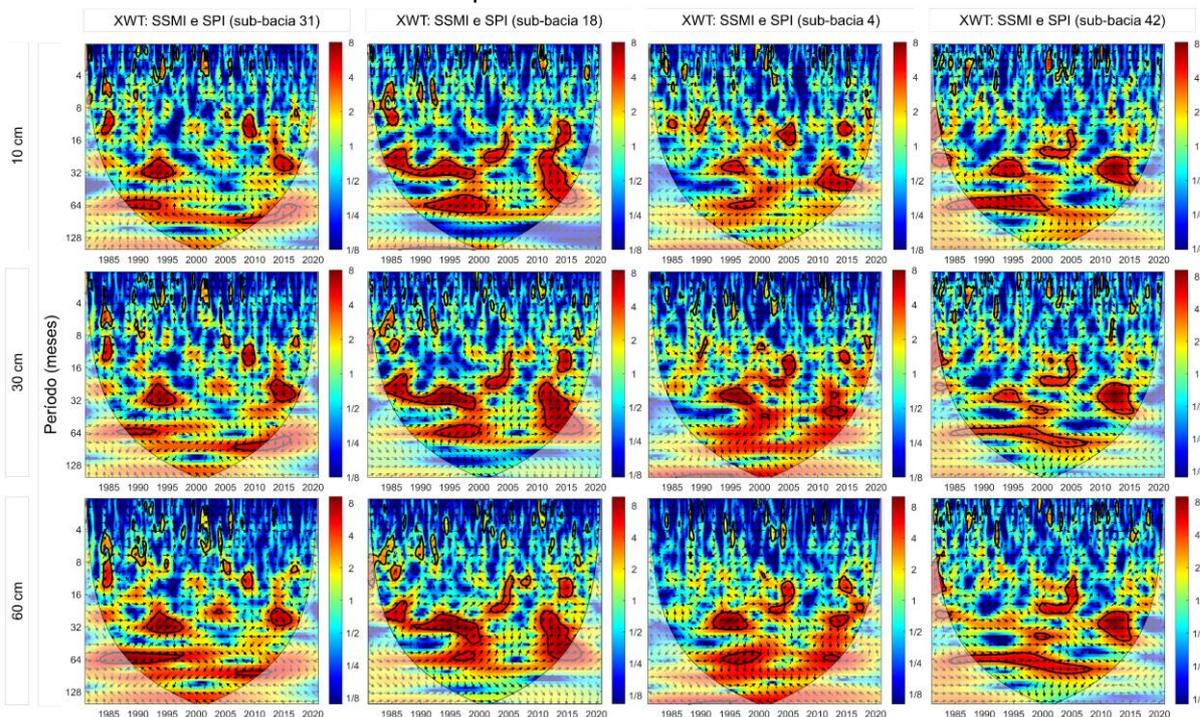
Alguns fatores podem interferir na precisão e nas incertezas associadas aos resultados dos tempos médios de propagação. A análise de demais dados meteorológicos, a mudanças no uso e ocupação do solo e as interferências das atividades humanas podem afetar muito as características e a evolução da seca (Zhou, *et al.*, 2021). Segundo Li *et al.* (2023) os déficits de seca meteorológica podem levar à seca agrícola de forma linear, entretanto os sistemas agrícolas podem exibir resiliência à seca meteorológica caso haja interferência humana, como a irrigação ou

outras intervenções que recarregarem a umidade do solo. O mesmo acontece com as interferências no tempo de propagação da seca na vegetação, que pode ser afetada por atividades de transferência de água entre bacias, irrigação, melhoria e mudanças nos tipos de torração de culturas, pastoreio e mudanças na cobertura do solo (Li *et al.*, 2024). Esses fatores podem enfraquecer a correlação entre os diferentes tipos de seca, resultando em um aumento no tempo de propagação.

A abordagem utilizando análise wavelet foi aplicada entre os índices para detalhar as relações entre os diferentes tipos de secas, considerando ainda as diferentes profundidades do solo. Nesta aplicação, foram utilizadas as séries com escalas mensais de um mês e sem defasagens temporais (SPI-1, SSMI-1 e aNDVI-1), visto que as correlações mais fortes foram observadas, na grande maioria, nessa escala. Os resultados da transformada wavelet cruzada (XWT) e da coerência wavelet (WTC) são ilustrados na Figura 31 e Figura 32, onde a escala de cores varia entre o azul (baixa correlação) ao vermelho (alta correlação), enquanto os contornos destacam correlações estatisticamente significativas. A direção e ângulo das setas indicam a fase das correlações: para a direita, séries positivamente correlacionadas; para a esquerda, séries fora de fase e negativamente correlacionadas; para cima e para baixo, liderança entre as variáveis analisadas.

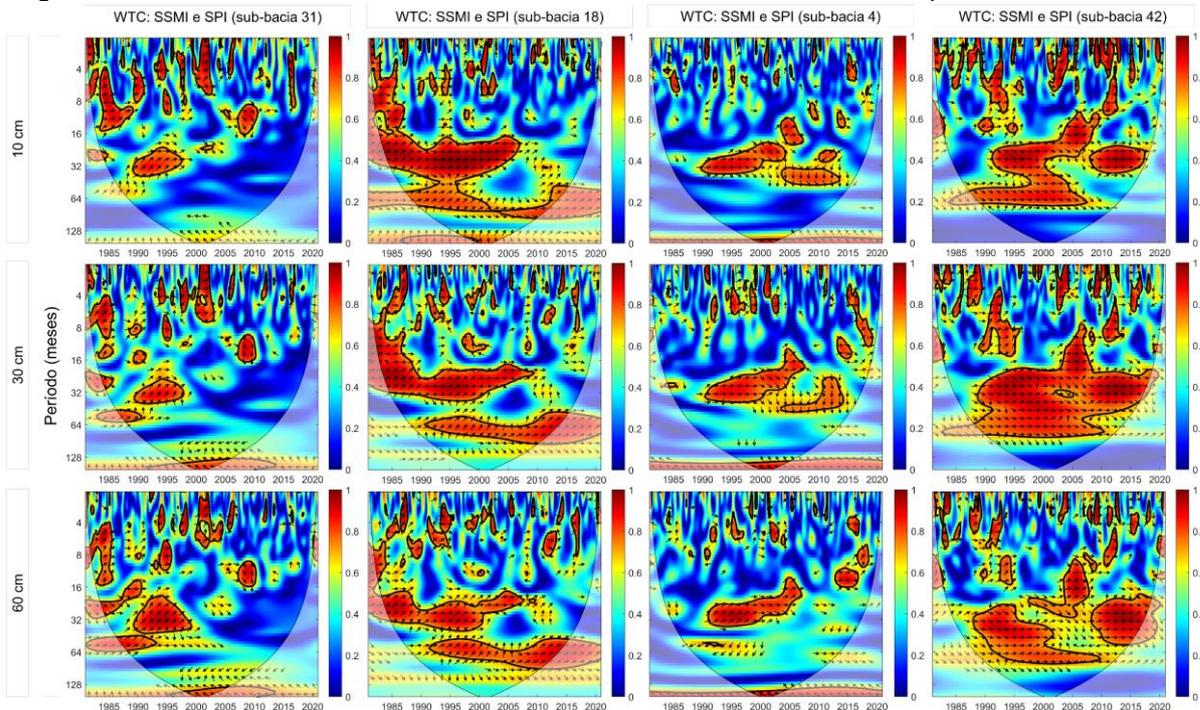
De modo geral, as interações entre o SSMI e o SPI através da XWT (Figura 31) apresentam ciclos de ressonância significativa em períodos de 8 a 16 meses e 32 a 64 meses, distribuídos espaçadamente no tempo. Nas quatro sub-bacias, as setas direcionadas para direita e para cima, na quase totalidade, indicam que o SPI estava em fase com o SSMI, ou precedia ligeiramente a seca agrícola em 1/8 do período. No entanto, na região de transição entre Agreste e Zona da Mata foram observadas pequenas áreas com setas para baixo nas profundidades superficiais do solo entre 2010 e 2015, indicando que as mudanças no SSMI ocorreram antes das mudanças correspondentes no SPI. Na RMR, ocorre uma interação forte e prolongada entre o SSMI e o SPI no período em torno de 64 meses. Isso é evidente na profundidade intermediária e total do solo, atravessando quase toda a série temporal no cone de influência, sugerindo um comportamento previsível e cíclico na disponibilidade de umidade do solo na região.

Figura 31 - Transformada wavelet cruzada entre SSMI e SPI nas diferentes sub-bacias e profundidades do solo.



Fonte: O autor (2024).

Figura 32 - Coerência wavelet entre SSMI e SPI nas diferentes sub-bacias e profundidades do solo.



Fonte: O autor (2024).

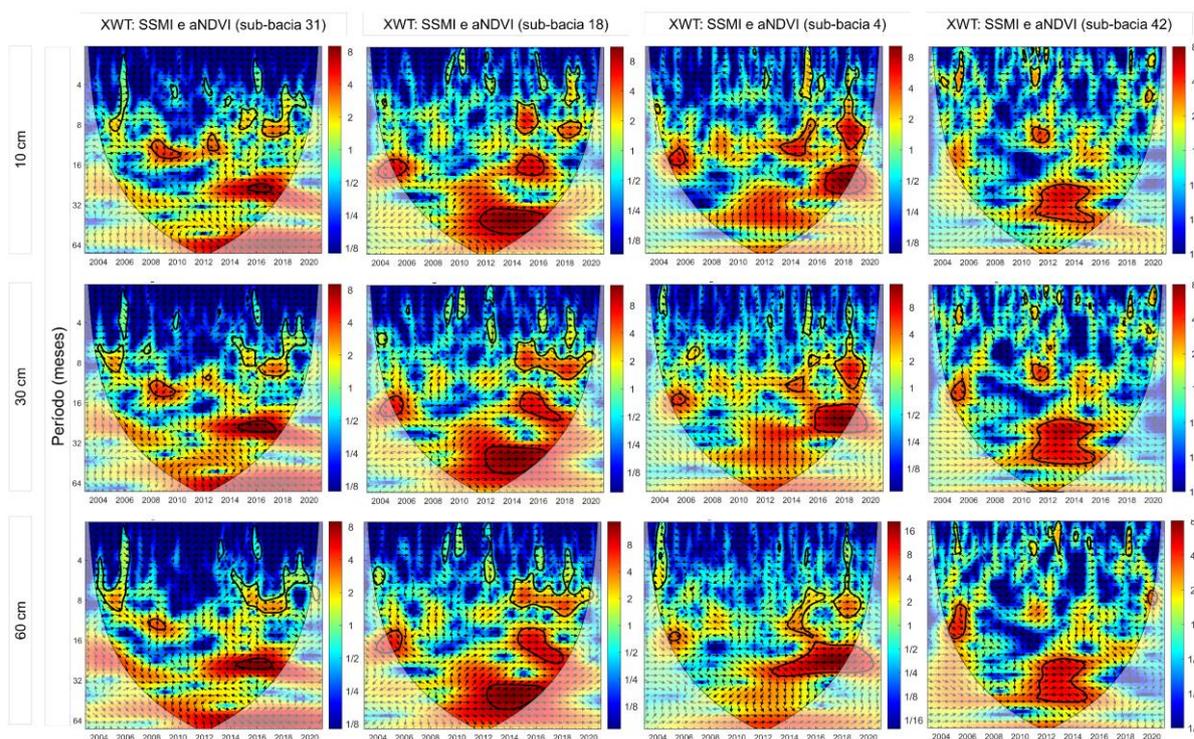
Os resultados do WTC reforçam a coerência entre as séries SSMI e SPI (Figura 32). Entretanto, os períodos e as regiões foram estatisticamente mais extensos que a XWT. Essas observações também foram relatadas por Chang *et al.* (2023), ao aplicar WTC e XWT entre séries mensais de precipitação e umidade do solo em diferentes profundidades no semiárido do norte da China. Nas quatro sub-bacias do Capibaribe, os ciclos significativos ocorrem a partir de um mês, concentrando-se ao longo dos períodos e dos anos até 64 meses. Ciclos significativos em escalas mais longas, aproximadamente 128 meses, e menos comuns, ocorreram nas sub-bacias 31 e 4, com ângulo das setas indicando o SSMI precedendo o SPI em 5/8 do período (6,6 anos). Percebe-se que, com o aumento da profundidade do solo, as regiões de coerência significativas tendem a segregar, reduzindo os intervalos de períodos significativos e os prolongamentos ao longo dos anos.

A relação entre as séries do SSMI, em diferentes profundidades, e aNDVI através da XWT é apresentada na Figura 33. Esse tipo de aplicação é útil para avaliar o impacto do déficit de umidade do solo na vegetação, considerando as relações defasadas entre a planta e o estresse hídrico no solo (Zeri *et al.*, 2021). Os resultados apresentam ressonâncias significativas variando de 1 a 60 meses, com a maior parte da energia ocorrendo em períodos mais longos, de 16 a 60 meses, e de forma intermitente. Em todas as regiões, as setas indicam que a relação entre os índices esteve geralmente em fase, e em alguns períodos o SSMI liderava ligeiramente o aNDVI. Entretanto, na sub-bacia 31, ocorreram pequenos ciclos significativos de mudanças na vegetação precedendo mudanças na umidade do solo, mais precisamente entre 2008 e 2010.

Nesse período, juntamente com os anos de 2015 a 2017, ocorreram as interações mais fortes nessa região, coincidindo com eventos de El Niño de magnitude moderada e muito forte, respectivamente. No primeiro evento, a liderança da seca na vegetação pode ter sido ocasionada pelo impacto da seca meteorológica, que não foi utilizada nesta abordagem. Possivelmente a vegetação respondeu a variabilidade da precipitação de forma mais rápida, independente das condições de umidade do solo. Uma outra sub-bacia localizada no Agreste, 18, apresentou interações significativas mais fortes entre 2012 e 2016, com regiões de ressonância mais extensas. Além de coincidir com a ocorrência de El Niño, esse período foi identificado por Brito *et al.* (2018) como a seca mais severa e prolongada do semiárido brasileiro, ao investigar índices de solo e de vegetação entre os anos de 1981 e 2016. Medeiros, Oliveira e

Torres (2020) identificaram distintas condições de circulação atmosférica associadas a esse período de seca no Nordeste, sendo um deslocamento da Zona de Convergência Intertropical (ZCIT) para o Norte, seguido de um movimento ascendente anômalo na Amazônia Ocidental, a circulação de Walker e à convecção na ZCIT sobre a África e o Golfo do México.

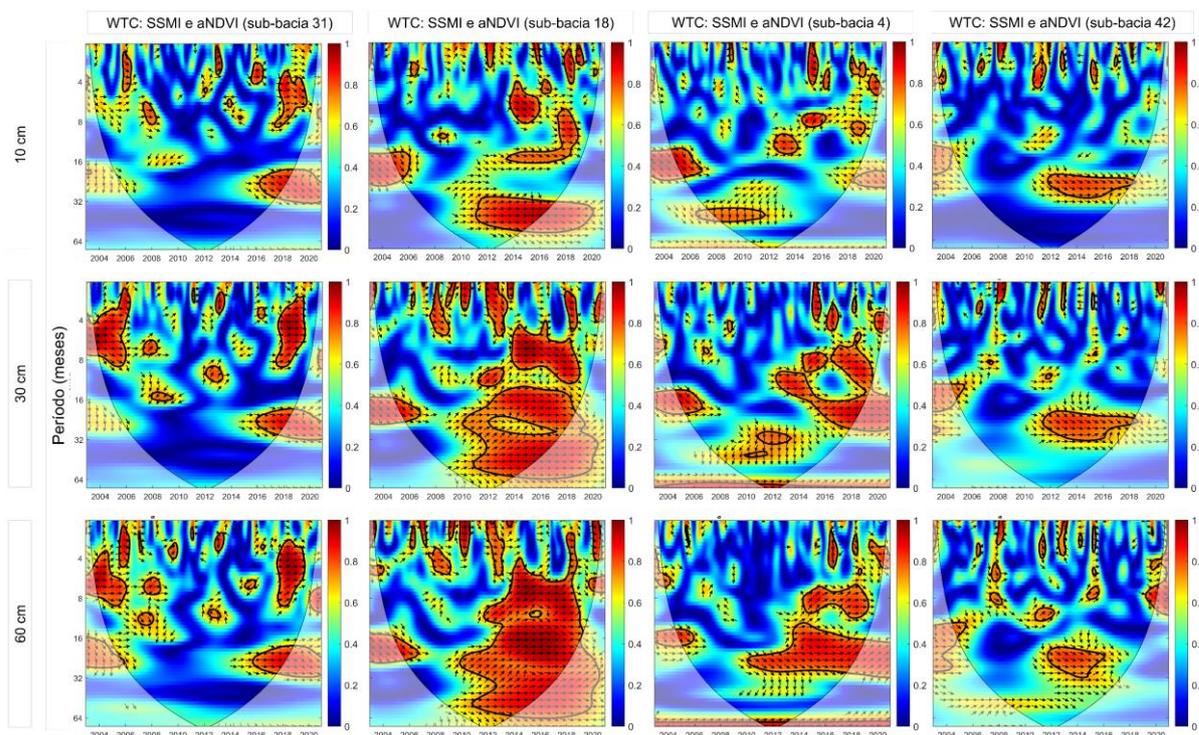
Figura 33 - Transformada wavelet cruzada entre SSMI e aNDVI nas diferentes sub-bacias e profundidades do solo.



Fonte: O autor (2024).

No WTC (Figura 34), os períodos e coerências significativas foram estatisticamente mais extensos, principalmente nas sub-bacias 18 e 4. De modo geral, esses períodos variaram de 1 a 32 meses nas sub-bacias 31 e 42, e de 1 a 64 meses nas sub-bacias 18 e 4. Os ângulos de fase demonstram que as séries variam conjuntamente na maior parte do tempo analisado, embora também ocorram atrasos na resposta da vegetação às mudanças na umidade do solo na escala de 16 a 32 meses entre 2005 e 2007. Em períodos mais longos, a coerência entre as séries geralmente aumenta à medida que a profundidade do solo aumenta, e enfraquece nos períodos mais curtos. Na profundidade total do solo, os anos entre 2011 e 2016 apresentaram ciclos significativos entre as sub-bacias 18, 4 e 42, com a amplitude dos períodos (4 a 60 meses) reduzindo e fragmentando de oeste à leste da bacia.

Figura 34 - Coerência wavelet entre SSMI e aNDVI nas diferentes sub-bacias e profundidades do solo.



Fonte: O autor (2024).

#### 4.6 RELAÇÕES ENTRE EVENTOS ENSO E AS SECAS METEOROLÓGICA E AGRÍCOLA

Para investigar as relações entre as anomalias de circulação atmosférica e as secas meteorológicas e agrícolas, foram utilizados os métodos de correlação de Pearson e análise wavelet. A seca da vegetação não foi considerada devido ao curto período de observações disponível. Para a seca agrícola, foram analisados apenas os dados de umidade do solo na profundidade total (0 – 60 cm). Inicialmente, foram examinadas as correlações mensais entre os eventos ENSO e as secas meteorológicas e agrícolas em diferentes escalas (1 a 12 meses) e defasagens mensais (0 a 12), no período de 1982 a 2020 (Figura 35 e Figura 36). As defasagens foram incluídas devido ao retardo existente entre o tempo de desenvolvimento de eventos ENSO e a subsequente ocorrência de secas (McPhaden; Zebiak; Glantz, 2006; Vicente-Serrano *et al.*, 2011).

É importante destacar que no Nordeste brasileiro a fase quente do ciclo ENSO, El Niño, está frequentemente associada a períodos de seca, enquanto os episódios de La Niña estão relacionados a anos mais chuvosos, (Andreoli; Kayano, 2006; Costa

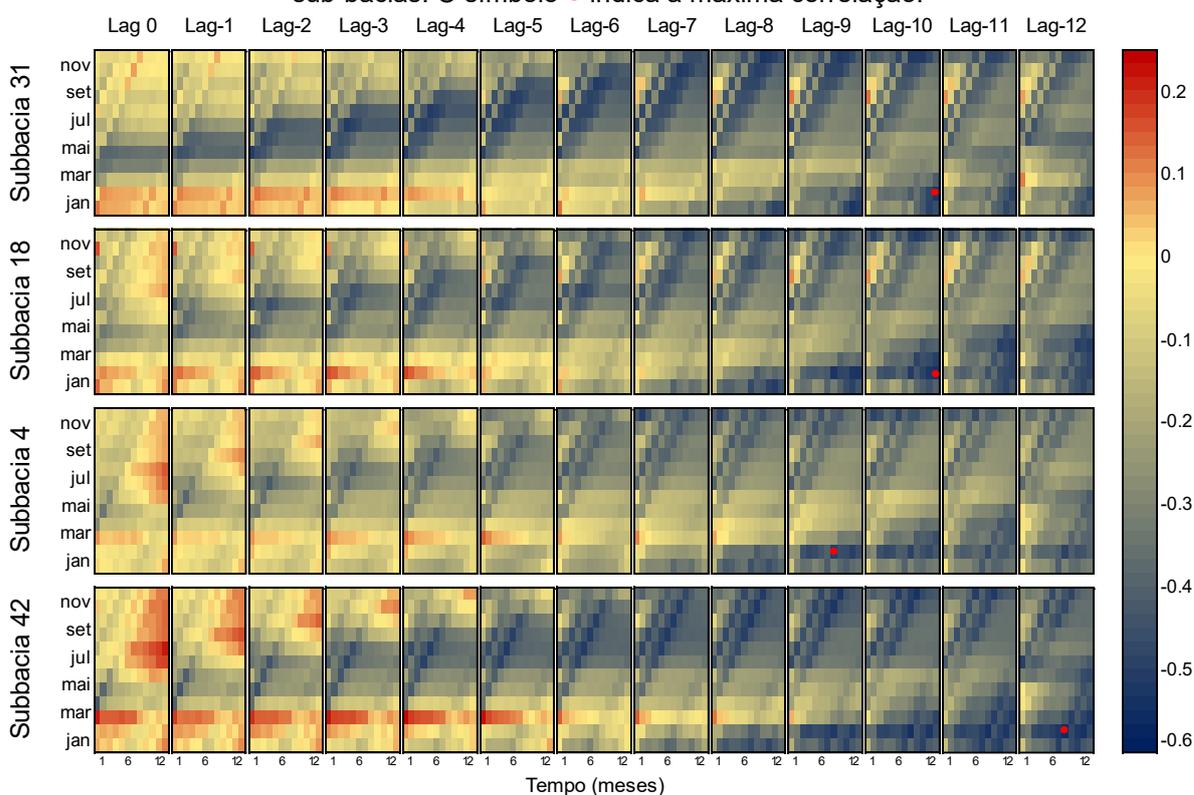
*et al.*, 2021; Pereira *et al.*, 2018; Medeiros; *et al.*, 2020; Hastenrath; Heller, 1977). Considerando que as séries dos eventos ENSO representam uma dinâmica inversa aos dados de SPI e SSMI, ou seja, fases positivas de ENSO indicam seca, enquanto valores positivos de SPI e SSMI indicam condições mais úmidas, as maiores correlações, sejam positivas ou negativas, refletem uma melhor relação linear entre as fases ENSO e os índices de secas na região. Dessa forma, a abordagem utilizada, a partir do coeficiente de Pearson e as defasagens, permite identificar os períodos em que pode ocorrer uma intensificação das condições de seca, ou umidade, associados as diferentes fases do ENSO.

Os resultados das correlações entre o SPI e os eventos ENSO (Figura 35) demonstram predominantemente relações negativas ao longo dos meses, escalas e defasagens. De modo geral, observam-se fortes correlações negativas que se distribuem de forma diagonal e intensificam-se à medida que há um aumento da escala e do retardo do SPI. Essas correlações geralmente têm início no outono, prolongando-se até a primavera e atingindo o verão a partir de atrasos de 7 meses. Os valores máximos de correlação em cada sub-bacia foram todos negativos e significativos ( $p < 0,001$ ) (Figura 35), identificados no mês de fevereiro, final do verão austral, que ocorre logo após os picos do ENSO. No Agreste, esses valores são observados na defasagem de 10 meses e na escala de SPI mais longa, de 12 meses. Nas sub-bacias 4 e 42, as menores correlações são observadas em atrasos de 9 e 12 meses, respectivamente, e na escala de 8 meses. Isso sugere que os eventos ENSO, que geralmente iniciam de junho a agosto (inverno) (Trenberth, 1997), têm uma influência não imediata na variabilidade da chuva da região, manifestando-se com maior intensidade por volta de 9 a 12 meses do seu início. Essas defasagens são semelhantes aos resultados encontrados por Zambrano, Rivadeneira e Pérez-Martín (2018), que observaram tempos de respostas entre o SPI-12 e anomalias da temperatura da superfície do mar (SST), na região Niño 3.4, em torno de 9 meses, numa bacia com clima semiárido, subúmido e úmido, no Equador.

Nas sub-bacias analisadas, também são observadas correlações positivas, mas com conexões muito fracas ( $< 0,24$ ) com o ENSO, ocorrendo principalmente entre os meses de janeiro a março e em defasagens de até 7 meses. Isso sugere que, nesses períodos, a relação entre o SPI e as fases ENSO é menos sensível. Além disso, as correlações positivas indicam que as fases positivas do ENSO (El Niño) estão associadas a valores positivos de SPI, refletindo maior ocorrência de chuvas,

ao mesmo tempo que as fases negativas do ENSO (La Niña) estão associadas a valores negativos de SPI, indicando condições mais secas. A interpretação dessa relação torna-se mais complexa e menos previsível, visto que outros fatores climáticos podem estar influenciando as condições de seca e umidade na bacia. Esse comportamento é particularmente evidente na região litorânea, onde é possível identificar correlações positivas em maiores proporções.

Figura 35 - Correlações mensais entre ENSO e SPI em diferentes escalas e defasagens nas quatro sub-bacias. O símbolo ● indica a máxima correlação.



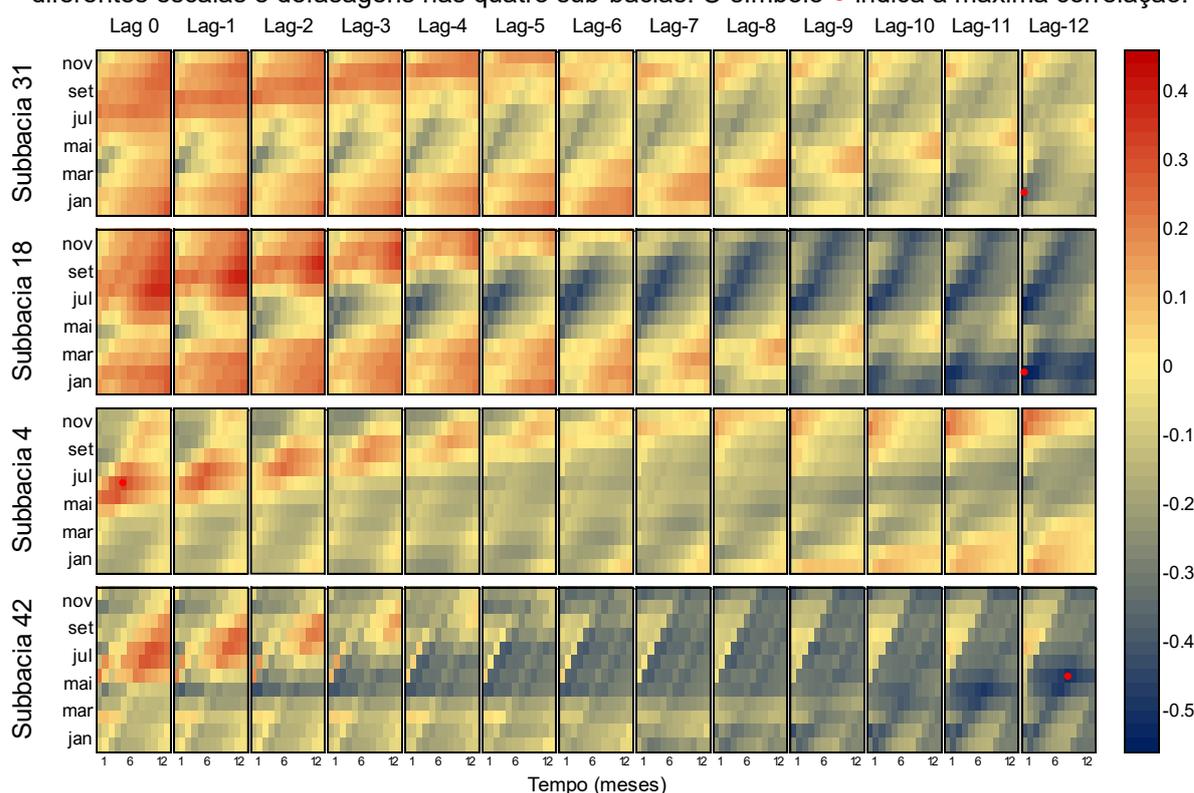
\*Correlação de Pearson nas sub-bacias 31 ( $r = -0,54^{**}$ ), 18 ( $r = -0,54^{**}$ ), 4 ( $r = -0,51^{**}$ ) e 42 ( $r = -0,57^{**}$ ).

Fonte: O autor (2024).

A teleconexão entre o ENSO e o SSMI, com diferentes escalas e defasagens, destaca na Figura 36 a influência da anomalia atmosférica da região Niño 3.4 na anomalia da umidade do solo da bacia. Os padrões dos resultados de correlação apresentam a complexa interação entre os dois índices, com valores negativos de Pearson indicando que eventos El Niño induzem a solos mais secos, e condições mais úmidas ocorrem durante eventos La Niña (Almendra-Martín *et al.*, 2022; Holmes *et al.*, 2017). Por outro lado, resultados positivos indicam que os eventos de El Niño estão associados a solos mais úmidos, e de La Niña a solos mais secos. No Agreste (sub-

bacia 31 e 18), por exemplo, há uma predominância de valores positivos nas defasagens de 0 a 4 meses, em tempos maiores de acumulação, estando concentrados principalmente durante o inverno e a primavera. No geral, essas correlações são fracas e muito fracas ( $< 0,28$ ) e sem significância, sugerindo que outros fatores também podem influenciar nessa relação (Oertel *et al.*, 2018). Ainda sobre a mesma região, observa-se que o aumento da defasagem induz a um aumento de correlações negativas, que são mais expressivas na subabacia 18. Esses valores se concentram especialmente a partir do lag 10, em escalas menores do SSMI (1 e 2), durante a transição verão/outono e no inverno, atingindo a correlação máxima (significativa) em fevereiro, com uma resposta expressiva da anomalia de umidade do solo ao ENSO em torno de 12 meses.

Figura 36 - Correlações mensais entre ENSO e SSMI, referente à profundidade total do solo, em diferentes escalas e defasagens nas quatro sub-bacias. O símbolo ● indica a máxima correlação.



\*Correlação de Pearson nas sub-bacias 31 ( $r = -0,39^*$ ), 18 ( $r = -0,54^{**}$ ), 4 ( $r = 0,32^*$ ) e 42 ( $r = -0,51^*$ ).

Fonte: O autor (2024).

A transição entre o Agreste e a Zona da Mata, sub-bacia 4, apresenta uma correlação máxima no lag 0, diferindo das demais regiões. Esse valor é positivo e significativo, indicando que o ENSO positivo está associado a anomalias positivas na

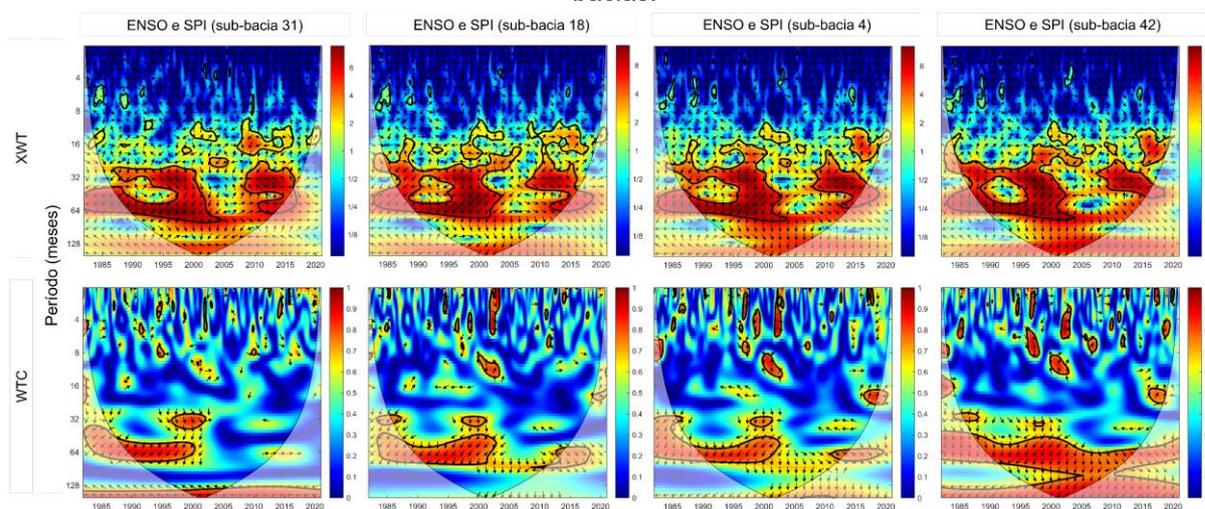
umidade do solo (Almendra-Martín *et al.*, 2022), ao mesmo tempo a fase negativa do ENSO está relacionada a condições de seca agrícola. Tal comportamento é inesperado para a região, uma vez que, normalmente, a fase positiva do ENSO induz a condições mais secas. As correlações negativas também ocorrem em todas as defasagens ( $\leq -0,30$ ), porém, sem significância. Já na região litorânea, o período sem defasagem concentra correlações positivas fracas ( $\leq 0,29$ ) durante o inverno, principalmente nas escalas maiores do SSMI. Com o aumento dos tempos de defasagem, há uma predominância das correlações negativas que ocorrem também durante o inverno, atingindo o valor máximo ( $-0,51$ ) no lag 12 e na escala 8. Devido o regime de chuvas nessa região, essa relação negativa entre ENSO e SSMI não implica diretamente em seca agrícola com a ocorrência de eventos de El Niño. Tais conexões indiretas refletem variações na umidade do solo moduladas pela intensidade do ENSO, induzindo a atenuação ou amplificação na umidade, sem necessariamente resultar em secas.

Os resultados da periodicidade entre o SPI-1 e o ENSO através da wavelet cruzada e espectro de coerência wavelet reforçam a complexidade da relação entre os índices climáticos (Figura 37). A análise XWT revela períodos conjugados interanuais, distribuídos principalmente em escalas de tempos de 16 a 64 meses. Há também a presença de ciclos significativos em menores períodos, indicando impactos do ENSO de forma mais imediata nas variações do SPI, embora ocorram de forma segregada e com correlações mais fracas ao longo dos anos. Toda a região apresenta uma periodicidade em torno de 3 a 5 anos entre 1987 e 2003, com o ângulo das setas ( $135^\circ$ ) indicando o ENSO precedendo o SPI em  $3/8$  do período. Durante os anos de 1996 a 2000 essa periodicidade é prolongada em ciclos mais duradouros, abrangendo períodos mais curtos, a partir de 30 meses, com a maior parte das setas indicando que o ENSO antecede o SPI em  $90^\circ$  ( $1/4$  do período). Adicionalmente, outros ciclos significativos ocorrem na região entre os anos 2009 e 2015, em períodos de 32 a 64 meses e com o SPI atrasado em  $180^\circ$  do ENSO, equivalente à metade do período.

De modo geral, a direção das setas revela um padrão esperado entre os índices, com os eventos ENSO liderando as variações do SPI. O fato de as setas apontarem para a esquerda indica uma inversão de fases entre esses índices (Chang *et al.*, 2023; dos Santos *et al.*, 2023). Nesse caso, durante fases positivas do ENSO o SPI tende a ser negativo, resultando em condições de secas, já durante a fase negativa do ENSO o SPI tende a ser positivo, refletindo aumento de precipitação e,

consequentemente, condições mais úmidas. Tais resultados são consistentes com as máximas correlações de Pearson, relações negativas, discutidas anteriormente (Figura 35).

Figura 37 - Transformada wavelet cruzada e coerência wavelet entre ENSO e SPI nas diferentes sub-bacias.



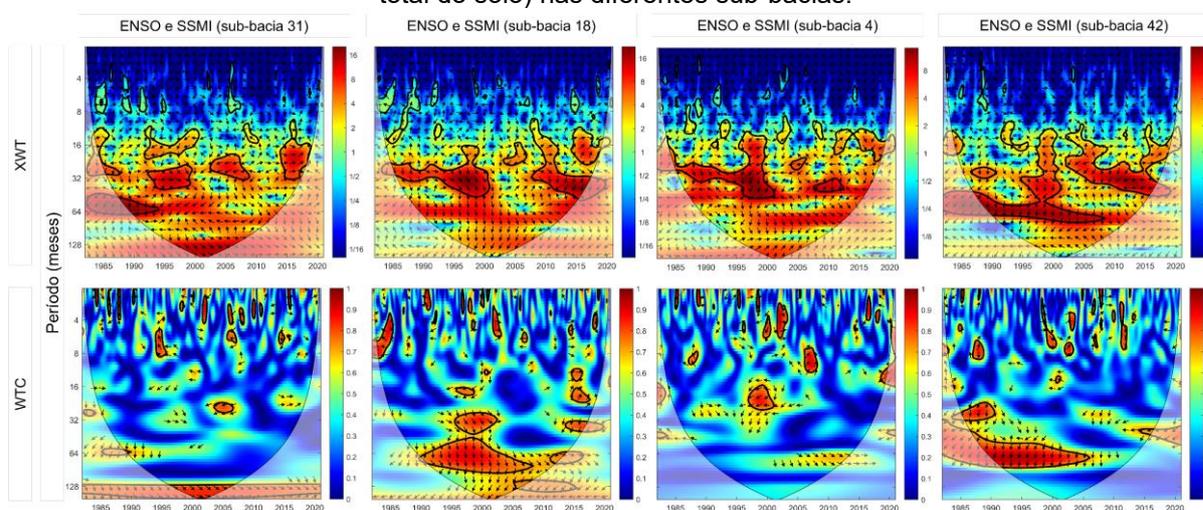
Fonte: O autor (2024).

O espectro de coerência entre as séries reforça os ciclos de ressonância significativos nas escalas de 32 a 64 meses (aproximadamente 2,5 a 5 anos) entre 1987 e 2005. Em geral, os ângulos das setas refletem a inversão de fases entre os índices, ao mesmo tempo que indicam a liderança do ENSO nas variações do SPI. Ao analisar as variações na bacia, percebem-se pequenas diferenças na intensidade da coerência e na periodicidade das sub-bacias 31, 18 e 4. Na região litorânea, no entanto, o ciclo de ressonância se estende por um período mais longo e contínuo, abrangendo todos os anos analisados em escalas mais longas, em torno de 5 a 10 anos. Dessa forma, constata-se que os eventos ENSO têm impacto significativo na variabilidade regional da seca meteorológica na bacia, com teleconexões que se estendem por vários anos e até mesmo décadas.

A relação entre o ENSO e o SSMI através da transformada wavelet cruzada (Figura 38) apresenta ciclos de ressonância significativos menores e mais fragmentados quando comparados com os resultados do SPI e ENSO (Figura 37). Os ciclos ocorrem, de modo geral, entre as escalas de 16 a 64 meses, com variações positivas e negativas alternadas. No Agreste, por exemplo, entre os anos de 1995 e 2000, as setas inclinadas para a direita, em escalas em torno de 32 meses, indicam

que as séries são correlacionadas positivamente, com o SSMI em fase alinhada ( $0^\circ$ ) com o ENSO na sub-bacia 31, e atrasado em  $45^\circ$  (em torno de 4 anos) na sub-bacia 18. Durante o mesmo período, as sub-bacias 4 e 42 apresentaram relações em fases opostas, com o ENSO precedendo o SSMI em  $135^\circ$  ( $3/8$  do ciclo). Ocorrem ainda ciclos de ressonância significativos fragmentados de 2000 a 2020 em todas as sub-bacias, em especial na região litorânea, com alternância de fases ao longo do período de 16 a 64 meses.

Figura 38 - Transformada wavelet cruzada e coerência wavelet entre ENSO e SSMI (profundidade total do solo) nas diferentes sub-bacias.



Fonte: O autor (2024).

O WTC entre o ENSO e o SSMI (Figura 38) demonstra a predominância de regiões de baixa coerência ao longo de toda a série, ocorrendo principalmente nas sub-bacias 31 e 4. Nestas áreas, embora ocorram pequenos ciclos significativos interanuais e interdecadais, a baixa coerência revela que as condições de umidade do solo podem ser moduladas por outros fatores climáticos na maior parte do tempo. Na região litorânea e na sub-bacia 18, os ciclos são consistentes com o XWT, com padrões de coerência evidentes, embora significativamente menos extensos, concentrando-se no período de 1987 a 2006 e 1990 a 2008, respectivamente. A coerência é especialmente mais forte na região litorânea durante 1990 a 2000 na escala de 64 meses, com a mesma relação de fase do XWT, comprovando a influência dos eventos ENSO na variabilidade da umidade do solo na região.

De modo geral, as descobertas revelam complexas interações entre as fases do ENSO e as secas meteorológica e agrícola ao longo da bacia do Capibaribe.

Enquanto a variabilidade da precipitação demonstra ser fortemente modulada pelo ENSO em escalas interanuais, a coerência com a anomalia de umidade do solo é mais fragmentada, especialmente no extremo Oeste e na área de transição da Zona da Mata. Pereira *et al.* (2018) identificaram ciclos de ressonância significativos entre o ENSO (Niño 3.4 e SOI) e o SPI durante a estação seca, em uma bacia do nordeste oriental do Brasil. Essa relação foi observada em escalas entre 2 a 5 anos nas décadas de 1980 a 1990. Na bacia do rio São Francisco, Santos *et al.* (2019) observaram, por meio da coerência wavelet, oscilações de baixa frequência entre SPI e ENSO fortemente associadas com o El Niño, principalmente na década de 70, enquanto correlações de curto prazo e intermitentes foram frequentemente associadas a fases quentes do ENSO.

Investigações aplicando a coerência wavelet entre indicador de seca agrícola, que na maioria dos estudos utiliza a umidade do solo (Zhang *et al.*, 2022), e fatores climáticos parecem ainda escassos no Brasil. No entanto, estudos em outras regiões do planeta demonstram a viabilidade dessa abordagem na compreensão da relação tempo-frequência entre padrões climáticos e umidade do solo. Wang *et al.* (2024), por exemplo, identificaram impactos significativos do ENSO no conteúdo de água do solo em regiões áridas e semiáridas na China, com ciclos de ressonância positivos na fase quente do ENSO, durante 2015 a 2016, em escalas de 9~14 meses. Chen *et al.* (2019) observaram relações significativas entre os índices Niño 4, Niño 3.4, MEI e SOI no índice padronizado do solo, na bacia do rio Luanhe (China), concentrados em períodos de 16 a 99 meses e na escala decadal de 99 a 187 meses.

#### 4.7 INCERTEZAS E LIMITAÇÕES

Embora o presente estudo tenha obtido resultados abrangentes sobre a dinâmica hidroclimatológica da bacia do rio Capibaribe, é importante reconhecer as incertezas e limitações inerentes aos dados e métodos utilizados. Fatores como a resolução espacial e temporal dos produtos de sensoriamento remoto, o processo de modelagem hidrológica, bem como as complexidades associadas à propagação das secas e às teleconexões atmosféricas devem ser considerados na interpretação das descobertas.

Primeiramente, por mais que as variáveis tenham sido comparadas em escala de sub-bacia e de unidade de análise, os dados utilizados para os índices de seca foram obtidos por diferentes abordagens. A resolução espacial e temporal dos produtos de precipitação e vegetação, por exemplo, é um fator que pode influenciar na precisão dos resultados. Mesmo com correlações satisfatórias observadas entre os dados do CHIRPS e do MOD13Q1, a diferença na resolução dos produtos pode ser investigada de forma detalhada em estudos adicionais. Técnicas de reamostragem e interpolação espacial podem ser empregadas para ajudar na redução das incertezas e, possivelmente, melhorar a consistência dos dados.

Na simulação do conteúdo de água no solo com o SWAT, embora o modelo tenha apresentado desempenho satisfatório em alguns períodos e regiões da bacia, ainda é necessário reconhecer as incertezas associadas à representação das variáveis hidrológicas. Tais incertezas e limitações têm sido discutidas em estudos que utilizaram o SWAT para a estimativa espacial e temporal de secas agrícolas (Havrylenko *et al.*, 2016b; Li *et al.*, 2023; Nguyen *et al.*, 2023) e hidrológicas (Li *et al.*, 2024). Li *et al.* (2023) destacam três fatores que contribuem para essas incertezas: (1) o refinamento dos dados de entrada, como a resolução do MDE, a classificação do uso do solo e a precisão dos dados de precipitação; (2) as incertezas nos parâmetros calibrados; e (3) as limitações estruturais resultantes de uma compreensão incompleta dos processos subjacentes e da conceituação do modelo. Além disso, neste estudo, a calibração foi realizada apenas com dados fluviométricos, sendo uma limitação da pesquisa o processo no ajuste dos parâmetros a partir de dados observados da umidade do solo em diferentes profundidades. Destaca-se ainda que a simplificação dos dados de manejo agrícola a de culturas específicas da região também contribuem para as incertezas. No entanto, mesmo com as limitações, os resultados da simulação

hidrológica foram adequados para a avaliação da seca agrícola na bacia do rio Capibaribe.

Finalmente, a propagação dos diferentes tipos de secas envolve processos lineares e não lineares a partir do desequilíbrio das variáveis do ciclo hidrológico. Períodos com déficits hídricos, identificados por índices de seca meteorológica, por exemplo, interferem diretamente na umidade do solo e, conseqüentemente, na vegetação, desencadeando uma propagação linear entre as secas. Entretanto, esse processo pode exibir características não lineares devido às interferências do manejo agrícola, como a irrigação e outras atividades que possam favorecer o aporte de água no solo. Os fatores climáticos também representam conexões não lineares complexas e interferem, direta ou indiretamente, na dinâmica hidroclimatológica na bacia. Embora este estudo tenha identificado influências significativas entre os eventos ENSO e as secas meteorológicas e agrícolas, a ocorrência de períodos com relações fragmentadas sugere a atuação de outros fatores atmosféricos e regionais modulando a variabilidade das secas. Dessa forma, a inclusão de dados refinados e a análise de outros mecanismos não lineares que possam influenciar os diferentes tipos de secas podem fornecer uma compreensão científica detalhada. A integração dessas informações possibilita o aprimoramento no monitoramento, na capacidade preditiva e na gestão adaptativa das secas na região.

## 5 CONCLUSÕES E RECOMENDAÇÕES

A abordagem aplicada nesta tese, integrando métodos alternativos baseados em sensoriamento remoto e modelagem hidrológica, forneceu uma compreensão detalhada da dinâmica hidroclimatológica na bacia do rio Capibaribe. O produto de precipitação proveniente do CHIRPS, juntamente com as condições da vegetação, por meio do NDVI, e a umidade do solo simulada no SWAT, permitiram uma compreensão abrangente das características espaciais e temporais dos diferentes eventos secas ocorridas nos últimos anos na região.

Na etapa inicial do estudo, foram identificadas condições heterogêneas da precipitação e da vegetação durante os últimos anos ao longo na bacia, apresentando grandes variações entre as regiões semiáridas, de transição e litorâneas. A seca meteorológica, analisada através do índice SPI, revelou que o número de eventos diminui à medida que a escala de tempo aumenta, enquanto a severidade e a duração dos eventos se intensificam. As secas de longo prazo foram mais severas e duradouras no extremo oeste da bacia. Em relação às categorias, as secas classificadas como moderadas de curto prazo foram mais frequentes no Agreste e na região de transição, seguidas pelas secas severas e extremas. Além disso, com o aumento da escala de tempo, a área central da bacia demonstrou maior suscetibilidade à ocorrência de secas extremas, necessitando de atenção especial durante a ocorrência de eventos de seca prolongada.

A dinâmica da vegetação em escala anual demonstrou uma resposta direta à variabilidade da precipitação. Em anos com a chuva acima da média, houve um aumento no vigor vegetativo em grande parte da bacia, enquanto em anos secos observou-se uma redução na cobertura vegetal, particularmente na região semiárida. No entanto, algumas regiões mantiveram os valores de NDVI médio anual relativamente estáveis durante toda a série analisada, como as áreas de maior altitude no Agreste e em algumas regiões próximas ao litoral.

O tempo de resposta da vegetação à precipitação ocorre geralmente um mês após os eventos de chuva, embora a região oeste da bacia ainda responda significativamente à precipitação com dois meses de atraso. No Agreste, o desenvolvimento da vegetação demonstrou ser afetado por déficits de chuva acumulados de três a doze meses, enquanto na Zona da Mata e Região Metropolitana

a seca na vegetação apresentou maior sensibilidade ao efeito cumulativo de secas meteorológicas de três meses.

Os resultados da calibração e validação com o SWAT indicaram que, apesar de limitações na captura de vazões de pico e de áreas com regimes fluviais intermitentes, o modelo representou de forma satisfatória o comportamento hidrológico da bacia. A precisão da simulação da umidade do solo mensal foi considerada eficaz para a representação da seca agrícola ocorrida na bacia nos últimos anos.

A propagação entre a seca meteorológica, agrícola e da vegetação apresentou características distintas, com uma forte interação sazonal. Em geral, as secas meteorológicas se propagaram mais rapidamente para as secas agrícolas, especialmente nas camadas superficiais do solo, com tempos mais curtos durante o outono. A transição da seca agrícola para a seca da vegetação foi relativamente mais lenta, com o Agreste apresentando tempos maiores durante a primavera e o litoral da bacia no outono. A análise wavelet relevou que as secas meteorológicas precederam as secas agrícolas na maior parte da série, com interações mais evidentes na camada intermediária do solo e na região litorânea. Interações entre a seca agrícola e da vegetação ocorreram principalmente durante anos de El Niño, com ciclos significativos bem definidos e sem grandes defasagens entre os índices.

Em relação às teleconexões, foi observado que os eventos ENSO influenciaram significativamente nas secas meteorológicas e agrícolas na bacia, com fortes correlações negativas identificadas em defasagens entre 10 e 12 meses. Os ciclos de ressonância interanuais e os ângulos de diferença de fases indicaram que eventos ENSO, no geral, precederam a ocorrência dos dois tipos de secas. No entanto, a teleconexão com a seca agrícola foi mais fragmentada, sugerindo que outros fatores climáticos e regionais também modulam a variabilidade da umidade do solo.

Dessa forma, a abordagem integrada aplicada neste estudo forneceu uma compreensão detalhada dos complexos aspectos e interações entre as secas meteorológicas, agrícolas e da vegetação. A combinação de ferramentas alternativas para o monitoramento e a avaliação das secas demonstrou ser eficaz na avaliação do comportamento hidrológico espacial e temporal na região, podendo auxiliar em políticas e ações de gerenciamento das secas, especialmente em áreas mais vulneráveis às mudanças climáticas.

## Recomendações

A partir dos resultados obtidos neste estudo, são propostas a seguir algumas sugestões para investigações subsequentes, que possam aprimorar a compreensão das respostas e da dinâmica hidroclimatológica na bacia do rio Capibaribe:

- Adoção de técnicas de reamostragem e interpolação para refinar e uniformizar a resolução espacial dos produtos de sensoriamento remoto, permitindo um maior detalhamento e otimização da sua aplicação em escala de sub-bacia.
- Inclusão de índices de seca que consideram outras variáveis hidrológicas (agregadas ou não), como as vazões naturalizadas (seca hidrológica), a temperatura, a evapotranspiração e o nível das águas subterrâneas.
- Avaliação da influência do uso e ocupação do solo, da operação de reservatórios e da exploração das águas subterrâneas na ocorrência, duração e intensidade das secas.
- Inclusão de dados detalhados do manejo agrícola das principais culturas, como a cana-de-açúcar, feijão e milho, visando aprimorar a simulação da umidade do solo no modelo SWAT.
- Investigação da interação das secas com outras teleconexões atmosféricas, incluindo a Oscilação Multidecadal do Atlântico (AMO), a Oscilação do Atlântico Norte (NAO), a Oscilação Decadal do Pacífico (PDO) e o Modo Meridional do Atlântico (MMA).

## REFERÊNCIAS

- ABBAS, Sawaid; NICHOL, Janet E.; WONG, Man Sing. Trends in vegetation productivity related to climate change in China's Pearl River Delta. **Plos one**, v. 16, n. 2, p. e0245467, 2021.
- ABBASPOUR, K. C.; JOHNSON, C. A.; VAN GENUCHTEN, M. Th. Estimating Uncertain Flow and Transport Parameters Using a Sequential Uncertainty Fitting Procedure. **Vadose Zone Journal**, v. 3, n. 4, p. 1340–1352, 2004.
- AGHAKOUCHAK, A. *et al.* Remote sensing of drought: Progress, challenges and opportunities. **Reviews of Geophysics**, v. 53, n. 2, p. 452–480, 2015.
- AHMADALIPOUR, Ali; MORADKHANI, Hamid; DEMIREL, Mehmet C. A comparative assessment of projected meteorological and hydrological droughts: Elucidating the role of temperature. **Journal of Hydrology**, v. 553, p. 785–797, 2017.
- ALMENDRA-MARTÍN, Laura *et al.* Influence of atmospheric patterns on soil moisture dynamics in Europe. **Science of The Total Environment**, v. 846, p. 157537, 2022.
- AL-QURAIISHI, Ayad M. F.; GAZNAYEE, Heman A.; CRESPI, Mattia. Drought trend analysis in a semi-arid area of Iraq based on Normalized Difference Vegetation Index, Normalized Difference Water Index and Standardized Precipitation Index. **Journal of Arid Land**, v. 13, n. 4, p. 413–430, 2021.
- ALRIAH, Mohamed Abdallah Ahmed *et al.* Assessment of observed changes in drought characteristics and recent vegetation dynamics over arid and semiarid areas in Sudan. **Theoretical and Applied Climatology**, v. 155, n. 5, p. 3541–3561, 2024.
- ALVALÁ, REGINA C.S. *et al.* Drought monitoring in the Brazilian Semiarid region. **Anais da Academia Brasileira de Ciências**, v. 91, n. suppl 1, 2019.
- AMRI, Rim *et al.* Analysis of Vegetation Behavior in a North African Semi-Arid Region, Using SPOT-VEGETATION NDVI Data. **Remote Sensing**, v. 3, n. 12, p. 2568–2590, 2011.
- ANDERSON, Martha C. *et al.* An Intercomparison of Drought Indicators Based on Thermal Remote Sensing and NLDAS-2 Simulations with U.S. Drought Monitor Classifications. **Journal of Hydrometeorology**, v. 14, n. 4, p. 1035–1056, 2013.
- ANDRADE, Carolyne W. L. *et al.* Climate change impact assessment on water resources under RCP scenarios: A case study in Mundaú River Basin, Northeastern Brazil. **International Journal of Climatology**, v. 41, n. S1, 2021.
- ANDRADE, Carolyne W.L. de *et al.* Soil moisture and discharge modeling in a representative watershed in northeastern Brazil using SWAT. **Ecohydrology & Hydrobiology**, v. 19, n. 2, p. 238–251, 2019.

ANDRADE, João Maria *et al.* A comprehensive assessment of precipitation products: Temporal and spatial analyses over terrestrial biomes in Northeastern Brazil. **Remote Sensing Applications: Society and Environment**, v. 28, p. 100842, 2022.

ANDREOLI, Rita Valéria; KAYANO, Mary Toshie. Tropical Pacific and South Atlantic effects on rainfall variability over Northeast Brazil. **International Journal of Climatology**, v. 26, n. 13, p. 1895–1912, 2006.

ARAÚJO, Diego C. S. **Sensoriamento remoto e modelagem aplicados à estimativa de atributos hidrológicos no semiárido brasileiro**. 2020. 235 f. Tese (Doutorado em Engenharia Civil) - Universidade Federal Rural de Pernambuco, 2020.

ARKEBAUER, Timothy J. Leaf radiative properties and the leaf energy budget. **Micrometeorology in Agricultural Systems**, v. 47, p. 93-103, 2005.

ASHOURI, Hamed *et al.* PERSIANN-CDR: Daily precipitation climate data record from multisatellite observations for hydrological and climate studies. **Bulletin of the American Meteorological Society**, v. 96, n. 1, p. 69-83, 2015.

AZMI, Mohammad; RÜDIGER, Christoph; WALKER, Jeffrey P. A data fusion-based drought index. **Water Resources Research**, v. 52, n. 3, p. 2222-2239, 2016.

BAGNOLD, R. A. Bed load transport by natural rivers. **Water Resources Research**, v. 13, n. 2, p. 303–312, 1977.

BARBOSA, Humberto A. Flash Drought and its characteristics in Northeastern South America during 2004–2022 using Satellite-Based products. **Atmosphere**, v. 14, n. 11, p. 1629, 2023.

BARBOSA, Humberto 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.

BERGER, K.A.; WANG, Y.; MATHER, T.N. MODIS-derived land surface moisture conditions for monitoring blacklegged tick habitat in southern New England. **International Journal of Remote Sensing**, v. 34, n. 1, p. 73–85, 2013.

BEZERRA, Alan César *et al.* Dynamics of land cover and land use in Pernambuco (Brazil): Spatio-temporal variability and temporal trends of biophysical parameters. **Remote Sensing Applications: Society and Environment**, v. 25, 2022.

BOONGALING, Cheamson Garret K.; FAUSTINO-ESLAVA, Decibel V.; LANSIGAN, Felino P. Modeling land use change impacts on hydrology and the use of landscape metrics as tools for watershed management: The case of an ungauged catchment in the Philippines. **Land Use Policy**, v. 72, p. 116–128, 2018.

BOSCH, D. *et al.* In situ soil moisture network for validation of remotely sensed data. In: **IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2004. p. 3188-3190.

BRAGA, Ricardo Augusto Pessoa *et al.* **Gestão e educação socioambiental na Bacia do Capibaribe**. Editora Cled. Recife, 2015.

BRASIL NETO, Reginaldo Moura *et al.* Evaluation of TRMM satellite dataset for monitoring meteorological drought in northeastern Brazil. **Hydrological Sciences Journal**, v. 67, n. 14, p. 2100–2120, 2022.

BRESSIANI, de Almeida Danielle *et al.* Effects of different spatial and temporal weather data resolutions on the stream flow modeling of a semi-arid basin, Northeast Brazil. **International Journal of Agricultural and Biological Engineering**, v. 8, n. 3, p. 1–16, 2015.

BRITO, S. S. B. *et al.* Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. **International Journal of Climatology**, v. 38, n. 2, p. 517–529, 2018.

BRITO, Célia Soares de *et al.* Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: A case study of the Piranhas River basin, northeastern Brazil. **Atmospheric Research**, v. 250, p. 105380, 2021.

BROCCA, Luca *et al.* Soil moisture for hydrological applications: Open questions and new opportunities. **Water**, v. 9, n. 2, 2017.

BROWN, Jesslyn F. *et al.* The Vegetation Drought Response Index (VegDRI): A new integrated approach for monitoring drought stress in vegetation. **GIScience & Remote Sensing**, v. 45, n. 1, p. 16-46, 2008.

BURITI, Catarina; BARBOSA, Humberto Alves. **Um século de secas: por que as políticas hídricas não transformaram o Semiárido brasileiro?** Lisboa/Portugal: Editora Chiado, 2018.

CAMMALLERI, Carmelo; VOGT, Jürgen; SALAMON, Peter. Development of an operational low-flow index for hydrological drought monitoring over Europe. **Hydrological Sciences Journal**, v. 62, n. 3, p. 346-358, 2017.

CAMPOS, José Nilson B. Paradigms and Public Policies on Drought in Northeast Brazil: A Historical Perspective. **Environmental Management**, v. 55, n. 5, p. 1052–1063, 2015.

CAO, Ruixue *et al.* Deep soil water storage varies with vegetation type and rainfall amount in the Loess Plateau of China. **Scientific Reports**, v. 8, n. 1, p. 1–12, 2018.

CARVALHO NETO, José Guimarães de. **Modelagem e valoração de serviço ambiental hidrológico na bacia hidrográfica do rio Una – Pernambuco**. 2018. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2018.

CASTILLO, V. M.; GÓMEZ-PLAZA, A.; MARTÍNEZ-MENA, M. The role of antecedent soil water content in the runoff response of semiarid catchments: A simulation approach. **Journal of Hydrology**, v. 284, n. 1–4, p. 114–130, 2003.

CHANEY, Nathaniel W. *et al.* High-resolution modeling of the spatial heterogeneity of soil moisture: Applications in network design. **Water resources research**, v. 51, n. 1, p. 619-638, 2015.

CHANG, Yaowen *et al.* Quantifying the Coupled Effect between Soil Moisture and Climate in the Desert Steppe Environment of Inner Mongolia, China. **Water**, v. 15, n. 6, p. 1150, 2023.

CHATTERJEE, Sumanta *et al.* Soil moisture as an essential component for delineating and forecasting agricultural rather than meteorological drought. **Remote Sensing of Environment**, v. 269, n. December 2021, p. 112833, 2022.

CHEN, Xu *et al.* Evolution properties between meteorological, agricultural and hydrological droughts and their related driving factors in the Luanhe River basin, China. **Hydrology Research**, v. 50, n. 4, p. 1096–1119, 2019.

CHOUDHARY, Rajat; ATHIRA, P. Effect of root zone soil moisture on the SWAT model simulation of surface and subsurface hydrological fluxes. **Environmental Earth Sciences**, v. 80, n. 18, 2021.

CIRILO, José Almir. Crise hídrica: desafios e superação. **Revista USP**, n. 106, p. 45, 2015.

COOK, B. I. *et al.* Twenty-First Century Drought Projections in the CMIP6 Forcing Scenarios. **Earth's Future**, v. 8, n. 6, 2020.

COSH, Michael H. *et al.* Temporal persistence and stability of surface soil moisture in a semi-arid watershed. **Remote Sensing of Environment**, v. 112, n. 2, p. 304–313, 2008.

COSTA, Micejane da Silva *et al.* Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño–Southern Oscillation. **International Journal of Climatology**, v. 41, n. S1, 2021.

CUARTAS, Luz Adriana *et al.* Recent Hydrological Droughts in Brazil and Their Impact on Hydropower Generation. **Water**, v. 14, n. 4, p. 601, 2022.

CUNHA, Ana Paula M. A. *et al.* Extreme Drought Events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n. 11, p. 642, 2019.

CURK, Miha; GLAVAN, Matjaž; PINTAR, Marina. Analysis of Nitrate Pollution Pathways on a Vulnerable Agricultural Plain in Slovenia: Taking the Local Approach to Balance Ecosystem Services of Food and Water. **Water**, v. 12, n. 3, p. 707, 2020.

MORIASI, Daniel N. *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the ASABE**, v. 50, n. 3, p. 885-900, 2007.

CARVALHO NETO, José Guimarães; SRINIVASAN, Vajapeyam Srirangachar; RUFINO, Iana Alexandra Alvez. Aplicação do modelo SWAT para estudo de cenários hipotéticos na bacia hidrográfica do riacho dos namorados no Cariri Paraibano. **Revista Geográfica Acadêmica**, v. 5, n. 2, p. 30-40, 2011.

DELIBERTY, Tracy L.; LEGATES, David R. Interannual and seasonal variability of modelled soil moisture in Oklahoma. **International Journal of Climatology**, v. 23, n. 9, p. 1057–1086, 2003.

DEVIA, Gayathri K.; GANASRI, B.P.; DWARAKISH, G.S. A Review on Hydrological Models. **Aquatic Procedia**, v. 4, n. 1, p. 1001–1007, 2015.

DIDAN, K. MODIS/Aqua Vegetation Indices Monthly L3 Global 0.05Deg CMG V061. 2021.

DONG, Yi *et al.* Spatial–Temporal Evolution of Vegetation NDVI in Association with Climatic, Environmental and Anthropogenic Factors in the Loess Plateau, China during 2000–2015: Quantitative Analysis Based on Geographical Detector Model. **Remote Sensing**, v. 13, n. 21, p. 4380, 2021.

ERASMI, Stefan *et al.* Vegetation Greenness in Northeastern Brazil and Its Relation to ENSO Warm Events. **Remote Sensing**, v. 6, n. 4, p. 3041–3058, 2014.

FAN, Xingwang *et al.* MODIS detection of vegetation changes and investigation of causal factors in Poyang Lake basin, China for 2001–2015. **Ecological Indicators**, v. 91, p. 511–522, 2018.

FANG, Xuening *et al.* Variations of deep soil moisture under different vegetation types and influencing factors in a watershed of the Loess Plateau, China. **Hydrology and Earth System Sciences**, v. 20, n. 8, p. 3309–3323, 2016.

FARIAS, Carolyne *et al.* Calibration of SWAT model in the Pernambuco state watersheds to support the SUPER system. **Revista Brasileira de Geografia Física**, v. 16, n. 6, p. 3572–3592, 2023.

FERRIGO, SARA. **Análise de consistência dos parâmetros do modelo swat obtidos por calibração automática—estudo de caso da bacia do lago descoberto-DF**. 2014. 166 f. Dissertação (Mestrado em Tecnologia Ambiental e Recursos Hídricos) - Universidade de Brasília, 2014.

FITZJOHN, C; TERNAN, J.L; WILLIAMS, A.G. Soil moisture variability in a semi-arid gully catchment: implications for runoff and erosion control. **Catena**, v. 32, n. 1, p. 55–70, 1998.

FORD, Trent W. *et al.* On the utility of in situ soil moisture observations for flash drought early warning in Oklahoma, USA. **Geophysical Research Letters**, v. 42, n. 22, p. 9790–9798, 2015.

FUNK, Chris *et al.* The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Scientific Data**, v. 2, n. 1, p. 150066, 2015.

GALVINCIO, Josicleda Domiciano; DE QUEIROGA MIRANDA, Rodrigo; DA LUZ, Gabrielly Gregorio. Use of Soil Moisture as an Indicator of Climate Change in the SUPer System. **Hydrology**, v. 11, n. 5, p. 65, 2024.

GEORGANOS, Stefanos *et al.* Examining the NDVI-rainfall relationship in the semi-arid Sahel using geographically weighted regression. **Journal of Arid Environments**, v. 146, p. 64–74, 2017.

GESSESSE, Agenagnew A.; MELESSE, Assefa M. Temporal relationships between time series CHIRPS-rainfall estimation and eMODIS-NDVI satellite images in Amhara Region, Ethiopia. In: **Extreme hydrology and climate variability**. Elsevier, 2019. p. 81-92.

GILBERT, R O. Statistical method for environmental pollution monitoring, Chapter 16.4 Mann–Kendall Test. **and Appendix A, Table A**, v. 18, p. 272, 1987.

GOMES, Mayara Maria de Arruda. **Abordagem integrada de modelagem hidrológica e operação de barragens para avaliação da eficiência do controle de cheias na Bacia do Rio Capibaribe**. 2019. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2019.

GONÇALVES, Suellen Teixeira Nobre *et al.* Índices e Metodologias de Monitoramento de Secas: Uma Revisão. **Revista Brasileira de Meteorologia**, v. 36, n. 3 suppl, p. 495–511, 2021.

GRINSTED, A.; MOORE, J. C.; JEVREJEVA, S. Application of the cross wavelet transform and wavelet coherence to geophysical time series. **Nonlinear Processes in Geophysics**, v. 11, n. 5/6, p. 561–566, 2004.

GUO, Hao *et al.* Meteorological Drought Analysis in the Lower Mekong Basin Using Satellite-Based Long-Term CHIRPS Product. **Sustainability**, v. 9, n. 6, p. 901, 2017.

HARGREAVES, George H.; SAMANI, Zohrab A. Estimating Potential Evapotranspiration. **Journal of the Irrigation and Drainage Division**, v. 108, n. 3, p. 225–230, 1982.

HASTENRATH, Stefan; HELLER, Leon. Dynamics of climatic hazards in northeast Brazil. **Quarterly Journal of the Royal Meteorological Society**, v. 103, n. 435, p. 77–92, 1977.

HAVRYLENKO, S. B. *et al.* Assessment of the soil water content in the Pampas region using SWAT. **Catena**, v. 137, p. 298–309, 2016.

HAYES, Michael J. *et al.* Drought monitoring: Historical and current perspectives. 2011.

HEIM, Richard R. A Review of Twentieth-Century Drought Indices Used in the United States. **Bulletin of the American Meteorological Society**, v. 83, n. 8, p. 1149–1166, 2002.

HOLMES, A. *et al.* Variability of soil moisture proxies and hot days across the climate regimes of Australia. **Geophysical Research Letters**, v. 44, n. 14, p. 7265–7275, 2017.

HUANG, Shengzhi *et al.* A nonparametric multivariate standardized drought index for characterizing socioeconomic drought: A case study in the Heihe River Basin. **Journal of Hydrology**, v. 542, p. 875–883, 2016.

HUANG, Shengzhi *et al.* The response of agricultural drought to meteorological drought and the influencing factors: A case study in the Wei River Basin, China. **Agricultural Water Management**, v. 159, p. 45–54, 2015.

HUDGINS, Lonnie; FRIEHE, Carl A.; MAYER, Meinhard E. Wavelet transforms and atmospheric turbulence. **Physical Review Letters**, v. 71, n. 20, p. 3279–3282, 1993.

HUFFMAN, George J. *et al.* The TRMM Multisatellite Precipitation Analysis (TMPA): Quasi-Global, Multiyear, Combined-Sensor Precipitation Estimates at Fine Scales. **Journal of Hydrometeorology**, v. 8, n. 1, p. 38–55, 2007.

HUO, Wenbo *et al.* GA-PIC: An improved Green-Ampt rainfall-runoff model with a physically based infiltration distribution curve for semi-arid basins. **Journal of Hydrology**, v. 586, n. November 2019, p. 124900, 2020.

IPCC. Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects; New York, NY, USA, 2014.

JEYASEELAN, A. Thillai. Droughts & floods assessment and monitoring using remote sensing and GIS. **Satellite remote sensing and GIS applications in agricultural meteorology**, v. 291, 2003.

JIAN, Shengqi *et al.* Effects of different vegetation restoration on soil water storage and water balance in the Chinese Loess Plateau. **Agricultural and Forest Meteorology**, v. 206, p. 85–96, 2015.

JIANG, Rengui *et al.* Assessment of vegetation growth and drought conditions using satellite-based vegetation health indices in Jing-Jin-Ji region of China. **Scientific Reports**, v. 11, n. 1, p. 13775, 2021.

JONES, Hamlyn G.; VAUGHAN, Robin A. **Remote sensing of vegetation: principles, techniques, and applications**. Oxford University Press, USA, 2010.

JOYCE, Robert J. *et al.* CMORPH: A Method that Produces Global Precipitation Estimates from Passive Microwave and Infrared Data at High Spatial and Temporal Resolution. **Journal of Hydrometeorology**, v. 5, n. 3, p. 487–503, 2004.

JUCÁ, Marcella Vasconcelos Quintella; RIBEIRO NETO, Alfredo. Remote sensing and global databases for soil moisture estimation at different depths in the Pernambuco state, Northeast Brazil. **RBRH**, v. 27, 2022.

KAFFAS, K.; HRISSANTHOU, V.; SEVASTAS, S. Modeling hydromorphological processes in a mountainous basin using a composite mathematical model and ArcSWAT. **Catena**, v. 162, p. 108–129, 2018.

KAMALI, Bahareh *et al.* Multilevel drought hazard assessment under climate change scenarios in semi-arid regions-a case study of the karkheh river basin in Iran. **Water**, v. 9, n. 4, 2017.

KENDALL, Maurice George. Rank correlation methods. 1948.

KHAKI, M.; AWANGE, J. The application of multi-mission satellite data assimilation for studying water storage changes over South America. **Science of The Total Environment**, v. 647, p. 1557–1572, 2019.

KHEZRURI, Yusef; SHARAFATI, Ahmad; NESHAT, Aminreza. Predicting agricultural drought using meteorological and ENSO parameters in different regions of Iran based on the LSTM model. **Stochastic Environmental Research and Risk Assessment**, v. 37, n. 9, p. 3599-3613, 2023.

KUBOTA, Takuji *et al.* Global Precipitation Map Using Satellite-Borne Microwave Radiometers by the GSMaP Project: Production and Validation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 7, p. 2259–2275, 2007.

LEI, Huajin; ZHAO, Hongyu; AO, Tianqi. Ground validation and error decomposition for six state-of-the-art satellite precipitation products over mainland China. **Atmospheric Research**, v. 269, p. 106017, 2022.

LELIS, Thatiana Aparecida *et al.* Análise de sensibilidade e calibração do modelo SWAT aplicado em bacia hidrográfica da região sudeste do Brasil. **Revista Brasileira de Ciência do Solo**, v. 36, n. 2, p. 623–634, 2012.

LI, Bin-Bin *et al.* Deep soil moisture limits the sustainable vegetation restoration in arid and semi-arid Loess Plateau. **Geoderma**, v. 399, p. 115122, 2021.

LI, Liang *et al.* Quantitative analysis of vegetation drought propagation process and uncertainty in the Yellow River Basin. **Agricultural Water Management**, v. 295, p. 108775, 2024.

LI, Yunyun *et al.* Spatiotemporal heterogeneity in meteorological and hydrological drought patterns and propagations influenced by climatic variability, LULC change, and human regulations. **Scientific Reports**, v. 14, n. 1, p. 5965, 2024.

LI, Yunyun *et al.* Temporal and Spatial Propagation Characteristics of the Meteorological, Agricultural and Hydrological Drought System in Different Climatic Conditions within the Framework of the Watershed Water Cycle. **Water**, v. 15, n. 22, p. 3911, 2023.

LINS, Frederico Abraão Costa *et al.* Soil moisture and hydrological processes dynamics under climate and land use changes in a semiarid experimental basin, Brazil. **Ecohydrology & Hydrobiology**, v. 24, n. 3, p. 681–697, 2024.

LV, Aifeng; FAN, Lei; ZHANG, Wenxiang. Impact of ENSO Events on Droughts in China. **Atmosphere**, v. 13, n. 11, p. 1764, 2022.

MAHEU, Audrey *et al.* A field evaluation of soil moisture modelling with the Soil, Vegetation, and Snow (SVS) land surface model using evapotranspiration observations as forcing data. **Journal of Hydrology**, v. 558, p. 532–545, 2018.

MANN, Henry B. Nonparametric tests against trend. **Econometrica: Journal of the econometric society**, p. 245-259, 1945.

MARENGO, Jose A. *et al.* 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, JOSÉ A. *et al.* Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. **Anais da Academia Brasileira de Ciências**, v. 90, n. 2 suppl 1, p. 1973–1985, 2018.

MARENGO, Jose A. *et al.* Increase risk of drought in the semiarid lands of Northeast Brazil due to regional warming above 4 C. In: **Climate change risks in Brazil**. Cham: Springer International Publishing, 2018. p. 181-200.

MARENGO, José A.; CUNHA, Ana P.; ALVES, Lincoln M. A seca de 2012-15 no semiárido do Nordeste do Brasil no contexto histórico. **Revista Climanálise**, v. 3, n. 1, p. 49-54, 2016.

MARTÍNEZ-FERNÁNDEZ, José *et al.* SWAT soil moisture assessment under Mediterranean conditions: An intercomparison analysis in the Henares basin (Spain). **Journal of Hydrology: Regional Studies**, v. 48, 2023.

MCPHADEN, Michael J.; ZEBIAK, Stephen E.; GLANTZ, Michael H. ENSO as an Integrating Concept in Earth Science. **Science**, v. 314, n. 5806, p. 1740–1745, 2006.

MEDEIROS, I. C. *et al.* Run-off–erosion modelling and water balance in the Epiácio Pessoa Dam river basin, Paraíba State in Brazil. **International journal of environmental science and technology**, v. 16, p. 3035-3048, 2019.

MEDEIROS, Felipe Jeferson; DE OLIVEIRA, Cristiano Prestrelo; TORRES, Roger Rodrigues. Climatic aspects and vertical structure circulation associated with the severe drought in Northeast Brazil (2012–2016). **Climate Dynamics**, v. 55, p. 2327-2341, 2020.

MEDEIROS, Rodolpho *et al.* Remote sensing phenology of the Brazilian caatinga and its environmental drivers. **Remote Sensing**, v. 14, n. 11, p. 2637, 2022.

MISHRA, Ashok *et al.* Drought monitoring with soil moisture active passive (SMAP) measurements. **Journal of Hydrology**, v. 552, p. 620–632, 2017.

MISHRA, Ashok K.; SINGH, Vijay P. A review of drought concepts. **Journal of Hydrology**, v. 391, n. 1–2, p. 202–216, 2010.

MOGES, Edom *et al.* Sources of hydrological model uncertainties and advances in their analysis. **Water**, v. 13, n. 1, p. 28, 2021.

MONTEITH, John L. Evaporation and environment. In: **Symposia of the society for experimental biology**. Cambridge University Press (CUP) Cambridge, 1965. p. 205–234.

MONTENEGRO, Suzana; RAGAB, Ragab. Impact of possible climate and land use changes in the semi arid regions: A case study from North Eastern Brazil. **Journal of Hydrology**, v. 434–435, p. 55–68, 2012.

MORIASI, Daniel N. *et al.* Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **Transactions of the ASABE**, v. 50, n. 3, p. 885–900, 2007.

MOUSSA, Roger; CHAHINIAN, Nanée; BOCQUILLON, Claude. Distributed hydrological modelling of a Mediterranean mountainous catchment – Model construction and multi-site validation. **Journal of Hydrology**, v. 337, n. 1–2, p. 35–51, 2007.

MOUSSA KOUROUMA, Jean *et al.* Assessing the spatio-temporal variability of NDVI and VCI as indices of crops productivity in Ethiopia: a remote sensing approach. **Geomatics, Natural Hazards and Risk**, v. 12, n. 1, p. 2880–2903, 2021.

MUKHAWANA, Mxolisi B.; KANYERERE, Thokozani; KAHLER, David. Review of In-Situ and Remote Sensing-Based Indices and Their Applicability for Integrated Drought Monitoring in South Africa. **Water**, v. 15, n. 2, p. 240, 2023.

MUSYOKA, Francis Kilundu *et al.* Multi-step calibration approach for SWAT model using soil moisture and crop yields in a small agricultural catchment. **Water**, v. 13, n. 16, 2021.

NETO, José de Oliveira Melo *et al.* Simulação hidrológica escalar com o modelo SWAT. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 1, p. 177–188, 2014.

NGUYEN, Thi Thu Ha *et al.* Multiple drought indices and their teleconnections with ENSO in various spatiotemporal scales over the Mekong River Basin. **Science of the Total Environment**, v. 854, p. 158589, 2023.

NICOLAI-SHAW, Nadine *et al.* A drought event composite analysis using satellite remote-sensing based soil moisture. **Remote Sensing of Environment**, v. 203, p. 216–225, 2017.

NIU, Jun *et al.* Time-lag effects of vegetation responses to soil moisture evolution: a case study in the Xijiang basin in South China. **Stochastic Environmental Research and Risk Assessment**, v. 32, n. 8, p. 2423–2432, 2018.

OERTEL, Melanie *et al.* Drought Propagation in Semi-Arid River Basins in Latin America: Lessons from Mexico to the Southern Cone. **Water**, v. 10, n. 11, p. 1564, 2018.

PAREDES, F. J.; BARBOSA, H.; GUEVARA, E. Análisis espacial y temporal de las sequías en el nordeste de Brasil. **Agriscientia**, v. 32, n. 1, p. 1-14, 2015.

PAREDES-TREJO, Franklin 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.

PERNAMBUCO. Plano Hidroambiental da Bacia Hidrográfica do rio Capibaribe, TOMO I, VOL II. Recife, 2010.

PRIESTLEY, Charles Henry Brian; TAYLOR, Robert Joseph. On the assessment of surface heat flux and evaporation using large-scale parameters. **Monthly weather review**, v. 100, n. 2, p. 81-92, 1972.

QI, Junyu *et al.* Assessing the performance of a physically-based soil moisture module integrated within the Soil and Water Assessment Tool. **Environmental Modelling and Software**, v. 109, p. 329–341, 2018.

RABELO, Udinart P. *et al.* Representing a dense network of ponds and reservoirs in a semi-distributed dryland catchment model. **Journal of Hydrology**, v. 603, p. 127103, 2021.

RAJIB, Mohammad Adnan; MERWADE, Venkatesh; YU, Zhiqiang. Multi-objective calibration of a hydrologic model using spatially distributed remotely sensed/in-situ soil moisture. **Journal of Hydrology**, v. 536, p. 192–207, 2016.

REBELLO, Paiva Alcoforado Vitor *et al.* Spatiotemporal vegetation response to extreme droughts in eastern Brazil. **Remote Sensing Applications: Society and Environment**, v. 18, n. November 2019, 2020.

REDDY, Gangalakunta P. Obi *et al.* Assessment of spatio-temporal vegetation dynamics in tropical arid ecosystem of India using MODIS time-series vegetation indices. **Arabian Journal of Geosciences**, v. 13, n. 15, p. 704, 2020.

REDDY, GP Obi. Satellite remote sensing sensors: principles and applications. **Geospatial technologies in land resources mapping, monitoring and management**, p. 21-43, 2018.

RETALIS, Adrianos *et al.* Downscaling CHIRPS precipitation data: an artificial neural network modelling approach. **International Journal of Remote Sensing**, v. 38, n. 13, p. 3943–3959, 2017.

REYNOLDS, James F. *et al.* Global desertification: building a science for dryland development. **Science**, v. 316, n. 5826, p. 847-851, 2007.

RIBEIRO NETO, A. *et al.* Infrastructure sufficiency in meeting water demand under climate-induced socio-hydrological transition in the urbanizing Capibaribe River basin–Brazil. **Hydrology and Earth System Sciences**, v. 18, n. 9, p. 3449-3459, 2014.

ROMANO, Nunzio. Soil moisture at local scale: Measurements and simulations. **Journal of Hydrology**, v. 516, p. 6-20, 2014.

ROUSHANGAR, Kiyoumars; GHASEMPOUR, Roghayeh; NOURANI, Vahid. Spatiotemporal analysis of droughts over different climate regions using hybrid clustering method. **Water Resources Management**, p. 1-16, 2022.

SALGUEIRO, Joao H P De Britto *et al.* Tendência de índices pluviométricos na bacia do rio Capibaribe-PE e sua influência na gestão dos recursos hídricos. **Revista Brasileira de Geografia Física**, v. 07, p. 1002–1014, 2014.

SANDEEP, P. *et al.* Monitoring of agricultural drought in semi-arid ecosystem of Peninsular India through indices derived from time-series CHIRPS and MODIS datasets. **Ecological indicators**, v. 121, p. 107033, 2021.

SANOGO, Karamoko *et al.* Spatiotemporal Response of Vegetation to Rainfall and Air Temperature Fluctuations in the Sahel: Case Study in the Forest Reserve of Fina, Mali. **Sustainability**, v. 13, n. 11, p. 6250, 2021.

SANTOS, Celso Augusto Guimarães *et al.* Analyzing the impact of ocean-atmosphere teleconnections on rainfall variability in the Brazilian Legal Amazon via the Rainfall Anomaly Index (RAI). **Atmospheric Research**, v. 307, p. 107483, 2024.

SANTOS, Celso Augusto Guimarães *et al.* Geospatial drought severity analysis based on PERSIANN-CDR-estimated rainfall data for Odisha state in India (1983–2018). **Science of The Total Environment**, v. 750, n. 3–4, p. 141258, 2021.

SANTOS, Celso Augusto Guimarães; SILVA, Richarde Marques da; PAIVA, Fernanda Maria de Lima. Modelagem hidrossedimentológica de uma microbacia da bacia experimental de São João do Cariri. **Anais do XVI Simpósio de Recursos Hídricos do Nordeste, João Pessoa. Novembro**, v. 1, 2005.

SANTOS, Daris Correia *et al.* Precipitation variability using GPCP data and its relationship with atmospheric teleconnections in Northeast Brazil. **Climate Dynamics**, v. 61, n. 11–12, p. 5035–5048, 2023.

SANTOS, José Yure Gomes *et al.* Modeling the impacts of future LULC and climate change on runoff and sediment yield in a strategic basin in the Caatinga/Atlantic forest ecotone of Brazil. **Catena**, v. 203, p. 105308, 2021b.

SANTOS, Marcus Suassuna *et al.* Time-space characterization of droughts in the São Francisco river catchment using the Standard Precipitation Index and continuous wavelet transform. **RBRH**, v. 24, 2019.

SANTOS, Thalyta Soares dos *et al.* Análise de Eventos Extremos na Região Amazônica. **Revista Brasileira de Geografia Física**, v. 6, n. 5, p. 1356, 2013.

SEHGAL, Vinit *et al.* Integrating climate forecasts with the Soil and Water Assessment Tool (SWAT) for high-resolution hydrologic simulations and forecasts in the Southeastern U.S. **Sustainability**, v. 10, n. 9, 2018.

SEHGAL, V. Near Real-time Seasonal Drought Forecasting and Retrospective Drought Analysis using Simulated Multi-layer Soil Moisture from Hydrological Models at Sub-Watershed Scales. 2017. - Virginia Polytechnic Institute and State University, 2017.

SEHGAL, Vinit; SRIDHAR, Venkataramana. Effect of hydroclimatological teleconnections on the watershed-scale drought predictability in the southeastern United States. **International Journal of Climatology**, v. 38, n. February, p. e1139–e1157, 2018.

SEHGAL, Vinit; SRIDHAR, Venkataramana. Watershed-scale retrospective drought analysis and seasonal forecasting using multi-layer, high-resolution simulated soil moisture for Southeastern U.S. **Weather and Climate Extremes**, v. 23, n. July 2018, p. 100191, 2019.

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

SENEVIRATNE, Sonia *et al.* Changes in climate extremes and their impacts on the natural physical environment. 2012.

SENEVIRATNE, Sonia I. *et al.* Investigating soil moisture–climate interactions in a changing climate: A review. **Earth-Science Reviews**, v. 99, n. 3-4, p. 125-161, 2010.

SHAFIEE-JOOD, Majid *et al.* Assessing the value of seasonal climate forecast information through an end-to-end forecasting framework: Application to U.S. 2012 drought in central Illinois. **Water Resources Research**, v. 50, n. 8, p. 6592–6609, 2014.

SHRESTHA, Manoj Kumar *et al.* Assessing SWAT models based on single and multi-site calibration for the simulation of flow and nutrient loads in the semi-arid Onkaparinga catchment in South Australia. **Agricultural Water Management**, v. 175, p. 61–71, 2016.

SILVA PEREIRA, Thiago Alberto *et al.* Key climate oscillation factors controlling precipitation variability during the dry season in eastern northeast Brazil: Study case of Mundaú and Paraíba do Meio river basins. **Water**, v. 10, n. 11, p. 1617, 2018.

SILVA, Alexandro Medeiros *et al.* Modeling the effects of future climate and land-use changes on streamflow in a headwater basin in the Brazilian Caatinga biome. **Geocarto International**, v. 37, n. 26, p. 12436–12465, 2022a.

SILVA, Antonio Samuel Alves da *et al.* Spatial and Temporal Variability of Precipitation Complexity in Northeast Brazil. **Sustainability**, v. 14, n. 20, p. 13467, 2022.

SILVA, Eduardo *et al.* Spatial variability of precipitation correlated with relief in Recife metropolitan region and surrounding areas. **Journal of Hyperspectral Remote Sensing**, v. 6, n. 5, p. 225–234, 2016.

SILVA, Glauciene Justino Ferreira *et al.* Multi-datasets to monitor and assess meteorological and hydrological droughts in a typical basin of the Brazilian semiarid region. **Environmental Monitoring and Assessment**, v. 196, n. 4, p. 368, 2024.

SILVA, Jhon Lennon Bezerra da *et al.* Environmental degradation of vegetation cover and water bodies in the semiarid region of the Brazilian Northeast via cloud geoprocessing techniques applied to orbital data. **Journal of South American Earth Sciences**, v. 121, p. 104164, 2023.

SILVA, Richarde Marques *et al.* Hydrological simulation in a tropical humid basin in the Cerrado biome using the SWAT model. **Hydrology Research**, v. 49, n. 3, p. 908-923, 2018.

SILVA, Tarciana Rafaela Barbosa Figueiroa *et al.* Climate Indices-Based Analysis of Rainfall Spatiotemporal Variability in Pernambuco State, Brazil. **Water**, v. 14, n. 14, p. 2190, 2022b.

SIMÕES, André Felipe *et al.* Enhancing adaptive capacity to climate change: The case of smallholder farmers in the Brazilian semi-arid region. **Environmental Science & Policy**, v. 13, n. 8, p. 801–808, 2010.

SINGH, Ankita; VYAS, Vipin. A Review on remote sensing application in river ecosystem evaluation. **Spatial Information Research**, v. 30, n. 6, p. 759–772, 2022.

SLOAN, Patrick G. *et al.* Modeling surface and subsurface stormflow on steeply-sloping forested watersheds. 1983.

SOLANDER, Kurt C. *et al.* The pantropical response of soil moisture to El Niño. **Hydrology and Earth System Sciences**, v. 24, n. 5, p. 2303–2322, 2020.

SOLÉ-BENET, Albert *et al.* Influences of micro-relief patterns and plant cover on runoff related processes in badlands from Tabernas (SE Spain). **Catena**, v. 31, n. 1–2, p. 23–38, 1997.

SOROOSHIAN, Soroosh *et al.* Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. **Bulletin of the American Meteorological Society**, v. 81, n. 9, p. 2035-2046, 2000.

SOUSA JUNIOR, M. de A.; LACRUZ, M. S. P. Sensoriamento remoto para seca/estiagem. **SAUSEN, TM; LACRUZ, MSP Sensoriamento Remoto para Desastres. São Paulo: Oficina de Textos**, p. 149-174, 2015.

SOUZA, Alzira GSS *et al.* Use of SMOS L3 soil moisture data: Validation and drought assessment for Pernambuco State, Northeast Brazil. **Remote Sensing**, v. 10, n. 8, p. 1314, 2018.

SOUZA, Alzira Gabrielle Soares Saraiva; RIBEIRO NETO, Alfredo; SOUZA, Laio Lucas de. Soil moisture-based index for agricultural drought assessment: SMADI application in Pernambuco State-Brazil. **Remote Sensing of Environment**, v. 252, p. 112124, 2021.

SRIVASTAVA, Ankur *et al.* The role of landscape morphology on soil moisture variability in semi-arid ecosystems. **Hydrological Processes**, v. 35, n. 1, 2021.

SUN, Qianqian *et al.* A Weighted-Time-Lag Method to Detect Lag Vegetation Response to Climate Variation: A Case Study in Loess Plateau, China, 1982–2013. **Remote Sensing**, v. 13, n. 5, p. 923, 2021.

SURMAINI, Elza *et al.* Early detection of drought impact on rice paddies in Indonesia by means of Niño 3.4 index. **Theoretical and Applied Climatology**, v. 121, n. 3–4, p. 669–684, 2015.

SVOBODA, Mark D. *et al.* **Handbook of drought indicators and indices**. Geneva, Switzerland: World Meteorological Organization, 2016.

TAMIMINIA, Haifa *et al.* Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **ISPRS journal of photogrammetry and remote sensing**, v. 164, p. 152-170, 2020.

TAYLOR, Christopher M. *et al.* Afternoon rain more likely over drier soils. **Nature**, v. 489, n. 7416, p. 423–426, 2012.

TOMLINSON, Charlie J. *et al.* Remote sensing land surface temperature for meteorology and climatology: a review. **Meteorological Applications**, v. 18, n. 3, p. 296–306, 2011.

TÖRNROS, T.; MENZEL, L. Addressing drought conditions under current and future climates in the Jordan River region. **Hydrology and Earth System Sciences**, v. 18, n. 1, p. 305–318, 2014.

TORRENCE, Christopher; COMPO, Gilbert P. A Practical Guide to Wavelet Analysis. *Bulletin of the American Meteorological Society*, v. 79, n. 1, p. 61–78, 1998.

TORRENCE, Christopher; WEBSTER, Peter J. Interdecadal Changes in the ENSO–Monsoon System. **Journal of Climate**, v. 12, n. 8, p. 2679–2690, 1999.

TOULIOS, Leonidas. Remote sensing as a service tool for the detection of water resources and crop conditions monitoring. **Hellenic Agricultural Organization DEMETER; Institute of Soil Classification & Mapping: Larissa, Greece**, 2015.

TRENBERTH, Kevin E. The definition of el nino. **Bulletin of the American Meteorological Society**, v. 78, n. 12, p. 2771-2778, 1997.

TUCCI, Carlos E. M. Modelos Hidrológicos. Universidaed. Porto Alegre, 2005.

UNIYAL, Bhumika *et al.* Evaluation of SWAT simulated soil moisture at catchment scale by field measurements and Landsat derived indices. **Agricultural Water Management**, v. 193, p. 55–70, 2017.

VENZON, Pedro Thiago; PINHEIRO, Adilson; KAUFMANN, Vander. Hydrological simulation uncertainties in small basins through the SWAT model. **RBRH**, v. 23, n. 0, 2018.

VERECKEN, H. *et al.* On the value of soil moisture measurements in vadose zone hydrology: A review. **Water Resources Research**, v. 44, 2008.

VIANA, Jussara Freire de Souza *et al.* Evaluation of gridded meteorological datasets and their potential hydrological application to a humid area with scarce data for Pirapama River basin, northeastern Brazil. **Theoretical and Applied Climatology**, v. 145, n. 1–2, p. 393–410, 2021.

VIANA, Jussara Freire de Souza. **Impactos das mudanças do uso da terra sobre o balanço hidrossedimentológico: bases para gerenciamento dos recursos hídricos na Bacia do Rio Pirapama**. 2019. 192 f. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Pernambuco, Recife, 2019.

DE SOUZA VIANA, Jussara Freire *et al.* Modelagem hidrológica da Bacia Hidrográfica do Rio Pirapama-PE utilizando o modelo SWAT. **Journal of Environmental Analysis and Progress**, p. 155-172, 2018.

VICENTE-SERRANO, Sergio M. *et al.* A multiscale global evaluation of the impact of ENSO on droughts. **Journal of Geophysical Research**, v. 116, n. D20, p. D20109, 2011.

WANG, Jie *et al.* The Time Lag Effects and Interaction among Climate, Soil Moisture, and Vegetation from In Situ Monitoring Measurements across China. **Remote Sensing**, v. 16, n. 12, p. 2063, 2024.

WANG, Aihui; LETTENMAIER, Dennis P.; SHEFFIELD, Justin. Soil moisture drought in China, 1950-2006. **Journal of Climate**, v. 24, n. 13, p. 3257–3271, 2011.

WANG, Lingli; QU, John J. Satellite remote sensing applications for surface soil moisture monitoring: A review. **Frontiers of Earth Science in China**, v. 3, p. 237-247, 2009.

WICKHAM, Hadley. ggplot2. New York, NY: Springer New York, 2009.

WILHITE, Donald A.; PULWARTY, R. S. National drought management policy guidelines: A template for action. **Integrated Drought Management Programme (IDMP) Tools and Guidelines Series**, v. 1, 2014.

WILHITE, Donald A. The role of disaster preparedness in national planning with specific reference to droughts. In: **Natural Disasters and Extreme Events in Agriculture: Impacts and Mitigation**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005. p. 23-37.

WILHITE, Donald A.; GLANTZ, Michael H. Understanding: the drought phenomenon: the role of definitions. **Water international**, v. 10, n. 3, p. 111-120, 1985.

WILKS, Daniel S. **Statistical Methods in the Atmospheric Sciences**. Elsevier, 2006.

WIT, Anja de. Runoff controlling factors in various sized catchments in a semi-arid Mediterranean environment in Spain. 2001. 228 f. Universiteit Utrecht, 2001.

WU, Hong *et al.* Appropriate application of the standardized precipitation index in arid locations and dry seasons. **International Journal of Climatology**, v. 27, n. 1, p. 65–79, 2007.

WU, Qiusheng *et al.* Evaluation of AMSR2 soil moisture products over the contiguous United States using in situ data from the International Soil Moisture Network. **International Journal of Applied Earth Observation and Geoinformation**, v. 45, p. 187–199, 2016.

XAVIER, Alexandre C. *et al.* New improved Brazilian daily weather gridded data (1961–2020). **International Journal of Climatology**, v. 42, n. 16, p. 8390–8404, 2022.

XIONG, Jun *et al.* Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 126, p. 225–244, 2017.

XU, Yang *et al.* Characterization of agricultural drought propagation over China based on bivariate probabilistic quantification. **Journal of Hydrology**, v. 598, p. 126194, 2021.

XU, Peipei *et al.* Diverse responses of different structured forest to drought in Southwest China through remotely sensed data. **International Journal of Applied Earth Observation and Geoinformation**, v. 69, p. 217–225, 2018.

XU, Yang *et al.* Propagation from meteorological drought to hydrological drought under the impact of human activities: A case study in northern China. **Journal of Hydrology**, v. 579, p. 124147, 2019.

XUE, Jinru; SU, Baofeng. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, v. 2017, p. 1–17, 2017.

YANG, Lei *et al.* Response of temporal variation of soil moisture to vegetation restoration in semi-arid Loess Plateau, China. **Catena**, v. 115, p. 123–133, 2014.

YEVJEVICH, Vujica M. *et al.* **An objective approach to definitions and investigations of continental hydrologic droughts.** Fort Collins, CO, USA: Colorado State University, 1967.

YINGLAN, A *et al.* Spatial variation of correlations between vertical soil water and evapotranspiration and their controlling factors in a semi-arid region. **Journal of Hydrology**, v. 574, n. April, p. 53–63, 2019.

ZAMBRANO, Francisco *et al.* Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile. **Atmospheric Research**, v. 186, p. 26–42, 2017.

ZAMBRANO MERA, Yeriel Elizabeth; RIVADENEIRA VERA, Jonny Fernando; PÉREZ-MARTÍN, Miguel Ángel. Linking El Niño Southern Oscillation for early drought detection in tropical climates: The Ecuadorian coast. **Science of The Total Environment**, v. 643, p. 193–207, 2018.

ZARE, Mohammad; AZAM, Shahid; SAUCHYN, David. Evaluation of Soil Water Content Using SWAT for Southern Saskatchewan, Canada. **Water**, v. 14, n. 2, p. 249, 2022.

ZARGAR, Amin *et al.* A review of drought indices. **Environmental Reviews**, v. 19, n. NA, p. 333-349, 2011.

ZERI, Marcelo; *et al.* A soil moisture dataset over the Brazilian semiarid region. 2020. Disponível em: <https://data.mendeley.com/datasets/xrk5rfcpvg/2>. Acesso em: 1 jan. 2022.

ZERI, Marcelo *et al.* Importance of including soil moisture in drought monitoring over the Brazilian semiarid region: An evaluation using the JULES model, in situ observations, and remote sensing. **Climate Resilience and Sustainability**, v. 1, n. 1, p. 1–18, 2022.

ZHANG, Zezhong *et al.* Analysis of Spatiotemporal Variation Characteristics and Driving Factors of Drought in Yinshanbeilu Inner Mongolia Based on a Cloud Model. **Water**, v. 16, n. 2, p. 265, 2024.

ZHANG, Xuan *et al.* Drought propagation under global warming: Characteristics, approaches, processes, and controlling factors. **Science of The Total Environment**, v. 838, p. 156021, 2022.

ZHANG, Chunhua; KOVACS, John M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, v. 13, n. 6, p. 693–712, 2012.

ZHANG, Dianjun; ZHOU, Guoqing. Estimation of soil moisture from optical and thermal remote sensing: A review. **Sensors**, v. 16, n. 8, 2016.

ZHAO, Anzhou *et al.* Evaluating the cumulative and time-lag effects of drought on grassland vegetation: A case study in the Chinese Loess Plateau. **Journal of Environmental Management**, v. 261, p. 110214, 2020.

ZHAO, Nana *et al.* Investigation of rainfall-runoff processes and soil moisture dynamics in grassland plots under simulated rainfall conditions. **Water**, v. 6, n. 9, p. 2671–2689, 2014.

ZHE, Meng; ZHANG, Xueqin. Time-lag effects of NDVI responses to climate change in the Yamzhog Yumco Basin, South Tibet. **Ecological Indicators**, v. 124, 2021.

ZHOU, Yu *et al.* Climate contributions to vegetation variations in Central Asian drylands: Pre- and post-USSR collapse. **Remote Sensing**, v. 7, n. 3, p. 2449–2470, 2015.

ZHOU, Keke *et al.* The use of combined soil moisture data to characterize agricultural drought conditions and the relationship among different drought types in China. **Agricultural Water Management**, v. 243, p. 106479, 2021.

ZHU, Lingli *et al.* A review: Remote sensing sensors. **Multi-purposeful application of geospatial data**, v. 19, 2018.