



*Universidade Federal da Paraíba
Centro de Tecnologia
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E
AMBIENTAL
– MESTRADO –*

**AVALIAÇÃO DA SECA E DE SUAS CARACTERÍSTICAS SOBRE O
ESTADO DA PARAÍBA UTILIZANDO DADOS TRMM E DE
PLUVIÔMETROS (1998–2017)**

Por

Reginaldo Moura Brasil Neto

*Dissertação de Mestrado apresentada à Universidade Federal da Paraíba para
obtenção do grau de Mestre*

João Pessoa – Paraíba

Março de 2020



Universidade Federal da Paraíba
Centro de Tecnologia
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E
AMBIENTAL**
- MESTRADO -

**AVALIAÇÃO DA SECA E DE SUAS CARACTERÍSTICAS SOBRE O
ESTADO DA PARAÍBA UTILIZANDO DADOS TRMM E DE
PLUVIÔMETROS (1998–2017)**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Civil e Ambiental da Universidade Federal da Paraíba, como parte dos requisitos para a obtenção do título de Mestre.

Reginaldo Moura Brasil Neto

Orientador: Prof. Dr. Celso Augusto Guimarães Santos

João Pessoa – Paraíba

Março de 2020

**Catalogação na publicação
Seção de Catalogação e Classificação**

N469a Neto, Reginaldo Moura Brasil.

Avaliação da seca e de suas características sobre o
estado da Paraíba utilizando dados TRMM e de
pluviômetros (1998-2017) / Reginaldo Moura Brasil Neto.
- João Pessoa, 2020.
189 f. : il.

Orientação: Celso Augusto Guimarães Santos.
Dissertação (Mestrado) - UFPB/Tecnologia.

1. Secas. 2. Paraíba. 3. SPI. 4. TRMM. I. Santos, Celso
Augusto Guimarães. II. Título.

UFPB/BC

REGINALDO MOURA BRASIL NETO

**AVALIAÇÃO DA SECA E DE SUAS CARACTERÍSTICAS SOBRE O
ESTADO DA PARAÍBA UTILIZANDO DADOS TRMM E DE
PLUVIÔMETROS (1998–2017)**

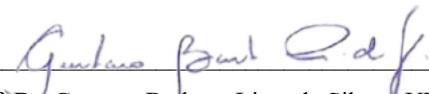
Dissertação aprovada em 20/03/2020 como requisito para a obtenção do título de Mestre em Engenharia Civil e Ambiental do Centro de Tecnologia da Universidade Federal da Paraíba.

BANCA EXAMINADORA



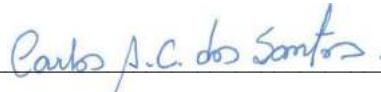
Prof. Dr. Celso Augusto Guimarães Santos – UFPB

(Orientador)



Prof. Dr. Gustavo Barbosa Lima da Silva – UFPB

(Examinador Interno)



Prof. Dr. Carlos Antônio Costa dos Santos – UFCG

(Examinador Externo)

Nenhuma pessoa, por mais inteligente que seja, é melhor que o grupo.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por não desistir de mim e me levantar nos momentos em que mais pensei ser incapaz. Obrigado por tudo e tanto mesmo que eu não mereça, Pai.

À minha maior fã, Paula Catarina, por todo empenho, cuidado e zelo ao decorrer de toda a caminhada. A vitória é mais sua do que minha.

Ao meu pai, Reginaldo Pires, por toda contribuição e ensinamento dado desde o início, garantindo as boas condições de educação desde cedo, sem a qual não teria chegado até aqui.

À minha avó, Jaclyete Pires, fiel admiradora das minhas conquistas e componente impar de mais essa etapa concluída. Vida longa a você minha rainha e que eu possa levar o nome de seu companheiro à frente com muito orgulho.

Ao querido amigo, Valerio Ribeiro, a quem aprendi a admirar no muito e no pouco. Obrigado por sua lealdade meu amigo e sou feliz por compartilhar momentos com você.

À minha namorada, Byanka Vanessa, por toda compreensão, cuidado e zelo ao decorrer da jornada. Obrigado por ser uma companheira fiel, paciente e amiga desde sempre.

Ao meu querido orientador, Prof. Dr. Celso Augusto, por todos os ensinamentos e por todo tempo dedicado desde sempre. Sem você, muito disso não seria possível e esteja certo de que você é um exemplo de profissional, especialmente para este seu filho engenheiro.

Aos professores e profissionais que contribuíram para minha formação acadêmica, em especial ao Prof. Dr. Carlos Antônio e ao Prof. Dr. Gustavo Barbosa por terem aceitado a missão e pelos conselhos e orientações dadas no intuito de me fazer seguir os bons caminhos.

Aos amigos da M2 Construções, por toda compreensão e por todas as oportunidades. A M2 tem lugar especial no meu coração e que possamos crescer juntos e cada vez mais.

Aos meus queridos amigos que tanto contribuíram e depositaram confiança, acreditando mais em mim do que eu mesmo. Em especial, às amigas que ganhei nessa caminhada Camila, Isabelly, Lairanne, Moana, Isabel, Vanessa, Paula, Natália, Tatiane e aos amigos Alexandre, Jorge e Thiago, dos quais espero levar para o resto da vida.

Aos demais familiares e amigos que estiverem comigo nos momentos bons e ruins.

Mais um ciclo que se fecha para que outro inicie. Que Deus nos abençoe e nos proteja.

RESUMO

A seca é um fenômeno natural originado a partir da ausência de precipitação ao longo de certo período capaz de causar danos ao desenvolvimento de diferentes atividades da sociedade. Para analisar esses fenômenos, as estimativas de chuvas oriundas de satélites de sensoriamento remoto têm aparecido como alternativa viável para monitorar as secas nas áreas mais remotas e complexas do mundo. Nesse sentido, este trabalho objetiva avaliar o comportamento espaço-temporal das secas em múltiplas escalas temporais e das suas características sobre o estado da Paraíba, com base no índice *Standardized Precipitation Index* (SPI), utilizando dados de postos pluviométricos e estimativas de precipitação do satélite TRMM (*Tropical Rainfall Measuring Mission*) (1998–2017). Para tanto, foram utilizados dados mensais de 78 postos pluviométricos e de 187 *grids* TRMM e foram desenvolvidas análises de secas pontuais e por mesorregiões em oito escalas de tempo. A precisão estatística do satélite foi avaliada a partir de 11 métricas e os eventos de seca foram caracterizados quanto à duração, severidade, intensidade, frequência e percentual de área atingida. Além disso, foram realizadas análises de tendências com base nos testes não paramétricos de Mann-Kendall e Sen e análises de *clusters* hierárquicas para zonear o estado em diferentes zonas homogêneas. Por fim, propôs-se um índice composto geoespacial que mensura o risco à ação das secas em várias escalas de tempo a partir das características das secas, o NIDS-Trend. Os resultados indicam que nas mesorregiões próximas ao litoral, o satélite é menos preciso ao captar o padrão das secas, e que os resultados das secas de médio prazo são os mais expressivos dentre as demais escalas temporais. Por outro lado, tendem a ocorrer mais eventos de seca de curto prazo e esses são menos duradouros e severos do que ao avaliar os de longo prazo, apesar de não ter sido possível identificar alterações relevantes quanto à intensidade média dos eventos. No tocante a análise de tendências, percebeu-se que quanto maior a escala temporal, mais expressivas e significantes foram as declividades das linhas de tendência e além disso, há indícios de que os eventos de seca tendem a ser mais secos, duradouros e severos em grande parte do estado. O zoneamento quanto ao padrão das secas indica que há forte tendência em dividir o estado em duas grandes regiões, sendo uma formada pela Mata Paraibana e Agreste e outra pelo Sertão e Borborema. Quanto ao NIDS-Trend, percebeu-se que os valores das secas de curto prazo foram maiores, enquanto que o risco à ação das secas foi menor para as secas de longo prazo. Conclui-se que as estimativas do TRMM são uma fonte de dados útil no processo de caracterização das secas sobre o estado da Paraíba e que estudos desse tipo devem ser feitos para monitorar esses fenômenos mais precisamente.

PALAVRAS-CHAVE: Secas, Paraíba, SPI, TRMM.

ABSTRACT

Drought is a natural phenomenon originated from the absence of precipitation over a certain period that is capable of causing damage to the development of different activities in society. To analyze these phenomena, rainfall estimates from remote sensing satellites have appeared as a viable alternative to monitor droughts in the most remote and complex areas of the world. In this sense, this work aims to evaluate the spatio-temporal behavior of droughts at multiple time scales and their characteristics on the state of Paraíba, based on the *Standardized Precipitation Index* (SPI), using data from rainfall stations and satellite precipitation estimates TRMM (*Tropical Rainfall Measuring Mission*) (1998–2017). For that, monthly data from 78 pluviometric stations and 187 TRMM grids were used and analyzes of specific droughts and mesoregions were developed in eight time scales. The statistical accuracy of the satellite was assessed from 11 metrics and the drought events were characterized in terms of duration, severity, intensity, frequency and percentage of affected area. In addition, trend analyzes were performed based on Mann-Kendall and Sen's non-parametric tests and hierarchical cluster analyzes to zonate the state in different homogeneous zones. Finally, a composite geospatial index that measures the risk of drought action at various time scales based on drought characteristics, the NIDS-Trend, was proposed. The results indicate that in the mesoregions close to the coast the satellite is less accurate in capturing the pattern of droughts, and that the results of medium-term droughts are the most expressive among the other time scales. On the other hand, more short-term drought events tend to occur and these are less long-lasting and severe than when evaluating long-term droughts, although it was not possible to identify relevant changes regarding the average intensity of the events. Regarding the trend analysis, it was noticed that the larger the time scale, the more expressive and significant the slopes of the trend lines were, and moreover, there are indications that drought events tend to be drier, longer and more severe in much of the state. The zoning regarding the pattern of droughts indicates that there is a strong tendency to divide the state into two large regions, one formed by Mata Paraibana and Agreste and another by Sertão and Borborema. As for the NIDS-Trend, it was noticed that the values of short-term droughts were higher, while the risk to the action of droughts was lower for long-term droughts. Finally, it is concluded that the TRMM estimates are a useful source of data in the process of characterizing droughts over the state of Paraíba and that studies of this type should be carried out to monitor these phenomena more precisely.

KEYWORDS: Drought, Paraíba, SPI, TRMM.

SUMÁRIO

1.	INTRODUÇÃO	12
2.	OBJETIVOS	13
3.	FUNDAMENTAÇÃO TEÓRICA	14
3.1.	PRECIPITAÇÃO	14
3.2.	O TRMM E OS SATÉLITES DE SENSORIAMENTO REMOTO	17
3.3.	ANÁLISE DA SECA	24
3.4.	STANDARDIZED PRECIPITATION INDEX (SPI)	32
3.5.	ANÁLISE DE TENDÊNCIAS.....	41
3.6.	ANÁLISE DE AGRUPAMENTO.....	48
4.	MATERIAIS E MÉTODOS.....	54
4.1.	ÁREA DE ESTUDO.....	54
4.2.	DADOS DE PRECIPITAÇÃO.....	56
4.2.1.	DADOS DE PLUVIÔMETROS	56
4.2.2.	DADOS TRMM	60
4.3.	STANDARDIZED PRECIPITATION INDEX (SPI).....	61
4.3.1.	METODOLOGIA DE CÁLCULO	61
4.3.2.	RUN THEORY E CARACTERIZAÇÃO DOS EVENTOS DE SECA	65
4.4.	ANÁLISE DE TENDÊNCIAS.....	68
4.5.	ANÁLISE DE AGRUPAMENTO.....	71
4.6.	ANÁLISE DE ACURÁCIA ESTATÍSTICA	75
4.7.	ANÁLISE DE RISCO DAS SECAS	80
5.	RESULTADOS E DISCUSSÃO	83
5.1.	AVALIAÇÃO DAS SECAS SOBRE A PARAÍBA	83
5.2.	QUANTO À ACURÁCIA ESTATÍSTICA	90
5.3.	QUANTO À CARACTERIZAÇÃO DAS SECAS	105
5.4.	QUANTO À ANÁLISE DE TENDÊNCIA	125
5.5.	QUANTO À ANÁLISE DE AGRUPAMENTO	139
5.6.	AVALIAÇÃO DO NIDS-TREND.....	159
6.	CONCLUSÕES	168
7.	RECOMENDAÇÕES	169
	REFERÊNCIAS BIBLIOGRÁFICAS	171

LISTA DE FIGURAS

Figura 1– Influência da (a) métrica de dissimilaridade e do (b) método de ligação entre <i>clusters</i> na formação de diferentes grupos homogêneos.	50
Figura 2 – Estado da Paraíba e suas mesorregiões.	54
Figura 3 –(a) Distribuição espacial do percentual de falha das séries de chuva, (b) distribuição percentual das falhas para cada mesorregião e (c) evolução temporal do percentual de dados disponíveis ao longo dos 20 anos.	57
Figura 4 – Distribuição espacial da grade TRMM e dos postos pluviométricos utilizados sobre o estado da Paraíba.	61
Figura 5 – (a) Hietograma utilizado para o cálculo do SPI-1 do mês de abril, (b) adequação da série pluviométrica conforme uma distribuição gama $H(x)$, (c) padronização dos valores de $H(x)$ conforme uma distribuição normal $N(0,1)$ e (d) relação entre os valores de precipitação e de SPI.....	62
Figura 6 – Definição de um evento de seca e suas principais características.....	66
Figura 7 – Tabela de contingência para avaliação de índices de desempenho.....	79
Figura 8 – (a) Hietograma e gráfico de dispersão da precipitação média mensal sobre o estado da Paraíba usando pluviômetros e estimativas do TRMM, e comportamento do SPI 1-48 com base nos: (b) dados de pluviômetros e nas (c) estimativas do TRMM (1998–2017).	85
Figura 9 – Variação temporal do índice SPI e análise de frequência dos tipos de eventos em múltiplas escalas temporais com base na série de precipitação média sobre a Paraíba, utilizando dados de pluviômetros (à esquerda) e as estimativas do TRMM (à direita).	88
Figura 10 – Distribuição espacial dos índices R , Kd e Kp sobre o estado da Paraíba.	92
Figura 11 – Distribuição espacial dos índices B , RB , MSE e $RMSE$ sobre o estado da Paraíba.	94
Figura 12 – Distribuição espacial dos índices PC , POD , $(1 - FAR)$ e CSI sobre o estado da Paraíba.	98
Figura 13 – Análise de acurácia estatística dos índices R , $RMSE$, Kd , Kp e PC para cada uma das mesorregiões do estado da Paraíba (1998–2017).	101
Figura 14 – Diagrama de desempenho de Roebber <i>et al.</i> (2009) para as mesorregiões da Paraíba.	104
Figura 15 – Distribuição espacial da quantidade e da intensidade média dos eventos de seca sobre o estado da Paraíba (1998–2017).....	106

Figura 16 – Distribuição espacial da duração e da severidade média dos eventos de seca sobre o estado da Paraíba (1998–2017).....	108
Figura 17 – Análise do número de eventos de secas e duração, severidade e intensidade média dos eventos de secas para as mesorregiões do estado da Paraíba em múltiplas escalas temporais (1998–2017). Os dados de postos pluviométricos estão em azul e os do TRMM em vermelho.	111
Figura 18 – Distribuição espacial do percentual de ocorrência de eventos suavemente e moderadamente secos sobre o estado da Paraíba (1998–2017).....	114
Figura 19 – Distribuição espacial do percentual de ocorrência de eventos severamente e extremamente secos sobre o estado da Paraíba (1998–2017).....	116
Figura 20 – Análise de frequência dos tipos de eventos secos para as mesorregiões do estado da Paraíba em múltiplas escalas temporais utilizando dados de pluviômetros (à esquerda) e TRMM (à direita) (1998–2017).....	118
Figura 21 – Variação do percentual de área atingida pelos tipos de eventos secos sobre o estado da Paraíba utilizando dados de pluviômetros e as estimativas do TRMM (1998–2017).	121
Figura 22 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de comportamento de secas sobre o estado da Paraíba (1998–2017).....	126
Figura 23 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de duração das secas sobre o estado da Paraíba (1998–2017).131	
Figura 24 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de severidade de secas sobre o estado da Paraíba (1998–2017).	135
Figura 25 – Análise do percentual de área com tendência significante com base nas séries de comportamento, duração e severidade das secas para as mesorregiões da Paraíba (1998–2017).....	138
Figura 26 – Variação do coeficiente de correlação cofenética (c) para as séries de comportamento, duração e severidade em múltiplas escalas temporais sobre o estado da Paraíba (1998–2017). Os resultados de pluviômetros estão em azul e os TRMM em vermelho.	140
Figura 27 – Relação entre a distância de correlação entre <i>clusters</i> , critério de silhuetas e critério de Calinski-Harabasz com a quantidade de <i>clusters</i> para as séries de comportamento, duração e severidade das secas sobre o estado da Paraíba (1998–2017).....	143

Figura 28 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de comportamento das secas sobre o estado da Paraíba (1998–2017).....	147
Figura 29 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de duração das secas sobre o estado da Paraíba (1998–2017).	151
Figura 30 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de severidade das secas sobre o estado da Paraíba (1998–2017).....	156
Figura 31– Análise de risco da seca e avaliação do índice NIDS-Trend sobre o estado da Paraíba em múltiplas escalas temporais (1998–2017).....	162

LISTA DE TABELAS

Tabela 1 – Parâmetros de seca e suas relações lógicas com o índice NIDS-Trend.....	81
Tabela 2 – Variação do coeficiente de correlação de Pearson (R) e da raiz do erro médio quadrático normalizado ($NRMSE$) entre as séries dos pluviômetros e TRMM considerando as múltiplas categorias de eventos e escalas temporais.	123

1. INTRODUÇÃO

A seca é um fenômeno natural recorrente que ocorre em basicamente todos os regimes climáticos (Zhao *et al.*, 2018) e cujo impactos afetam diferentes setores da sociedade, tais como a geração da energia elétrica, a agricultura, os recursos hídricos, o turismo e os ecossistemas (Ionita *et al.*, 2016). Diante de sua complexidade, vários índices vêm sendo desenvolvidos para auxiliar o monitoramento desse fenômeno e dentre tais, o *Standardized Precipitation Index* (SPI) (McKee *et al.*, 1993) é considerado um dos mais difundidos no mundo. Isso está ligado ao fato de que o SPI é um índice padronizado que permite a avaliação das secas em diferentes escalas de tempo e categorias, além de viabilizar comparações entre resultados de diferentes regiões do por ser um índice normatizado (Caloiero *et al.*, 2018).

Além disso, o SPI só requer dados de precipitação para ser computado, o que facilita a sua aplicação frente a outros índices mais complexos e a identificação de características como início, duração, severidade, intensidade e frequência das secas (Botai *et al.*, 2017). É importante acrescentar que estudos têm utilizado o SPI como índice primário para monitorar as secas em diferentes regiões, permitindo a caracterização de seus eventos sob diferentes aspectos (e.g., Tan *et al.*, 2015; Caloiero, 2017; Fu *et al.*, 2018). Além da caracterização a partir de grandezas como duração, severidade, intensidade e frequência, métodos de avaliação de tendências também têm atraído a atenção de vários estudiosos e contribuído no entendimento do padrão das secas, facilitando sua compreensão e de suas variações futuras.

No caso das secas, os testes não paramétricos de Mann-Kendall e de Sen são úteis para detectar a existência de tendências e a magnitude da tendência e ambos têm sido muito utilizados para identificar e caracterizar as suas tendências e características em várias escalas de tempo (McGree *et al.*, 2016; Dashtpagerdi *et al.*, 2018; Khan *et al.*, 2018). Sob perspectiva alternativa, outros trabalhos também têm sido desenvolvidos no intuito de identificar regiões com comportamento similares em relação à ação e comportamento das secas. Assim, as técnicas de análises de *clusters* têm se mostrado um ferramenta eficaz na identificação dos fatores que influenciam a ocorrência de secas em diferentes regiões, contribuindo para a compreensão das secas de maneira multidisciplinar (Li *et al.*, 2015; Shiau e Lin, 2016; Yang *et al.*, 2017).

No entanto, para analisar as secas em detalhe, são necessárias redes de dados robustas e espacializadas, capazes de captar o regime pluviométrico da região. No Brasil, essa tarefa é desafiadora devido à extensão territorial do país, às diversidades climáticas e físicas existentes

e à existência de uma rede pluviométrica com diversas falhas em sua composição (Pereira *et al.*, 2013; Curtarelli *et al.*, 2014; Rao *et al.*, 2015). Frente a esse desafio, o uso de satélites de sensoriamento remoto surge como alternativa viável para monitorar o regime das chuvas sobre as regiões mais remotas e complexas do mundo. Dentre eles, o *Tropical Rainfall Measuring Mission* (TRMM) tem se notabilizado por gerar estimativas ininterruptas de precipitação a partir de diferentes produtos e resoluções espaço-temporais sobre as regiões tropicais do planeta Terra (Kummerow *et al.*, 1998).

Nesse sentido, alguns pesquisadores têm avaliado a acurácia dos produtos do TRMM para captar o padrão das secas em diferentes regiões (Sahoo *et al.*, 2015; Jesús *et al.*, 2016; Jiang *et al.*, 2017) e outros já utilizam esses dados para caracterizar as secas e suas tendências (Santos *et al.*, 2017; Santos *et al.*, 2019b), e padrões de similaridade entre as regiões (Santos *et al.*, 2019a), encontrando resultados satisfatórios na maioria dos casos. Dentre as zonas mais estudadas dos últimos tempos, destaca-se especialmente o Nordeste do Brasil (NEB), região classificada como uma das áreas mais vulneráveis do mundo à ação de mudanças climáticas, onde as secas são difundidas e recorrentes (Cunha *et al.*, 2018). Há pouco tempo, a seca que se iniciou em 2011, intensificou-se em 2012 e perdurou até 2017 foi um dos episódios mais severo das últimas décadas, atingindo quase 9 milhões de pessoas (Brito *et al.*, 2018).

Na Paraíba, estado localizado nessa região, as secas também são muito frequentes e os efeitos têm acarretado grandes perdas agrícolas e socioeconômicas ao longo dos últimos tempos (Brasil Neto *et al.*, 2017; Santos *et al.*, 2019b). De todo modo, destaca-se que ainda há carência de estudos mais detalhados sobre essa região, capazes de avaliar as secas e suas características e avaliar a eficácia do satélite TRMM em monitorar esse fenômeno. Além disso, não se tem conhecimento de outros trabalhos que tenham empregado técnicas de análises das tendências, análises de agrupamento ou formulado um índice de risco quanto à ação das secas, nem se quer comparado os resultados de pluviômetros e das estimativas do TRMM envolvendo tais técnicas sobre a região. Diante do exposto, realça-se o teor inédito deste trabalho e sua importância para o manejo dos recursos hídricos dessa e outras regiões.

2. OBJETIVOS

O objetivo geral deste trabalho é avaliar o comportamento espaço-temporal das secas de curto, médio e longo prazo e de suas principais características sobre o estado da Paraíba, Brasil, com base no índice SPI, utilizando dados de postos pluviométricos e estimativas de

precipitação do satélite TRMM ao longo de recentes 20 anos (1998–2017). Quanto aos objetivos específicos deste trabalho, destacam-se:

- (a) avaliar, com base em 11 diferentes métricas, a acurácia estatística do satélite TRMM em captar o comportamento espaço-temporal das secas sobre o estado da Paraíba;
- (b) caracterizar, de modo espaço-temporal, os eventos de seca que afetaram o estado da Paraíba quanto à quantidade de eventos, duração, severidade, intensidade média, frequência de eventos secos e porção de área atingida ao longo dos recentes 20 anos;
- (c) identificar a existência de tendências e a magnitude da tendência das séries de comportamento, duração e severidade das secas, utilizando os testes não-paramétricos de Mann-Kendall e Sen;
- (d) regionalizar o estado da Paraíba em diferentes zonas estatisticamente homogêneas quanto ao comportamento, duração e severidade das secas, utilizando análise de *clusters* hierárquica; e
- (e) desenvolver um índice inovador de análise de risco geoespacial das secas.

3. FUNDAMENTAÇÃO TEÓRICA

3.1. PRECIPITAÇÃO

Atualmente, a escassez de água é considerada uma grande ameaça em diversas regiões do mundo e por tal motivo, a busca contínua por melhorias no entendimento, controle e manejo dos recursos hídricos tem sido parte crucial para o desenvolvimento socioeconômico de várias regiões. Nesse contexto, pelo fato de a precipitação ser considerada a principal fonte de entrada do ciclo hidrológico (Kidd e Huffman, 2011; Schneider *et al.*, 2016; Muhammad *et al.*, 2018) e a variável meteorológica de maior importância para produção agrícola e para caracterização do clima regional (Teodoro *et al.*, 2016), a compreensão de sua variabilidade espaço-temporal é de suma importância para o desenvolvimento dos recursos hídricos em qualquer área da Terra.

Segundo Tucci (2001), a precipitação é definida como toda água proveniente do meio atmosférico que atinge a superfície do planeta, variando em forma de granizo, neve, neblina ou chuva, sendo esta última a mais comum em regiões tropicais e a forma exclusivamente avaliada neste trabalho. Nesse sentido, o entendimento do comportamento espaço-temporal

das chuvas passa a ser uma tarefa crucial para o planejamento e operação de diversos setores da sociedade, como o abastecimento de água, a agricultura, o controle e a proteção contra as inundações e a drenagem urbana, além de servir como auxílio em projetos de análises de vazões, para o balanço hídrico das bacias hidrográficas e para a identificação de áreas susceptíveis a desastres naturais causados por secas, cheias e mudanças climáticas (Lyra *et al.*, 2014).

No entanto, é importante destacar que a precipitação apresenta alta variabilidade espaço-temporal, principalmente nas regiões áridas e semiáridas do planeta (Farhangi *et al.*, 2016), o que torna o seu monitoramento desafiador. Usualmente, as medições de chuva feitas por postos pluviométricos são as mais importantes e diretas formas de obtenção de dados de precipitação (Cao *et al.*, 2018) e a partir desses dados, diversos estudos relacionados ao monitoramento das secas, ao processo de modelagem hidrológica ou a análise de tendências futuras, por exemplo, têm sido desenvolvidos com intuito de entender o comportamento da natureza e da precipitação sob diferentes temáticas. Entretanto, é válido pontuar que realizar o monitoramento das chuvas a partir de dados de postos pluviométricos é um processo que envolve algumas limitações.

No geral, as medições oriundas de postos pluviométricos têm caráter pontual, o que faz com que a caracterização espaço-temporal das chuvas em zonas extensas, remotas e de elevada complexidade topográfica não seja uma tarefa simples (Varikoden *et al.*, 2012; Wagner *et al.*, 2012). Aliado à complexidade das características físicas, destaca-se que aspectos relacionados aos custos de operação e manutenção das estações pluviométricas distribuídas sobre a superfície do planeta tornam o monitoramento das chuvas a partir desse método convencional uma tarefa bastante complexa (Terink *et al.*, 2018). De fato, é válido destacar que em um mundo ideal, haveria disponibilidade de dados de chuva em diferentes escalas espaço-temporais sobre todas as regiões e esses teriam dados teriam a maior qualidade, consistência e abrangência temporal possível (Alexander *et al.*, 2019).

Entretanto, sabe-se que a realidade é outra e vários estudos indicam que a rede de postos a nível global é espacialmente irregular e em algumas regiões insuficiente, fato esse que prejudica a caracterização do regime pluviométrico. Em seu estudo sobre análise de secas a nível global, Spinoni *et al.* (2014) apontaram que a distribuição de pluviômetros ao redor do mundo ao longo de recentes 60 anos (1951–2011) é muito irregular. Ao adotar a quantidade de estações que compõem o banco de dados do GPCC (*Global Precipitation Climatology Centre*) (Becker *et al.*, 2013) como referência numérica, o estudo mostra que a quantidade de

postos é consideravelmente menor nas regiões da África e da América do Sul, enquanto nas regiões da Europa e da América do Norte, a quantidade tende a ser mais expressiva.

Recentemente, Kidd *et al.* (2017) analisaram a porcentagem da superfície terrestre que era devidamente monitorada por pluviômetros e concluíram que a área de todos esses instrumentos existentes no planeta é inferior a metade de um campo de futebol, apesar de que a representatividade dos aparelhos seja maior. Além disso, os resultados apontam que mesmo que cada pluviômetro estivesse igualmente espaçado a uma distância de 5 km uns dos outros, apenas 1% do planeta seria monitorado por esses equipamentos, fato que realça a debilidade dessa instrumentação a nível mundial. Ao avaliar a situação do Brasil, é possível perceber que diversos fatores contribuem para que o monitoramento da chuva nesse país tenha alto grau de complexidade.

Apesar de a rede pluviométrica ser composta por quase 12.000 postos, é válido lembrar que o Brasil é um país de dimensões continentais e que tem densidade pluviométrica de cerca de um posto por 720 km² (Gadelha *et al.*, 2019), valor inferior à recomendação da *World Meteorological Organization* (WMO, 1994), em áreas planas e com pouca ondulação (575 km²). Além disso, alguns estudos ainda indicam que a distribuição espacial desses postos é irregular e que as séries de dados geralmente apresentam falhas em sua composição, sendo as regiões do Nordeste e do centro do Brasil as zonas que apresentam as redes com mais falhas do país (Pereira *et al.*, 2013; Curtarelli *et al.*, 2014; Soares *et al.*, 2016).

Em se tratando da diversidade das características físicas, destaca-se que no Brasil existem cinco diferentes regimes climáticos (Reboita *et al.*, 2010; Rao *et al.*, 2015) e cerca de 25 diferentes zonas pluviometricamente homogêneas espalhadas por todo o território (Keller Filho *et al.*, 2005), o que realça a necessidade de uma rede de monitoramento pluviométrico densa e de elevada confiabilidade, capaz de captar a variação espaço-temporal da precipitação sobre o país. Sendo assim, nota-se que apesar de se tratar de uma metodologia convencional, a utilização de dados de chuva a partir de pluviômetros para realização de certos estudos é limitada tanto pela inexistência quanto pela inconsistência das séries disponíveis (Kenabatho *et al.*, 2012; Mhanna e Bauwens, 2012; Ng *et al.*, 2018).

Diante dessa problemática, métodos alternativos para a obtenção de dados de chuva têm sido impulsionados ao longo dos anos e dentre eles, a utilização de produtos de sensoriamento remotos orbitais capazes de estimar a precipitação de modo sistemático sobre grandes domínios espaciais vem se notabilizando como uma fonte de dados alternativa para o

desenvolvimento de vários estudos na área dos recursos hídricos. Nesse contexto, destaca-se que essa busca pelo desenvolvimento de produtos capazes de estimar a precipitação de modo preciso tem atraído a atenção de diversos estudiosos, e isso contribuiu não só para o avanço das técnicas de obtenção de dados, como para o monitoramento dos recursos naturais em temáticas multidisciplinares.

3.2.O TRMM E OS SATÉLITES DE SENSORIAMENTO REMOTO

Segundo Moraes (2004), o sensoriamento remoto pode ser definido como o conjunto de atividades que possibilita a obtenção de informações de elementos que compõem a superfície terrestre, sem a necessidade de contato direto com esses elementos. No geral, essas atividades envolvem a detecção, a aquisição e análise da energia eletromagnética que é emitida ou refletida por esses elementos e o registro dessa energia pelos diferentes sensores remotos. Recentemente, a utilização das técnicas de sensoriamento remoto tem se destacado como forte alternativa para a realização de inventários, de mapeamentos e monitoramento de recursos naturais espalhados pelo mundo, bem como na captação do padrão espaço-temporal das chuvas.

De certo modo, é válido pontuar que apesar dos registros pluviométricos mais longos e usuais serem os de pluviômetros (Xie *et al.*, 2003), as estimativas de precipitação obtidas pelos radares e satélites de sensoriamento remoto se destacam como fontes de dados alternativas para caracterizar a precipitação a nível global com alta resolução espaço-temporal (Ren *et al.*, 2018). Todavia, Tang *et al.* (2015) afirmam que os dados de radares possuem incertezas associadas a terrenos complexos e relacionam esse fato ao bloqueio dos sinais desses equipamentos nesses ambientes. As observações de satélite, por sua vez, apresentam maior cobertura espacial sobre mares, regiões remotas e de elevada altitude, diante da capacidade das microondas dos sensores de interagirem com as partículas das nuvens, fato esse que é uma vantagem frente à utilização de radares (Ashouri *et al.*, 2015).

Alguns registros apontam que o *Television Infrared Observation Satellite*, o TIROS I, foi o primeiro satélite meteorológico lançado no mundo, fato esse que representou grande marco para o processo de previsões meteorológicas da época (NOAA, 2017). Desde lá, muitos avanços na área do sensoriamento remoto orbital foram feitos e hoje diversos produtos estão disponíveis para utilização, e.g., *Precipitation Estimation from Remote Sensing Information using Artificial Neural Network* (PERSIANN) (Sorooshian *et al.*, 2000), *Climate*

Prediction Center Morphing (CMORPH) (Joyce *et al.*, 2004), *TRMM Multisatellite Precipitation Analysis data* (TMPA) (Huffman *et al.*, 2007), *Global Satellite Mapping of Precipitation* (GSMP) (Kubota *et al.*, 2007), *Integrated Multi-satellitE Retrievals for GPM mission* (IMERG) (Hou *et al.*, 2014) e *Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS) (Funk *et al.*, 2015).

Vale a pena destacar que existem vários algoritmos e métodos de sensoriamento remoto disponíveis e que esses variam de produto para produto (Tao *et al.*, 2016). No geral, são essas variações que fazem com que haja diferença quanto à qualidade e a resolução espaço-temporal dos dados, trazendo à tona vantagens e desvantagens relativas à utilização de cada produto. De todo modo, é inegável que o advento dessa metodologia proporcionou vários avanços na área dos recursos hídricos, contribuindo para que sua utilização seja cada vez mais aceita no meio científico. Dentre as missões que foram desenvolvidas para monitorar a precipitação, uma das primeiras e mais importantes foi a do *Tropical Rainfall Measuring Mission* (TRMM) e desde então, vários avanços foram e vem sendo feitos utilizando seus dados como referência para diversos estudos.

O TRMM é uma missão conjunta entre a agência espacial americana NASA (*National Aeronautics and Space Administration*) e a agência espacial japonesa JAXA (*Japan Aerospace Exploration*), que foi desenvolvida com o objetivo de compreender de modo mais abrangente a variabilidade espaço-temporal da precipitação nas zonas tropicais do planeta Terra, área essa que concentra cerca de dois terços da precipitação mundial (Kummerow *et al.*, 1998). Lançado em novembro de 1997, o satélite TRMM orbitava com ângulo de inclinação de 35° e era capaz de completar sua órbita com cerca de 90 minutos, realizando em torno de 16 órbitas em um dia (Li *et al.*, 2019b). Apesar do satélite ter sido desenvolvido para durar apenas cerca de 3 anos, em agosto de 2001 sua altura orbital aumentou de 350 km para pouco mais de 400 km, o que fez com que ele só caísse em meados de 2015, após 18 anos de atividade (Curtarelli *et al.*, 2014).

Apesar de o satélite TRMM ter sido composto por cinco equipamentos distintos, sendo eles o *Precipitation Radar* (PR), o *TRMM Microwave Imager* (TMI), o *Visible and Infrared Scanner* (VIRS), o *Lightning Imaging Sensor* (LIS) e o *Clouds and the Earth's Radiant Energy System Instrument* (CERES), as estimativas de precipitação dessa missão se baseavam apenas nas medidas dos três primeiros componentes (Melo *et al.*, 2015). Os dois últimos, por sua vez, estavam relacionados a captação e a caracterização dos raios que atingiam a região tropical do planeta. De qualquer modo, cabe destacar que cada um dos elementos que

compunham o satélite tinha funções e características específicas, mas ao agirem de maneira integrada, possibilitavam a captação das estimativas de precipitação com refinada escala temporal sobre grandes áreas.

Especificamente, o VIRS era um radiômetro que tinha como função promover uma alta resolução nas observações das nuvens, captando informações relacionadas à área de sua cobertura, aos tipos das nuvens e as suas temperaturas. Já o TMI era um radiômetro que tinha capacidade de fornecer várias informações integradas sobre a altura total de precipitação, a nuvem líquida de água e de gelo, a intensidade da chuva e os tipos de eventos de chuvas que por ventura aconteciam (Cashion *et al.*, 2005). Por último, o radar PR se destaca dentre os demais componentes por ser considerado o primeiro radar de precipitação do mundo a ser lançado a bordo de um satélite, capaz de mensurar a precipitação de maneira tridimensional tanto sobre o oceano quanto sobre a terra (Kummerow *et al.*, 2000).

Desde o seu lançamento, a missão TRMM passou por vários avanços, o que garantiu o aumento na acurácia dos produtos de precipitação e fez com que as estimativas de precipitação desse satélite tenham sido consideradas as melhores dentre os produtos estimados por satélite de sua era (Jiang *et al.*, 2017). Dentre eles, o TMPA é o produto do satélite TRMM que combina as informações do PR e do TMI, ambos a bordo do satélite TRMM, com dados de microondas e sensores infravermelhos a bordo dos satélites *Defense Meteorological Satellite Program* (DMSP) (Spencer *et al.*, 1989), *US Earth Observing Satellite* (EOS) (Lobl *et al.*, 2007), NOAA e MetOP (Sanò *et al.*, 2015), além de incorporar informações dos 67.000 postos pluviométricos que compõem o banco de dados mundial do GPCC (Huffman *et al.*, 2007).

O último e mais completo produto de precipitação do TRMM é o TMPAv7. Essa versão passou por vários avanços até chegar em sua configuração final, e algumas dessas atualizações merecem destaque e já foram avaliadas por alguns estudiosos. Dentre esses, Sahoo *et al.* (2015) concluíram que em relação a sua versão anterior, o TMPAv6, o algoritmo de cálculo e o sistema de processamento do TMPAv7 passaram a incluir mais registros de micro-ondas e um conjunto de dados de satélites infravermelhos de outras plataformas. Além disso, mais campos de informações passaram a ser disponibilizados nos arquivos de dados, o esquema de calibração das bandas das latitudes passou a ser utilizado por diferentes satélites de maneira integrada e os dados de micro-ondas de entrada passaram a ser uniformemente reprocessado.

No geral, o TMPAv7 contém três produtos com diferentes resoluções temporais: o 3B42RT (3 horas), o 3B42 (diária) e o 3B43 (mensal) (Tan *et al.*, 2017). As informações de precipitação desses três produtos estão disponíveis de 1998 até os dias atuais e apresentam uma resolução espacial de $0.25^\circ \times 0.25^\circ$ (~ 27 km próximo ao Equador), cobrindo as diferentes regiões do planeta entre as latitudes 50°N e 50°S . Ao comparar a acurácia desses produtos, estudos revelam que o 3B42 e 3B43 apresentam precisão superior ao 3B42RT, tendo em vista que, enquanto os dois primeiros produtos são calibrados com base no banco de dados de precipitação do GPCC, os dados de precipitação estimados pelo 3B42RT, cujo propósito é realizar o monitoramento da precipitação em tempo real, dispensam os processos de calibração e correção utilizados nos outros dois produtos (Jesús *et al.*, 2016).

Apesar de o satélite TRMM ter caído em meados do ano de 2015, vale a pena notar que os produtos do TMPA serão produzidos continuamente até que seus possíveis sucessores, e.g., *Global Precipitation Measurement* (GPM), apresentem acurácia satisfatória para caracterizar o padrão espaço-temporal da precipitação em diferentes regiões (Huffman *et al.*, 2015). Além disso, é fato que a confiabilidade das estimativas de precipitação do TMPA deve ser avaliada e por isso, estudos de diferentes áreas dos recursos hídricos e meteorologia têm sido frequentemente desenvolvidos com o intuito de avaliar a qualidade das estimativas de precipitação do TRMM diante não só dos dados de postos pluviométricos, como também das estimativas de precipitação de outros produtos orbitais disponíveis.

Na maioria dos casos, estudos apontam que os dados estimados pelo satélite TRMM são capazes de captar o comportamento espaço-temporal da precipitação em regiões com diferentes características. Na China, por exemplo, esses estudos de caráter avaliativo têm sido amplamente desenvolvidos por esse ser um país de topografia complexa, extensão territorial significativa e grande diversidade climática, características que ao serem combinadas caracterizam um campo de teste robusto para avaliação das estimativas de precipitação dos satélites. Recentemente, Cao *et al.* (2018) avaliaram a acurácia do produto 3B43v7 sobre o Delta do Rio Yangtze, ao longo de 20 recentes anos (1998–2016) e concluíram que apesar do TMPA superestimar a chuva dos pluviômetros em alguns meses, esse produto foi considerado adequado para monitorar o padrão da precipitação sobre a área, com valores de coeficiente de correlação linear superiores a 0,79.

No caso, a maior contribuição desse estudo foi desenvolver uma análise que relaciona a acurácia do TMPA com fatores topográficos e com uso da terra da região. A partir dessa análise, os estudiosos concluíram que apesar dos resultados não indicarem relação entre a

topografia e a precisão do 3B43v7, houve uma relação de precisão mais expressiva entre as estimativas desse produto com as estações pluviométricas localizadas nas áreas urbanas, do que com postos que estão localizados em áreas de florestas ou com corpos hídricos. Chen *et al.* (2018), por sua vez, compararam as estimativas doIMERGv5 e do TMPA 3B42v7 na bacia do Rio Huaihe (2015–2017) e concluíram que também há boa acurácia na captação do regime pluviométrico espacial a nível mensal e anual sobre a região.

Todavia, os resultados não foram bons a nível diário e isso mostra a necessidade de avaliar os dados estimados antes de sua aplicação em estudos de outros tipos. Além disso, o estudo também mostra que os dois produtos variaram em acurácia em função da intensidade da precipitação e da topografia da região, e que, portanto, é necessário realizar uma avaliação mais detalhada a respeito dessas fontes de dados. Sobre a área de Pequim, Ren *et al.* (2018) avaliaram o desempenho das estimativas de quatro bases de dados diferentes, incluindo CMORPH, TMPA 3B42v7, 3B42v7 RT ao longo de 15 anos (2001–2015) em várias escalas de tempo. No geral, apesar de que todos os produtos tenham sido capazes de caracterizar o padrão das chuvas sobre a região, os resultados do 3B42v7 foram melhores a nível mensal e anual, mas os oriundos do 3B42v7 RT apresentaram o pior desempenho dentre os demais.

De modo análogo, Wei *et al.* (2018) avaliaram o desempenho das estimativas de quatro produtos diferentes, i.e.,IMERGv5,IMERGv4,CMORPH-CRT e TMPA 3B42v7 para captar o padrão das chuvas sobre toda a China (2014–2017). Utilizando mais de 500 pluviômetros como referência, os resultados mostraram que apesar da resolução espaço-temporal doIMERGv5 ser a mais refinada, não há vantagem notável em termos estatísticos sobre a precisão do TMPA, que foi o produto com desempenho mais expressivo a reproduzir a função de probabilidade de intensidade de precipitação diária sobre a China. De todo modo, os autores realçam que todos os produtos ainda precisam de melhorias, especialmente em regiões mais altas e de clima seco.

Recentemente, ao comparar as estimativas dos produtosIMERGv5 e do TRMM 3B42v7 sobre a planície de Huang-Huai-Hai, Xu *et al.* (2019) concluíram que existe um elevado nível de correlação linear com os dados observados e as estimativas dos satélites, especialmente para a precipitação a nível mensal e anual, bem como mostrado por Chen *et al.* (2018). Além disso, o estudo também mostra que apesar dos resultados doIMERGv5 terem acurácia superior ao do TMPA 3B42v7, as vantagens não foram proeminentes, corroborando com os resultados do estudo de Wei *et al.* (2018). Além de estudos desenvolvidos na China, vale ressaltar que essa temática também tem atraído a atenção de outros estudiosos de

diferentes partes do mundo. Na América do Sul, Satgé *et al.* (2019) avaliaram o desempenho de doze produtos orbitais em captar o regime das chuvas e sua aplicabilidade na modelagem hidrológica sobre a região do Lago Titicaca ao longo de 13 anos (2000–2012).

Os resultados indicam que o TMPA 3B42v7 teve desempenho superior ao do 3B42v7 RT, mas que no tocante ao monitoramento das chuvas, tal produto não apresentou acurácia significativa se comparado aos demais. Todavia, é válido pontuar que de maneira muito interessante, o 3B42v7 gerou os melhores resultados para a modelagem hidrológica de uma das bacias da região, fato que realça sua aplicabilidade sob outra temática dos recursos hídricos. Ao tratar mais especificamente do Brasil, um dos estudos pioneiros relacionados à avaliação do satélite TRMM foi desenvolvido por Franchito *et al.* (2009). Nesse estudo, as estimativas do TRMM 3A25 e do GPCPv2 foram avaliadas sobre todo Brasil utilizando diferentes escalas espaço-temporais por três anos (1998–2000).

Os resultados desse estudo mostram que as estimativas do TRMM tiveram correlação significativa com os dados dos postos pluviométricos de diferentes partes do Brasil e que além de ambos produtos terem sido capazes de reproduzir quantitativamente a precipitação sazonal sobre o Brasil, as estimativas de precipitação do TRMM foram mais confiáveis nas regiões com pior instrumentação, como Amazônia e Centro-Sul. Pereira *et al.* (2013), por sua vez, avaliaram as estimativas do TMPA 3B43v6 sobre o Brasil ao longo de 13 anos (1998–2010), período superior ao de Franchito *et al.* (2009). O estudo aponta que há concordância muito boa entre os dados do 3B43v6 e os de pluviômetros, tal que o coeficiente de correlação é superior a 0,95. Todavia, o 3B43v6 superestimou a precipitação mensal em 15%, tendo sido os piores resultados encontrados no Sudeste e os melhores no Norte.

Ainda utilizando o Brasil como área de estudo, Melo *et al.* (2015) compararam os efeitos da atualização do TMPA 3B42v6 para o 3B42v7 dentre o período de 1998–2011. Mais uma vez, foi possível concluir que ambos produtos captam o regime de chuvas das regiões do Brasil e que os resultados são melhores a nível mensal que a nível diário. Todavia, o estudo mostra que as estimativas de precipitação diárias não são recomendadas para as regiões Norte e Centro-Oeste, nem os dados mensais para região Norte e zona costeira do Nordeste. Para validar o uso dos sucessores do TMPA, Rozante *et al.* (2018) fizeram um estudo comparativo para avaliar as estimativas doIMERGv5 e do GSMAp-Gv7 (2014–2017). Apesar desse estudo ter comprovado que os dados doIMERG e do GSMAp são adequados para substituir os do TMPA, os resultados indicam que dentre as regiões do Brasil, a que cobre a costa do Nordeste foi a que apresentou os piores resultados, bem como mostrado Melo *et al.* (2015).

Um estudo interessante foi desenvolvido por Curtarelli *et al.* (2014) na região central do Brasil para avaliar os efeitos da mudança da altura orbital do satélite TRMM ocorrida em 2001. Quanto a acurácia do TMPA 3B43v7, os resultados indicam que houve superestimativa da precipitação, mas que ainda assim há boa concordância com os dados dos pluviômetros. Quanto aos efeitos da mudança da altura orbital, por sua vez, não foram encontradas muitas diferenças entre as estimativas antes e depois desse evento, à exceção dos meses cuja chuva foi maior que 250 mm. Já no norte do país, Almeida *et al.* (2015) avaliaram a acurácia estatística do 3B43v7 sobre o estado do Amazonas por cinco anos (2004–2008) e perceberam que as estimativas de precipitação do satélite TRMM são boa fonte de dados de chuva e representaram a variabilidade sazonal da precipitação da região.

Apesar dos resultados corroborarem com outras pesquisas desenvolvidas, destaca-se no estudo que as incertezas do 3B43v7 podem estar ligadas à diferença de escala entre os dados de precipitação, ao nível de pluviosidade e à variabilidade dos sistemas climáticos atuantes sobre algumas regiões. Utilizando um período mais abrangente, mas a mesma área de estudo, Michot *et al.* (2018) concluíram que as estimativas do 3B42v7 são mais precisas para detectar quando os eventos chuvosos ocorrem do que em mensurar quantitativamente a chuva, e que não há uma correlação significativa entre a altitude e os parâmetros estatísticos empregados. De todo modo, assim como Almeida *et al.* (2015), conclui-se que os dados do 3B42v7 representam um banco de dados consistente para caracterização da precipitação sobre a região Norte do Brasil.

Na região Sul do Brasil, Fensterseifer *et al.* (2016) avaliaram a acurácia dos produtos TMPA 3B42v6 e 3B42v7 ao longo de 13 anos (1998–2012) e concluíram que ambos produtos são consistentes em caracterizar a precipitação da região, com coeficientes de correlação linear variando entre 0,80 e 0,90 a nível mensal. Nota-se que nesse trabalho, o 3B42v7 teve acurácia consideravelmente superior à sua versão anterior, especialmente em se tratando da reprodução dos padrões de seca da região. No Sudeste, por sua vez, Lelis *et al.* (2018) compararam os dados estimados peloIMERGv3 e TRMM 3B43v7 sobre o leste São Paulo ao longo de um ano. Em geral, os resultados mostraram que os dois produtos são capazes de reproduzir o padrão espaço-temporal da precipitação, com diferenças que variaram entre -20% e 20% em relação aos dados observados.

No Nordeste do país, Cruz *et al.* (2018) avaliaram a aplicabilidade do produto 3B42v7 para a modelagem hidrológica da bacia do Rio Japaratuba utilizando diferentes escalas espaço-temporais. Os resultados mostram que as incertezas das estimativas diminuíram com o

aumento da escala temporal e que em relação a aplicabilidade do produto TMPA 3B42v7 para o processo de modelagem hidrológica, já para cenários de decêndios e a nível mensal, a utilização dessas estimativas se mostrou estaticamente adequada para modelagem hidrológica da bacia, tal como foi encontrado por Satgé *et al.* (2019). Na Paraíba de modo específico, dois estudos tem maior relevância no tocante à avaliação das estimativas do TRMM. No primeiro, Barbosa *et al.* (2015) compararam os dados do TMPA 3B42v7 com os de dois pluviômetros automáticos localizados sobre a bacia do Guaraíra, ao longo de oito anos.

Os resultados indicam que os dados a nível anual não tiveram rendimento satisfatório, já que a subestimativa anual média foi de 30%. Quanto à escala mensal, percebeu-se que apesar de haver boa concordância entre as bases de dados de outubro a fevereiro, houve forte tendência de subestimativa na região, especialmente no período mais chuvoso. De modo mais abrangente, Soares *et al.* (2016) avaliaram as estimativas do TMPA 3B42v7 em diferentes escalas espaço-temporais sobre todo o estado (1998–2014) e concluíram que esses dados reproduzem com uma certa eficácia o regime das chuvas sobre a região. Nas áreas mais chuvosas, os dados do TRMM foram subestimados e apresentaram menor acurácia, enquanto que nas zonas menos chuvosas a precipitação foi superestimada, mas mais precisa.

Diante do exposto, percebe-se que as estimativas de precipitação do TRMM podem ser consideradas como uma fonte de dados alternativa e validada em diferentes partes do mundo, com acurácia estatística satisfatória na maioria dos casos. Assim, sob a ótica do gerenciamento dos recursos hídricos, essas estimativas de precipitação com resolução espaço-temporal mais refinadas constituem informações relevantes para liberar ações de mitigação das secas e demais fenômenos danosos à população (Cunha *et al.*, 2018). Nesse contexto, é possível perceber que o advento das técnicas de sensoriamento remoto tem preenchido lacunas de várias pesquisas e tem ampliado o leque de aplicações na área da engenharia de recursos hídricos, especialmente no processo de análise de risco das secas, assunto de suma importância para o desenvolvimento socioeconômico da sociedade.

3.3. ANÁLISE DA SECA

A água está se tornando fisicamente, economicamente e socialmente escassa em várias regiões do planeta onde antes era abundante, e essa situação tem se tornado uma realidade cada vez mais evidente em diversas partes do mundo (Júnior *et al.*, 2016). Dentre alguns fatores que contribuem para tal cenário, as mudanças climáticas que atingem nosso planeta e que

aparecem como um dos grandes desafios ambientais dos últimos tempos vem impulsionando a ocorrência de fenômenos extremos cada vez mais severos e frequentes em inúmeras regiões (Caloiero *et al.*, 2018). Dentre esses fenômenos extremos, o estudo e análises das secas têm atraído a atenção de estudiosos espalhado pelo mundo que visam não só entender as características e o padrão de ocorrência desses fenômenos, como também buscar formas de minimizar ou até mesmo mitigar seus efeitos danosos à população.

Segundo o *National Drought Mitigation Center* da Universidade de Nebraska, Estados Unidos (NDMC, 2019), a seca no seu sentido mais geral é um fenômeno que se origina de uma deficiência de precipitação ao longo de um período de tempo, resultando em falta de água para algum setor de atividade, grupo ou meio ambiente. Assim, diante da importância da água para o desenvolvimento da civilização desde os primórdios, estima-se que a escassez desse recurso natural tão valioso, especialmente nos dias atuais, é responsável por causar diversos transtornos à população, o que faz com que as secas sejam categorizadas como um dos desastres da natureza mais severos a nível global e regional (Merino *et al.*, 2015), além de serem catalogadas como segundo maior desastre extensivo em termos geográficos do mundo (Thomas *et al.*, 2016).

De modo mais específico, as definições de seca podem ser de dois tipos: as conceituais e as operacionais (Wilhite e Glantz, 1985). A definição conceitual, por exemplo, é a que delinea o conceito básico de seca como uma descrição dos processos físicos envolvidos, como escassez da precipitação, deficiência quanto à umidade do solo ou à falta de água nos rios e reservatórios. As definições operacionais de seca, por sua vez, estão relacionadas às atividades que focam na identificação do início, da duração e do término dos diferentes episódios ocorridos, incluindo a avaliação de sua severidade também. O intuito destas definições operacionais é gerar uma série de informações relacionadas aos eventos de secas já ocorridos e permitir que seja dado suporte e avisos prévios sobre os eventos de secas que podem vir a acontecer (Mukherjee *et al.*, 2018).

Cabe destacar também que existe uma diferença entre o conceito escassez hídrica e o de secas de maneira propriamente dita (Van Loon e Van Lanen, 2013). Em geral, o que diferencia um termo do outro está relacionado ao controle que a humanidade tem quanto à ocorrência do fenômeno. O uso não sustentável dos recursos hídricos, por exemplo, mesmo que esse seja um recurso natural abundante, pode gerar a escassez hídrica em determinada região. As secas, por sua vez, são desastres que ocorrem naturalmente e cujos impactos só podem ser mitigados ou amenizados a partir de adaptações à variabilidade climática através

de medidas prévias. Nota-se, portanto, que o conceito de escassez hídrica está relacionado à carência e ação de medidas sustentáveis que tornam a água um bem escasso, enquanto as secas são desastres naturais que ocorrem de modo independente às atividades humanas e que afetam a população em diferentes níveis de severidade.

Por se tratar de um fenômeno recorrente, com vários graus de severidade e de elevada capacidade extensiva, as secas são capazes de causar danos consideráveis ao desenvolvimento de diversas atividades da sociedade, como na agricultura, na geração de energia hidrelétrica, no manejo dos recursos hídricos, na manutenção dos ecossistemas ou no desenvolvimento de áreas de turismo, por exemplo. Em regiões áridas e semiáridas, o entendimento das secas é não só preocupante como também desafiador e o motivo é que nessas áreas, o maior problema não necessariamente é o déficit de chuva, mas sim a alta variação da precipitação no tempo, no espaço, além de sua intensidade e duração (Farhangi *et al.*, 2016), o que torna essas regiões mais vulneráveis aos efeitos das secas.

Além disso, as secas se manifestam de diferentes formas e em diferentes intervalos de tempo, o que faz com que elas recebam diferentes classificações. As secas variam entre si de acordo com a duração e os setores sociais que são afetados por seus efeitos. Uma das mais usuais classificações foi proposta por Wilhite e Glantz (1985), que elencaram quatro tipos de secas: as meteorológicas, as agrícolas, as hidrológicas e as socioeconômicas. Mishra e Singh (2010) sugeriram a introdução das secas subterrâneas, que são caracterizadas pelo rebaixamento do nível de água subterrânea, e Van Dijk *et al.* (2013), por sua vez, também avaliaram os efeitos das chamadas secas ecológicas, que resultam no estresse de diferentes ecossistemas terrestre e aquático a partir da deficiência da umidade e da escassez hídrica em termos biológicos (Kiem *et al.*, 2016).

Entretanto, a maior parte dos autores corrobora com a classificação proposta por Wilhite e Glantz (1985) e categorizam as secas em quatro tipos distintos (Liu *et al.*, 2016). Inicialmente, as secas meteorológicas são aquelas que são originadas e caracterizadas pela precipitação abaixo do normal ao longo de um período de tempo que, no geral, varia de um a três meses, combinado ao aumento da evapotranspiração potencial e provocando déficit no balanço hídrico da região. Em função da elevada variabilidade da precipitação e do curto intervalo de tempo utilizado para caracterizar esse tipo de seca, cabe destacar que a definição de secas meteorológicas é mais específica para cada região. A análise dessa especificidade é muito importante porque o déficit de chuva ao longo de certo período pode ser considerado

um evento seco para uma região, enquanto que para outra não, o que exige conhecimento detalhado a respeito do padrão das secas em diferentes zonas.

Em continuidade, caso o cenário de falta de chuva e de aumento da evapotranspiração potencial persista por um período prolongado, os impactos podem resultar na insuficiência hídrica do solo e do subsolo, atingindo o desenvolvimento das culturas e caracterizando as secas agrícolas. Nesse caso, as secas agrícolas são originadas quando a umidade do solo disponível é inferior à umidade mínima requerida pelas plantas para o seu crescimento e o entendimento do padrão espaço-temporal desse tipo de secas é de extrema importância para o desenvolvimento de vários estudos da área de recursos hídricos, principalmente os mais ligados à identificação das relações entre chuva e vegetação e ao gerenciamento dos recursos hídricos em relação ao plantio das culturas desenvolvidas em diferentes partes do mundo.

Já o terceiro tipo de secas acontece quando o período de déficit do balanço hídrico sobre determinada região se estende ainda mais. As secas hidrológicas, como são conhecidas, estão intimamente relacionadas à redução dos níveis de água em reservatórios superficiais e dos rios por determinado período, que varia de dias, semanas, meses ou até anos seguidos. A relevância desse fenômeno está relacionada à importância do abastecimento hídrico e ao desenvolvimento da agricultura irrigada, e por tal motivo, compreender como essa variação das secas influencia a vazão dos rios ou o nível dos reservatórios de acumulação é um artifício poderoso para tentar minimizar os efeitos danosos causados à população.

Além das secas meteorológicas, agrícolas e hidrológicas, destacam-se também as secas socioeconômicas, que são aquelas que passam a afetar direta ou indiretamente as atividades dos seres humanos em termos socioeconômicos. De modo mais preciso, esse tipo associa a oferta e a demanda de algum bem econômico à população com os elementos dos demais tipos de secas, sejam elas as meteorológicas, agrícolas ou hidrológicas. Em outras palavras, as secas socioeconômicas ocorrem quando a demanda de um bem relacionado ao abastecimento da água é superior à disponibilidade hídrica da região e daí, por essa categoria estar ligada ao conceito de insuficiência dos recursos hídricos para atender às demandas da população, sua compreensão é de grande importância para amenizar os impactos socioeconômicos da região.

De todo modo, é interessante destacar que apesar desses conceitos serem diferentes, os tipos de secas são fenômenos de déficit hídrico causados pela falta de precipitação e que estão intimamente conectados entre si (Liu *et al.*, 2016). No caso, é possível perceber que quando a precipitação atinge níveis mais baixos, as secas meteorológicas aparecem primeiro e

em seguida os efeitos das secas agrícolas e hidrológicas. Por fim, as secas socioeconômicas acontecem quando quaisquer um dos outros tipos de secas chegam a certo grau de severidade. A conexão entre esses diferentes tipos de secas é perceptível quando se nota, por exemplo, que o déficit na precipitação origina as secas meteorológicas que afetam a agricultura e os recursos hídricos disponíveis, tal que todos esses elementos influenciam a demanda de algum bem socioeconômico da população.

Na prática, os eventos de seca têm múltiplas e inter-relacionadas características, como duração, severidade, intensidade, frequência e percentual de área extensiva ao longo do período de tempo. Cada uma dessas características tem grande importância para o manejo dos recursos hídricos e a compreensão integrada de todas elas constitui uma ferramenta poderosa no processo de gerenciamento de risco quanto à ação das secas. Quanto à duração, nota-se que secas mais duradouras tendem a afetar o potencial agrícola e a influenciar o nível dos rios e dos reservatórios de diferentes regiões e por isso, estima-se que entender o padrão espacial e temporal da duração das secas e de seus eventos é um processo importante para estimar quais setores da sociedade tendem a ser mais influenciados.

Por outro lado, avaliar a severidade das secas e sua variação espaço-temporal também é um passo crucial para mensurar danos causados à população. No geral, a severidade das secas é uma das principais características desses fenômenos (Dashtpagerdi *et al.*, 2015), e é a partir da qual que se mensura quão forte foi determinado evento de seca, quando comparado aos eventos passados. A partir do entendimento sobre essa característica, é possível elencar e classificar os eventos de secas mais severos que ocorreram de acordo com variáveis distintas, como prejuízos às culturas em termos financeiros ou número de pessoas atingidas, por exemplo. Classificar um evento de seca como extremo, severo, moderado ou suave auxilia a estimar os danos causados à sociedade como também ajuda a definir as ações que precisam ser tomadas para minimizar os efeitos das secas.

A característica que associa duração e severidade dos eventos de secas é a intensidade. No caso, a intensidade é a razão entre a duração e a severidade das secas e ela também tem sua importância no contexto de caracterização das secas. É de se esperar que um evento de seca que tenha grande duração e baixa severidade tenha consequências diferentes de eventos de secas com duração curta e grande severidade. Nesse contexto, entender o quão intensas são as secas contribui para determinar a velocidade que algumas medidas devem ser tomadas para que seus efeitos não sejam tão danosos. No geral, espera-se que as secas mais intensas, i.e.,

aquelas com elevada severidade e curta duração, tendem a atingir de modo mais rápido e danoso os diferentes setores da sociedade do que secas menos intensas.

A frequência dos eventos de seca, por sua vez, representa a quantidade de eventos secos que atingiram determinada região ao longo de determinado período. Essa característica tem alto valor no processo de caracterização das secas, especialmente por estar relacionada ao período de recorrência. Em outras palavras, nas regiões onde os eventos de seca são mais frequentes, o período de retorno dos eventos é menor, o que indica que esses fenômenos são mais recorrentes sobre determinada região. Desse modo, o monitoramento espaço-temporal dessa característica é essencial para o processo de gerenciamento de risco das secas, pois é de se esperar que regiões onde as secas são mais frequentes tendem a requerer maior cuidado quanto ao manejo de seus recursos do que regiões onde as secas não são tão frequentes.

Por fim, avaliar o potencial extensivo das secas em termos de área atingida contribui para a caracterização dos eventos mais significantes. Diante dessa caracterização, é possível não só identificar quais foram as regiões afetadas como também estimar qual foi a extensão geográfica de determinado evento de seca, relacionando seus efeitos com as variações das teleconexões climáticas ou com as características físicas da região, por exemplo. Identificar a existência de regiões homogêneas vulneráveis aos eventos de secas e conseguir quantificar essa estimativa em termos percentuais, portanto, contribui para o entendimento da dinâmica das secas e para o gerenciamento de risco desses fenômenos de alto potencial extensivo.

Diante da complexidade em monitorar e caracterizar os tipos e os eventos de secas que atingem a população, estudiosos criaram índices estatísticos para compreender a dinâmica e os efeitos desses fenômenos extremos. Os índices de seca, como são chamados, nada mais são do que valores numéricos que são estimados a partir de diferentes variáveis climatológicas, como precipitação, temperatura ou evapotranspiração, pelos quais é possível identificar os diferentes parâmetros das secas, como duração, severidade, intensidade, frequência e extensão territorial (Mishra e Singh, 2010). A partir desses índices, os efeitos das secas passaram ser caracterizados conforme suas diferentes classificações e em múltiplas escalas temporais, o que representou um avanço importante para o entendimento desses desastres naturais.

Motivados pela necessidade de identificar e caracterizar as secas, vários estudiosos espalhados pelo mundo vêm desenvolvendo índices que acoplam cada vez mais informações e garantem a caracterização mais completa desses fenômenos. Hoje, há na literatura uma grande quantidade de índices de seca disponíveis e cada um apresenta pontos fortes e fracos frente

aos outros. Diante dessa diversidade, é válido ressaltar que a escolha do índice de seca mais apropriado é um processo de grande importância para monitorar as secas e seus efeitos sobre determinada área (Adnan *et al.*, 2017) e essa decisão complexa está ligada a vários aspectos, tais como o propósito do estudo e a disponibilidade de dados climatológicos para computar o índice sobre determinada região, por exemplo (Morid *et al.*, 2006).

Historicamente, um dos primeiros métodos desenvolvidos para identificar a ocorrência das secas foi proposto por Henry (1906). No geral, os fenômenos eram identificados quando a precipitação acumulada ao longo de 21 dias ou período superior era igual ou menor do que 30% da precipitação média do período. Além disso, períodos com 15 dias consecutivos sem chuvas, precipitação anual acumulada inferior a 75% da média, precipitação acumulada mensal inferior a 60% da média eram critérios empregados para identificar esses fenômenos (Heim, 2002). Entretanto, nota-se que essas formulações tinham aplicação específica para certas regiões e se baseavam apenas no déficit da precipitação acumulada, o que era uma deficiência para monitorar os diferentes tipos de secas sobre diferentes regiões.

Com o avanço da tecnologia e o maior entendimento a respeito das secas, Palmer (1965) propôs um dos índices mais conhecidos da literatura, o *Palmer Drought Severity Index* (PDSI). Esse índice considera a precipitação, a temperatura e a umidade do solo e mensura condições de umidade e seca com base no conceito de oferta e demanda do balanço hídrico, sendo um dos índices meteorológicos mais utilizados para monitorar as secas sobre os Estados Unidos. Pouco depois, Palmer (1968) desenvolveu um dos primeiros índices a serem utilizados especialmente para monitorar as secas agrícolas, o *Crop Moisture Index* (CMI). Esse índice foi desenvolvido com o intuito de analisar as condições de seca das culturas com base em um modelo de balanço hídrico e foi utilizado pelo Departamento de Agricultura dos Estados Unidos, sendo um índice efetivo para monitorar essas secas principalmente na fase de crescimento das plantas.

Em seguida, Ped (1975) propôs o *Standardized Precipitation Temperature Index* (SPTI), índice que se baseia nas relações de anomalia da precipitação e da temperatura, cujos valores variam em classificações categóricas distintas. Já o *China Z Index* (CZI), proposto por Kendall e Stuart (1977), foi um dos índices mais utilizados para monitorar o comportamento das secas sobre a China. Esse índice só se baseia em dados de precipitação e é computado utilizando parâmetros estatísticos como média, desvio-padrão e o coeficiente de assimetria. Na Austrália, o *Decile Index* (DI) (Coughlan, 1987) foi o índice mais usual para monitorar o fenômeno sobre o país. O método empregado pelo DI se baseia na reordenação dos dados de

precipitação e na análise de frequência de distribuição cumulativa dos eventos, técnica que viabilizou, dentre outras coisas, a comparação entre a severidade das secas, realçando sua contribuição ao tema.

Diante dos avanços na área do sensoriamento remoto no final do século XX, diferentes índices foram propostos para monitorar as secas sob as mais diferentes temáticas. Dentre essas temáticas, notabiliza-se o avanço no monitoramento das secas agrícolas a partir da criação do *Vegetation Condition Index* (VCI) (Kogan, 1995), *Normalized Difference Water Index* (NDWI) (Gao, 1996) e *Vegetation Supply Water Index* (VSWI) (Haboudane *et al.*, 2004), por exemplo. O VCI normalizou o índice de vegetação, capacitando o monitoramento efetivo da variação espaço-temporal das secas ao redor do mundo. O NDWI detecta a água contida nas culturas e tem rápida resposta aos estresses da vegetação a partir de técnicas de sensoriamento remoto. O VSWI, por fim, integra informações da temperatura de cobertura do solo e do índice de vegetação, o que o torna eficaz no monitoramento das secas agrícolas.

Ao decorrer do tempo, os índices de secas passaram a combinar diferentes variáveis climatológicas no intuito de realizar a caracterização mais completa sobre esses fenômenos. Na Europa, o *Reconnaissance Drought Index* (RDI) (Tsakiris *et al.*, 2007) foi um dos índices mais utilizados para monitorar as secas e sua metodologia consiste em mensurar as condições de umidade das regiões com base na relação entre precipitação e evapotranspiração potencial, variável útil para identificação desse fenômeno. Do mesmo modo, Shukla e Wood (2008) desenvolveram o *Standardized Runoff Index* (SRI), que incorporou os processos hidrológicos à análise das secas e pelo qual é possível determinar as flutuações do fluxo de água diante da influência climática de cada região, revelando sua aplicabilidade para o monitoramento das secas hidrológicas.

De modo análogo, Vicente-Serrano *et al.* (2010) deram uma significativa contribuição ao processo de análise das secas ao formular o *Standardized Precipitation Evapotranspiration Index* (SPEI). Esse índice integra as informações de precipitação e de evapotranspiração sobre determinada região e considera uma condição de igual sensibilidade entre essas variáveis, o que torna o SPEI um índice adequado para captar os efeitos combinados da precipitação e da evapotranspiração. Com base em métodos de distribuição de probabilidade multivariadas, Kao e Govindaraju (2010) e Hao e AghaKouchak (2013), propuseram o *Joint Drought Index* (JDI) e o *Multivariate Standardized Drought Index* (MSDI), respectivamente. Utilizando o *copula-base model*, o JDI integra probabilidade conjunta entre a precipitação e a vazão,

enquanto o MSDI integra a probabilidade conjunta entre precipitação e a umidade do solo, dando robustez a esses índices.

Nota-se que diversos avanços foram feitos em relação ao desenvolvimento dos índices de seca e a previsão é de que estudos desse tipo continuem a ser feitos ao longo do tempo para que os efeitos das secas sejam cada vez mais compreensíveis e menos danosos. É válido relembrar que cada índice apresenta vantagens e desvantagens e é por isso que a escolha do índice adequado tem papel relevante na análise e gerenciamento de risco das secas. Dentre esses índices, um que teve uma das contribuições mais expressivas no tocante à análise desses fenômenos foi o *Standardized Precipitation Index* (SPI) (McKee *et al.*, 1993), e que apesar de antigo, ainda hoje é considerado uma das ferramentas mais uteis e adequadas para monitorar as condições de seca a nível global e regional (Botai *et al.*, 2017).

3.4. STANDARDIZED PRECIPITATION INDEX (SPI)

Apesar de existir uma notória dificuldade em estabelecer um índice universal que seja adequado para avaliar as secas, seus efeitos e suas características em diferentes regiões, pode-se dizer que o SPI é um forte candidato a desempenhar essa função e por isso tem sido um dos índices de seca mais utilizados no mundo ao longo do tempo (Heim, 2002). Desenvolvido por McKee *et al.* (1993) para avaliar esses desastres naturais no Colorado, Estados Unidos, o SPI é um índice estatístico padronizado que mensura, com base nos dados de chuva, a condição de severidade dos eventos secos e úmidos de uma região em múltiplas escalas temporais, o que viabiliza a análise do impacto das secas quanto aos recursos hídricos em diferentes níveis, i.e., desde a escassez da precipitação até os seus efeitos nas práticas agrícolas e na variação do nível dos reservatórios superficiais e dos rios.

O cálculo do SPI se baseia no ajuste de uma longa série de dados de precipitação de determinada região a uma distribuição probabilística padrão, que em seguida é reajustada a uma distribuição $N(0,1)$ (Edwards e McKee, 1997). Diante dessa metodologia, destaca-se que vários fatores contribuíram para que o SPI ganhasse popularidade entre os pesquisadores espalhados pelo mundo e fizeram com que esse índice fosse um dos indicadores mais usuais para monitorar as condições de seca a nível mundial, conforme recomendação da WMO (WMO, 2012). Dentre esses fatores, um que contribuiu para sua ampla utilização a nível global está relacionado aos dados de entrada requeridos para computar e utilizar o índice.

O SPI só se baseia em dados de precipitação para monitorar as condições de seca e de umidade e essa característica pode ser vista ora como um ponto forte ora como ponto fraco. No geral, é preciso admitir que fatores como temperatura do ar, velocidade do vento, umidade do solo e evapotranspiração potencial influenciam as condições de seca de uma região e, por não integrar essas informações, alguns autores expõem que o SPI tem limitações ao monitorar esses fenômenos (e.g., Vicent-Serrano *et al.*, 2010; Guo *et al.*, 2018a; Guo *et al.*, 2018b). Todavia, é válido destacar que o leque de aplicabilidade do SPI é muito superior ao de outros índices que precisam de diversas séries dados para serem computados, como SPEI e PDSI, por exemplo. Em regiões mal instrumentadas, remotas e complexas, obter uma série de dados de precipitação confiável é mais acessível do que obter séries de dados de outras variáveis meteorológicas (Jesús *et al.*, 2016).

Percebe-se que a disponibilidade de dados surge como agente limitante da aplicação de outros índices de seca em diversas regiões do planeta e esse, como dito, é um dos fatores que fez com que o SPI tenha se notabilizado dentre os demais. Por outro lado, cabe ressaltar que a metodologia empregada no cálculo do índice SPI pode ser considerada robusta, apesar de seu cálculo ser considerado relativamente simples. Sem dúvidas, a adequação dos dados de precipitação a uma distribuição probabilística e padronização desses valores são processos que tornaram a utilização do índice SPI expressiva frente a outros índices, pois a partir desse artifício, é possível integrar a robustez do método à simplicidade de cálculo do SPI.

A partir da adequação dos dados a distribuição probabilística, os eventos chuvosos são ajustados conforme sua probabilidade de ocorrência, o que faz com que a categorização dos eventos úmidos e secos seja uma definição estatística. Adiante, a padronização desses eventos utilizando uma relação de equiprobabilidade com a distribuição de Gauss $N(0,1)$ é uma etapa importante não só porque viabiliza a comparação do SPI entre diferentes regiões do planeta, ainda que essas tenham características diferentes, mas por também permitir a categorização dos eventos secos e úmidos em função dos padrões regionais. Essa informação auxilia tanto o entendimento do padrão espaço-temporal das secas quanto à emissão de alertas e definição de decisões diante dos eventos mais ou menos severos que atingiram certa região.

Todavia, autores apontam algumas limitações quanto ao ajuste da série de precipitação a uma distribuição probabilística (Mishra e Singh, 2010), especialmente em se tratando de erros e incertezas relativas à escolha da distribuição probabilística adequada, às influências do tamanho da série temporal disponível e ao comportamento de regiões onde a precipitação é nula na maior parte do ano. De todo modo, cabe destacar que essas limitações são muito

específicas e dificilmente inviabilizam a utilização do SPI no processo de monitoramento das secas e prova disso é que existem na literatura vários estudos a serem discutidos adiante que comprovam a eficácia desse índice em monitorar as secas utilizando diferentes distribuições, séries de dados de chuva curtas ou mesmo em regiões áridas e semiáridas onde os níveis pluviométricos são quase nulos em grande parte do ano.

Por outro lado, apesar da facilidade referente aos dados de entrada e ao processo de cálculo simples do SPI, um dos pontos mais fortes desse índice está relacionado à capacidade de avaliar a precipitação e as secas em múltiplas escalas temporais, garantindo análise dos seus efeitos em diferentes aspectos. Essa informação tem extrema relevância e representou um marco no processo de monitoramento das secas, já que a flexibilidade temporal do índice SPI permite a avaliação das secas em curto prazo, cujos efeitos estão ligados à disponibilidade hídrica do solo e às práticas agrícolas, como também as análises das secas de longo prazo, cujas consequências estão intimamente relacionadas às mudanças dos níveis dos rios, dos reservatórios e dos aquíferos, por exemplo (Awange *et al.*, 2016).

Sendo assim, pode-se dizer que apesar do SPI ser um índice que só se baseia em dados de precipitação, cujo enfoque está mais relacionado à análise das secas meteorológicas, sua aplicação com base em múltiplas escalas temporais também representa um bom indicador para avaliar os efeitos das secas agrícolas e hidrológicas. A análise multitemporal da chuva fornece informação multidisciplinar e completa quanto aos efeitos das secas nas diferentes regiões do mundo e nesse sentido, é válido pontuar que para cada escala temporal distinta, i.e., cada índice SPI, há uma interpretação específica das secas e de seus efeitos, enriquecendo os resultados que são disponibilizados mediante o emprego dessa ferramenta.

A análise multitemporal é feita do seguinte modo: para o cálculo do SPI-1 de abril de certo ano, a precipitação total de abril desse ano é comparada à precipitação de abril de todos os anos registrados, e em seguida, com base na probabilidade de ocorrência desses eventos, todos os acumulados de abril são classificados conforme sua raridade ao longo da série. A diferença entre o SPI-1 e o SPI-3 é que para o SPI-3 a precipitação acumulada é a dos três meses antecedentes, i.e., fevereiro, março e abril, e não só a de abril, como é o caso do SPI-1. De modo genérico, o índice SPI-X do mês Y compara a precipitação acumulada de X meses antecedentes ao mês Y de um determinado ano, incluindo o mês Y, com os acumulados dos mesmos períodos dos demais anos da série histórica.

Logo, diante das múltiplas escalas temporais que podem ser empregadas para avaliar a severidade dos eventos secos e úmidos, estudos indicam que as secas meteorológicas, por exemplo, podem ser monitoradas a partir dos índices SPI-1 a SPI-3, as secas agrícolas estão relacionadas aos resultados dos índices SPI-3 a SPI-6, e as secas hidrológicas, por fim, podem ser monitoradas a partir dos valores dos índices SPI-6 ao SPI-24 (Li *et al.*, 2013; Zhang e Jia, 2013; Byakatonda *et al.*, 2018). Todavia, é válido destacar que mesmo diante das vantagens de monitorar as secas com base no índice SPI, é notório que o seu desempenho em captar o regime desses fenômenos ainda deve ser avaliado para mensurar sua acurácia frente a outros índices de seca. Estudos de caráter comparativo têm sido feitos em diferentes regiões do mundo e, na maioria dos casos, os resultados indicam que o SPI ainda é um dos índices mais adequados para avaliar as secas em diferentes escalas temporais.

No Irã, Morid *et al.* (2006) avaliaram a desempenho de sete diferentes índices de seca ao longo de 32 anos (1970–2001). O estudo mostra que o SPI e o CZI tiveram desempenhos semelhantes e responderam lentamente ao início das secas, enquanto que o DI respondeu mais rapidamente a ocorrência desses fenômenos, mas foi inconsistente quanto à captação das suas características espaço-temporais. A conclusão final dos autores é de que o SPI é o índice mais recomendado para realizar o monitoramento operacional desses desastres na região. Além disso, nota-se que o SPI foi escolhido como índice primário de calibração dos demais, o que realça sua aceitação, aplicabilidade e robustez no meio científico. Recentemente, Mahmoudi *et al.* (2019) realizaram a mesma análise comparativa na região, mas avaliaram as secas em múltiplas escalas temporais, preenchendo uma das lacunas do estudo de Morid *et al.* (2006).

Mais uma vez, os resultados indicam que dentre os índices empregados, o SPI e CZI se notabilizaram quanto à consistência de seu comportamento ao decorrer do tempo, tal que o SPI apresentou um dos melhores desempenhos dentre os demais. Na Austrália, país que foi afetado por uma das maiores secas dos últimos tempos, Rahmat *et al.* (2015) analisaram o desempenho de caracterização das secas a partir do SPI, RDI e DI por mais de 50 anos (1955–2010). Apesar do DI ser um dos índices mais comuns na região, o estudo mostra que o RDI e o SPI são os índices mais expressivos por fornecerem uma classificação padronizada das secas. Além disso, o estudo ainda indica que o SPI teve bom desempenho ao caracterizar os efeitos das secas meteorológicas quando comparado aos resultados do índice RDI, mesmo ao ter em vista que o último considera a evapotranspiração potencial como parâmetro de cálculo.

Do mesmo modo, Timimi e Osamah (2016) realizaram um estudo comparativo sobre o Iraque com base em quatro índices, i.e., SPI, RDI, DI e RAI (*Rainfall Anomaly Index*). No

geral, os resultados indicam que há uma associação linear relevante entre os índices e que o SPI e o RDI são mais adequados para categorizar os eventos úmidos e secos sobre a região. Nesse contexto, destaque desse estudo é porque é possível perceber que mesmo em uma região onde a evapotranspiração potencial é elevada, o índice SPI apresentou concordância significativa para captar com precisão a ocorrência dos eventos úmidos e secos com índices que consideram mais variáveis.

Na África, Haied *et al.* (2017) monitoraram as secas utilizando três índices distintos, i.e., DI, SPI e RDI, sobre uma região semiárida. Os resultados apontam boa correlação linear entre os produtos do RDI e SPI, cujos valores de correlação de linear de Pearson superam 0,94, especialmente ao tratar das secas de curto prazo. Nessa região, o monitoramento a partir desses índices ajuda a identificar os efeitos das secas meteorológicas, agrícolas e hidrológicas, mas de modo geral o SPI e RDI foram os mais adequados para monitorar as secas sobre a região, assim como encontrado por Timimi e Osamah (2016). Um dos estudos mais completo dos anos recentes foi desenvolvido por Adnan *et al.* (2017), que avaliaram o desempenho de 15 diferentes índices sobre o Paquistão utilizando dados de mais de 60 postos pluviométricos.

Nesse estudo, assim como proposto por Morid *et al.* (2006), o SPI foi utilizado como índice primário para calibrar outros índices como CZI, SPEI, RDI e SPTI, fato que realça sua utilidade no cenário do monitoramento das secas mesmo depois da formulação de índices mais recentes. Apesar de todos os índices terem sido capazes de captar o episódio de seca mais longo da região, o estudo concluiu que o RDI, o SPEI e o SPI são os mais recomendados para avaliar as condições de seca. De todo modo, os autores estimulam o desenvolvimento de mais índices que integrem informações de chuva, temperatura e dados de sensoriamento remoto para melhorar a caracterização das secas sobre diferentes regiões. Na Índia, segundo país mais populoso do mundo, Wable *et al.* (2018) avaliaram o desempenho de cinco índices em múltiplas escalas temporais.

Os resultados apontaram que a escala de tempo mais precisa para monitorar as secas e comparar a eficácia dos índices é a que se baseia em um período de acumulação de nove meses. Ao utilizar critérios avaliativos de robustez, transparência e sofisticação, por exemplo, o estudo aponta que o SPEI é o mais adequado para avaliar as secas na região, mas afirma que os resultados do índice não foram tão discrepantes do encontrado no caso do SPI. Entretanto, os autores concluem que a evapotranspiração potencial é uma importante variável quanto ao monitoramento das secas e sugerem ainda o desenvolvimento de índices integrados capazes

de aumentar a compreensão do padrão das secas sobre as regiões, assim como Adnan *et al.* (2017).

Recentemente, Li *et al.* (2019a) monitoraram as secas no nordeste da China utilizando quatro índices (1960–2010). Ao avaliar o padrão das secas em múltiplas escalas temporais, foi possível perceber que em escalas temporais intermediárias, e.g., 7–18 meses, os índices de seca apresentaram melhor correlação e conformidade entre si, como discutido por Wable *et al.* (2018). O estudo concluiu que o SPI foi o mais confiável para monitorar as secas na região, especialmente o SPI-12. A sugestão final dos autores é que trabalhos que explorem a análise multitemporal das secas continuem sendo desenvolvidos ao longo do tempo para que o padrão de ocorrência das secas seja identificado com consistência e acurácia em diferentes regiões do planeta.

Na Paraíba de modo mais específico, Brasil Neto *et al.* (2018) avaliaram a influência da evapotranspiração potencial no padrão das secas em múltiplas escalas de tempo a partir do uso dos índices SPI e SPEI. Ao desenvolver o estudo em quatro regiões distintas, foi possível notar que os resultados obtidos a partir desses índices são similares entre si, independente da região. Além disso, para as secas de longo prazo os resultados são ainda mais similares, com coeficientes de determinação superiores a 0,95. No entanto, nas regiões onde a influência da temperatura é mais expressiva, os resultados das secas de curto prazo não indicaram tanta coerência entre o SPI e o SPEI. De todo modo, os autores ressaltam que o resultado pode estar ligado ao alto percentual de falhas nas séries de dados e pontuam que na maioria dos casos, os valores SPI e SPEI captaram o padrão das secas de modo bastante coerente.

Apesar da eficiência do SPI em monitorar as secas em várias escalas e regiões, é preciso ressaltar um aspecto relativo à sua utilização. No geral, nota-se que grande parte dos estudos feitos para avaliar a acurácia do SPI em captar o padrão espaço-temporal das secas se baseia em longos períodos de dados oriundos de postos pluviométricos. De certo modo, essa situação está relacionada ao fato de que quanto maior a série de dados, maior a chance de ter produtos que retratem fidedignamente a variação temporal das secas ao decorrer do tempo. Na etapa de adequação dos dados de precipitação à distribuição probabilística, é de se esperar que ao utilizar séries de dados maiores, os ajustes dos eventos chuvosos à função probabilística se darão de modo mais preciso e confiável do que ao serem utilizadas séries de dados curtas, já que quanto maior a quantidade de dados disponíveis, maior representatividade dos resultados.

Ao utilizar séries pluviométricas com poucos dados, é possível que variações pontuais no padrão da precipitação distorçam os resultados finais, especialmente em se tratando das análises de secas de curto prazo. Em outras palavras, o que pode ocorrer é que enquanto um evento de chuva pode ser considerado muito raro com base no comportamento de precipitação dos últimos cinco anos, em relação ao contexto histórico de 100 anos esse mesmo evento pode não ser tão raro assim e, por consequência, surge o questionamento a respeito da janela temporal que deve ser empregada. A recomendação usual é que sejam utilizadas séries com ao menos 30 anos de dados para desenvolver estudos relacionados ao monitoramento das secas (Guo *et al.*, 2016), mas dois pontos devem ser destacados diante dessa recomendação.

O primeiro ponto está relacionado à disponibilidade dos dados: é fato que grande parte do planeta carece de uma rede pluviométrica eficaz e por isso obter séries de dados confiáveis com 30 anos é inviável em diversas partes do globo. O outro ponto está relacionado ao fato de que ao analisar séries recentes, diminui-se a chance de que valores tendenciosos do passado sejam incorporados à série atual, pois quanto maiores forem as séries, maiores as chances de que os aspectos de tendência e de não estacionaridade passem a ser integrados ao valor do SPI. Ao utilizar uma série de dados com 100 anos, é preciso ter em mente que todos os eventos chuvosos ao longo desse período serão comparados entre si e por isso, é preciso não só avaliar o propósito do estudo como o quanto os eventos ocorridos há 100 anos passarão a influenciar os valores SPI dos acontecimentos mais recentes.

Diante desse impasse em relação ao tamanho mínimo das séries e à disponibilidade dos dados, as estimativas de precipitação dos satélites têm sido amplamente utilizadas no monitoramento das secas a nível regional e global ao longo dos últimos tempos. Apesar dessas séries terem, geralmente, menos de 30 anos, a disponibilidade dessas estimativas de precipitação com resolução espaço-temporal refinada e de modo sistemático sobre grandes domínios espaciais tem impulsionando o desenvolvimento de vários estudos que utilizam o SPI como índice primário de monitoramento das secas. Os resultados são muito relevantes e indicam que os satélites de sensoriamento remoto captam o padrão espaço-temporal das secas em diferentes regiões do planeta apesar das séries de dados serem consideradas curtas, como é o caso dos produtos do TRMM.

Um dos estudos mais relevantes para monitorar as secas, seus efeitos e suas incertezas utilizando dados de sensoriamento remoto foi desenvolvido por Naumann *et al.* (2012). Sobre a África, o estudo comparou os dados do TMPA 3B43 (1998–2010) com os do GPCC (1951–2009) e os resultados indicaram que para realizar um monitoramento confiável das secas na

região é mais viável utilizar as séries de dados mais curtas do TRMM do que as mais longas do GPCC, diante da resolução espacial mais fina. Além do mais, o estudo aponta que o uso dos dados TRMM é uma alternativa viável para monitorar tais fenômenos em tempo real na África e que a análise de incerteza desses produtos de satélite é importante para validar sua aplicação em várias regiões do planeta.

Em outro estudo, Li *et al.* (2013) analisaram a acurácia do TMPA 3B42 em captar a ocorrência dos eventos úmidos e secos sobre a bacia do Lago Poyang, na China, ao longo de 14 anos (1998–2010). No tocante ao monitoramento da precipitação, os resultados mostram que as estimativas diárias do TMPA não apresentam acurácia tão satisfatória em relação aos dados de pluviômetros, mas a nível mensal existe uma boa associação linear entre as fontes de dados. Ao utilizar múltiplas escalas temporais, e.g., SPI-3, SPI-6, SPI-9 e SPI-12, foi possível perceber que os dados estimados do TMPA tiveram consistência significativa em comparação aos dados *in situ*, e apesar de ressaltar algumas deficiências relativas ao tamanho da série de dados e ao *delay* para que os dados do 3B42 fossem disponibilizados, a conclusão final do estudo é que os dados estimados do TRMM são adequados para monitorar a variação espaço-temporal dos diferentes tipos de eventos úmidos e secos sobre a região.

Pouco depois, Sahoo *et al.* (2015) desenvolveram um dos trabalhos mais conceituados da literatura ao avaliar o desempenho dos produtos TMPA 3B42v6, 3B42v7 e 3B42v7 RT em captar o comportamento das secas meteorológicas a nível global (2000–2009). Os resultados apontam que as incoerências expressivas entre os produtos do TMPA e de outros satélites com os dados de pluviômetros foram encontradas nas regiões tropicais e nas zonas mais remotas do planeta, tendo o 3B42v7 apresentado melhor desempenho e o 3B42v7 RT, o pior. Ao avaliar a seca em múltiplas escalas temporais, o estudo indica que o tamanho das séries de dados teve um impacto muito pequeno em relação às estimativas dos valores SPI no contexto histórico, e a conclusão é de que os produtos do TMPA são hábeis o suficiente para detectar os eventos de secas e podem ser utilizados para monitorar as secas a nível regional e global.

No México, Jesús *et al.* (2016) monitoraram as secas meteorológicas em várias escalas de tempo com base no SPI, utilizando os dados estimados do TMPA 3B42 (1998–2013). Os resultados mostram que o 3B42 pode ser utilizado para monitorar apropriadamente as secas meteorológicas e captar os eventos secos sobre o país, mesmo a série tendo tamanho reduzido se comparado aos estudos convencionais. Dentre as escalas temporais, o estudo indica que o SPI-12 foi a mais adequada para identificar claramente os períodos úmidos e secos sobre a região, mas destacam que o maior percentual de área atingida foi encontrado mediante análise

do SPI-6. Por fim, os autores recomendam que sejam feitas assimilações entre os dados de pluviômetros e as estimativas de sensoriamento remoto a fim de prover dados mais robustos a respeito da severidade das secas sobre a região.

No intuito de avaliar a acurácia das estimativas do TMPA em captar o comportamento das secas a partir de diferentes métricas estatísticas, como coeficiente de correlação e a raiz do erro médio quadrático, Tao *et al.* (2016) desenvolveram o estudo sobre a província de Jiangsu, na China. Ao comparar as estimativas do TMPA 3B43v7 com os dados de 65 pluviômetros durante 17 anos (1998–2014), os resultados indicam que a acurácia do satélite decresce com o aumento da escala temporal, tal que as estimativas foram mais precisas para monitorar as secas em curto prazo, e.g., SPI-3 e SPI-6. Para as secas de longo prazo, foram encontradas limitações espaço-temporais associadas às circulações atmosféricas atuantes, à topografia e ao tamanho da série temporal, e por isso, a conclusão é de que pesquisas sejam desenvolvidas para validar a utilização dessas estimativas no processo de monitoramento das secas.

Jiang *et al.* (2017) analisaram a acurácia estatística do TMPA 3B42v7 em monitorar as secas sobre a bacia do Rio Weihe, na China, utilizando cinco escalas temporais distintas no período 1998–2013. Diferentemente dos resultados encontrados por Tao *et al.* (2016), o tamanho da série de dados do TMPA não representou problema ao computar os valores do índice SPI e a prova disso é que as estimativas do satélite captaram as características oriundas das séries longas, ao avaliar o padrão das secas no domínio do tempo e do espaço. Todavia, conforme proposto por Tao *et al.* (2016), os autores ressaltam a importância de integrar e usar os dados do IMERG aos do TMPA para monitorar as condições de seca sobre essa e outras regiões a partir de dados com resoluções espaço-temporais cada vez mais refinadas.

Na Malásia, Tan *et al.* (2017) avaliaram a acurácia das estimativas do TMPA 3B43v7 em captar as secas sobre a bacia do Rio Kelantan (1998–2014) com base no SPI-1, SPI-3, SPI-6 e SPI-12. Os resultados indicam que a acurácia do 3B43 varia em função da escala de tempo, tendendo essa a ser maior com menores escalas temporais, tal como discutido por Tao *et al.* (2016). O estudo destaca incertezas por parte dos dados estimados e as relacionam com as características físicas da região, ao tamanho da série temporal e a quantidade de estações utilizadas para calibrar as estimativas do TMPA, pois nas regiões menos instrumentadas a precisão do satélite cai. A conclusão é de que as estimativas do TMPA não foram adequadas para computar o SPI na região e por isso, é sugerido que estudos de caráter avaliativo sejam feitos para aumentar o entendimento desse produto quanto ao monitoramento das secas.

Recentemente, Zhong *et al.* (2019) avaliaram o desempenho de três estimativas de satélites de sensoriamento remoto (i.e., CHIRPS, PERSIANN-CDR, TMPA 3B42v7) para monitorar as secas na China. Quanto ao monitoramento dos fenômenos, não foi encontrada uma relação tão evidente entre o aumento da escala temporal e a acurácia das estimativas, pois em algumas regiões o aumento da escala refletia em um aumento da acurácia, enquanto que em outras a precisão das estimativas passava a decrescer. Além disso, é válido relembrar que apesar dos três produtos terem sido considerados inadequados para monitorar as secas na região oeste da China, o TMPA 3B42v7 teve resultados bastante satisfatórios sobre o país, mesmo contendo a menor série temporal dentre os produtos empregados na pesquisa.

Logo, monitorar as secas, seus efeitos e suas características a partir das estimativas dos produtos do TRMM vem se mostrando como alternativa bastante eficaz para caracterizar esses fenômenos em várias escalas temporais e sobre grandes domínios espaciais. Todavia, além de características como duração, severidade, intensidade, frequência e porção de área atingida, que são mais usualmente analisadas em estudos de caracterização das secas, métodos de análises de tendências também tem atraído a atenção de diversos estudiosos ao longo dos últimos anos. A partir desses métodos, é possível estimar as tendências e as magnitudes futuras das secas com base no seu comportamento ao longo da série histórica. Por essa ser uma informação de grande valor no tocante ao gerenciamento de risco das secas, estudos que envolvem essa análise vêm sendo desenvolvidos com cada vez mais frequência.

3.5. ANÁLISE DE TENDÊNCIAS

Avaliar tendências de séries temporais é um passo importante para o desenvolvimento de vários estudos hidrológicos, pois garante aos pesquisadores entendimento mais amplo sobre o comportamento futuro das variáveis analisadas. Nesse sentido, séries históricas de variáveis climatológicas, meteorológicas e hidrológicas têm sido avaliadas ao decorrer dos últimos tempos, dando maior segurança aos estudiosos no tocante às tomadas de decisão e manejo dos recursos hídricos. Em geral, a identificação da existência de tendências de uma série temporal é possível a partir da aplicação de técnicas paramétricas e não paramétricas, e a diferença básica entre tais métodos é que enquanto a primeira técnica requer que os dados se adequem a uma distribuição padrão e sejam independentes entre si, as não paramétricas não possuem tal exigência.

Por tal motivo, é notório que diante da flexibilidade de adequação aos dados naturais, estudos que envolvem a utilização dessas técnicas não paramétricas tem sido mais usuais no tocante a avaliação de tendências de séries temporais. Dentre as técnicas disponíveis, os testes de Mann-Kendall e de Sen são uns dos mais usuais (Byakatonda *et al.*, 2018; Santos *et al.*, 2018; Santos *et al.*, 2019b). A partir dessas técnicas não paramétricas, o padrão das séries temporais de diferentes origens e tipos são analisados, permitindo que os efeitos danosos dos fenômenos climáticos e extremos como as secas possam ser, na melhor das hipóteses, um pouco amenizados. O teste de Mann-Kendall foi primordialmente sugerido por Mann (1945) e modificado por Kendall (1975) e representa a etapa inicial quanto ao processo de avaliação de tendências das séries temporais, pois a partir de sua aplicação, determina-se a declividade da tendência e seu nível de significância.

Esse método se baseia no teste da hipótese nula H_0 , de que não existe tendência na série, contra a hipótese alternativa não nula H_1 , que há tendência crescente ou decrescente dos dados e assim, a depender dos resultados, a hipótese nula passa a ser rejeitada ou aceita. Além disso, destaca-se também que o teste não-paramétrico de Mann-Kendall avalia as tendências das séries temporais que podem conter falhas em sua composição, o que aumenta o leque de aplicabilidade dessa técnica, especialmente ao se utilizar séries de precipitação e de variáveis meteorológicas, que geralmente apresentam elevado percentual de falhas. Além do mais, o teste de Mann-Kendall não é sensível à existência de valores extremos e não há necessidade de que os dados utilizados se adequem a uma distribuição padrão, o que o torna um dos mais recomendado pela WMO para detectar a existência de significância estatística em estudos climatológicos (Mitchell *et al.*, 1966).

Além disso, considerando a quantidade de dados existentes nas séries temporais, pode-se estabelecer se a série apresenta ou não uma tendência relevante a um determinado nível de significância. Essa capacidade de analisar séries e suas tendências com diferentes níveis de significância garante maior propriedade aos estudiosos e embasam ainda mais as conclusões obtidas a partir da aplicação desse teste. Ao assumir que determinada série temporal tem uma tendência estatisticamente significante a um nível de significância de 0,01, que é o mesmo que admitir que há 99% de confiança, conclui-se que de fato há um alto percentual de rejeição da hipótese nula e espera-se que a série realmente apresente tal tendência. É de se destacar que esse elevado percentual de certeza é muito valioso em estudos específicos, principalmente os que estão relacionados a determinação de eventos extremos danosos como secas e cheias.

No entanto, por se tratar de um teste que leva em consideração a variabilidade espaço-temporal das características físicas do nosso planeta, existem algumas recomendações a fim de que as análises sejam confiáveis. A primeira premissa nesse caso está ligada ao tamanho das séries temporais, e a recomendação é de que essas tenham em torno de 30 anos de dados no intuito de que sinais de alterações climáticas sejam identificados. Por outro lado, é válido destacar que estudos que envolvem análises de tendências de séries cuja janela temporal é mais reduzida não são necessariamente inviáveis ou imprecisos. Nesse caso, a ressalva é que ao utilizar essas séries que tem o tamanho reduzido, mas que ainda assim tem significativa confiabilidade, qualquer tendência climática relatada deve ser mais atribuída à variabilidade climática da região do que à mudança climática como um todo (Byakatonda *et al.*, 2018).

Em outras palavras, como o período de dados é menor que o recomendado, não se pode concluir que a tendência foi ocasionada por mudança climática de modo propriamente dito, mas isso não impede que esses estudos com séries mais curtas sejam úteis para diversas aplicações na área dos recursos hídricos (Kumar *et al.*, 2016). O segundo fato interessante e que necessita de explicação está relacionado à existência de autocorrelação entre as séries e o quanto isso influenciará os resultados da análise de tendências. A existência de autocorrelação entre as séries pode ser efetiva nos resultados das tendências e suas alterações, e é por isso que alguns estudiosos se preocupam em retirar os efeitos da autocorrelação entre as séries e ter resultados mais precisos, assim como no caso do teste de Mann-Kendall modificado.

Por outro lado, é relevante destacar que vários estudos não levam essa consideração em questão e avaliam as tendências das séries com base apenas na metodologia do teste de Mann-Kendall. Ao comparar os resultados obtidos entre os testes de Mann-Kendall (MK) e de Mann-Kendall modificado (MMK), quanto à análise das secas e da precipitação, percebeu-se que os resultados não são tão diferentes em alguns estudos. Khanmohammadi *et al.* (2018), por exemplo, avaliaram a variação espaço-temporal dos eventos úmidos e secos sobre o Irã (1960–2014) com base nos índices SPI e RDI, e os resultados mostraram que com base nos testes de MK e MMK, as significâncias das tendências não foram muito diferentes. De modo preciso, a quantidade de séries com tendências estatisticamente significantes foi menor ao utilizar o teste de Mann-Kendall modificado, mas a diferença quantitativa não foi expressiva.

De todo modo, os autores ressaltam a necessidade de atenção quanto à dependência entre os dados para que a tendência seja computada precisamente. Na China, por sua vez, Tan *et al.* (2015) avaliaram a variação espaço-temporal das secas e de suas tendências com base nos índices SPI e SPEI ao longo de 40 anos (1972–2011). Ao caracterizar as secas em escalas

de tempo sazonais e anuais, o estudo realça a importância de eliminar a autocorrelação entre as séries de seca, mas aponta que os resultados encontrados com a retirada da autocorrelação foram basicamente os mesmos, o que fez com que o teste de Mann-Kendall padrão pudesse ser empregado sem prejuízos. Ainda a respeito do emprego do teste de Mann-Kendall, cabe destacar que esse só é capaz de identificar a direção da tendência das séries temporais, mas não identifica a correta magnitude da tendência das séries.

De fato, apesar de estimar a existência de tendências positivas ou negativas com base em diferentes níveis de significância, a lacuna referente à estimativa da magnitude de tal tendência é preenchida a partir do emprego do método de Sen (1968). Esse teste tem elevada relevância nos estudos das diferentes áreas dos recursos hídricos pois o real valor da tendência das séries temporais é útil para o entendimento das variáveis climatológicas avaliadas. O teste de Sen utiliza um modelo linear para estimar as tendências e assim como o de Mann-Kendall, não é significativamente afetado por valores extremos isolados. Além do mais, a magnitude das tendências é expressa de acordo com uma taxa de variação que se adequa às necessidades dos dados.

Para dados de precipitação, por exemplo, a depender da escala temporal avaliada, a taxa de variação pode ser expressa em mm/dia, mm/mês ou mm/ano, ao tratar da avaliação e análise de tendências de séries de precipitação diárias, mensais e anuais, respectivamente. Para as secas, a avaliação conjunta desses dois testes não paramétricos tem sido amplamente explorada pelos pesquisadores que buscam não só detectar a existência das tendências ao decorrer dos períodos analisados, como também identificar se a magnitude das secas e de outras características tende a aumentar ou a diminuir. Estudos que avaliam a tendência das secas têm sido desenvolvidos em diferentes partes do planeta e têm auxiliado os tomadores de decisões a gerenciar os recursos naturais em diferentes aspectos.

Utilizando seis escalas temporais distintas, Dashtpagerdi *et al.* (2015) avaliaram não só a severidade e a intensidade das secas como também suas tendências ao longo de 30 anos sobre regiões áridas e semiáridas do Irã. Os resultados obtidos a partir dos testes de Mann-Kendall e de Sen mostraram que as tendências foram mais significantes quanto à intensidade dos eventos do que para sua severidade de modo propriamente dito. Além disso, percebeu-se que o aumento da escala temporal influenciou o aumento na declividade da linha de tendência das séries bem como a quantidade de postos com tendência estatisticamente significante. Nas regiões áridas e semiáridas do Irã, as secas tenderão a ser mais severas e a recomendação dos autores é que outras características sejam avaliadas para compreender melhor seus efeitos.

No Brasil, Awange *et al.* (2016) avaliaram a evolução espaço-temporal das secas e de suas características em múltiplas escalas temporais por mais de 100 anos (1901–2013). Em relação à análise de tendências, os resultados mostram que nenhuma tendência significante foi detectada em relação à frequência, intensidade ou duração das secas de curto e longo prazo. Todavia, ao avaliar o percentual de área atingida, as tendências foram significantes e notáveis ao avaliar as secas de curto prazo, enquanto que para as secas de longo prazo os resultados não foram tão expressivos. Esse estudo tem grande importância especialmente no tocante à implantação de programas e estratégias quanto ao risco à ação das secas no Brasil, país onde grande parte da população vive sob os efeitos desses fenômenos.

Na Nova Zelândia, Caloiero (2017) analisou o padrão de tendência das secas com base nos índices SPI-3, SPI-6, SPI-12 e SP-24 (1951–2012) utilizando dados de quase 300 estações pluviométricas. A partir do teste de Mann-Kendall, os resultados indicam variabilidade dentre as escalas temporais, tal que no caso do SPI-3, grande parte da região apresentou tendências negativas no verão (15%) e no outono (40%), mas no inverno (5%) e na primavera (6%), as tendências indicaram que os eventos serão mais úmidos. Já para o SPI-12, por sua vez, quase 20% dos postos tiveram tendência significantemente negativa e para o SPI-24 esse número aumentou ainda mais, indicando que quanto maior for a escala temporal, maior é o nível de confiança. Esse estudo contribuiu para o processo de identificação de áreas mais vulneráveis a secas e é útil para o planeamento e gerenciamento dos recursos hídricos em diferentes setores.

Na África do Sul, Botai *et al.* (2017) empregaram o SPI-3, SPI-6 e SPI-12 para avaliar as características das secas e suas tendências (1985–2016) e os resultados mostram que há grande variabilidade espaço-temporal quanto à magnitude das tendências das secas. Nas zonas sul e oeste, os eventos foram mais frequentes, duradouros, severos e intensos. Além disso, o estudo mostrou que com o aumento da escala temporal também há aumento na duração, severidade e intensidade dos eventos de secas de longo prazo e que esses valores são mais expressivos do que os das secas de curto prazo. Todavia, perante o teste de Mann-Kendall, os resultados indicam que tendências das séries de duração, severidade e intensidade são quase insignificantes sobre a região em todas as escalas temporais.

Na Índia, Guhathakurta *et al.* (2017) avaliaram as tendências e a variabilidade das secas meteorológicas utilizando os índices SPI-1 e SPI-3 ao longo de mais de 100 anos (1901–2015). Com base no índice SPI-1, as séries tiveram tendências decrescentes estatisticamente significantes nos meses de junho, julho e setembro, especialmente na porção central do país. Já em agosto, as séries apresentaram tendência positiva ao nível de significância de 0,05 na

região oeste, indicando um aumento nas condições de umidade dessa área. Ao realizar análise sazonal, os autores notaram aumento do número de distritos que apresentaram tendências significantes, e esses dados estão tanto relacionados ao aumento da escala temporal quanto à ação das monções de sudoeste e de nordeste que influenciam o comportamento da região.

Ainda na Ásia, Khan *et al.* (2018) desenvolveram análises de tendências das secas em múltiplas escalas temporais em duas bacias distintas a partir do teste de Mann-Kendall. Um dos pontos fortes desse estudo foi não só comparar o desempenho de quatro índices de secas, comprovando que o SPI e SPEI foram os mais adequados para monitorar esses fenômenos, como comparar os resultados em relação à análise de tendências dos índices. Na bacia do Rio Songhua, as tendências estatisticamente significantes encontradas entre as diferentes escalas temporais foram positivas, enquanto na bacia do Rio Indus, as tendências foram negativas, independentemente do índice de seca e da escala temporal. Os autores recomendam que mais estudos desse tipo sejam desenvolvidos para prover uma ferramenta melhor em relação ao planejamento e manejo dos recursos hídricos das regiões.

Zarei e Eslamian (2017) avaliaram as tendências das chuvas e das secas sobre regiões áridas do Irã utilizando testes paramétricos e não paramétricos (1985–2013). Quanto ao padrão da precipitação, os resultados indicam que a nível mensal poucos postos apresentaram tendência estatisticamente significante, mas a nível sazonal, foram encontradas tendências negativas em todas as estações do ano, com destaque para o verão e o outono. Em relação à análise das secas, os resultados indicam que existiram anos consideravelmente secos ao decorrer do período, mas esses eventos não influenciaram o aparecimento de tendências, tal que apenas duas estações apresentaram significância estatística relevante.

Utilizando os dados do CRU (*Climate Research Unit*), Páscoa *et al.* (2017) avaliaram as tendências das secas de longo prazo sobre a Península Ibérica, a partir dos índices SPI e SPEI. Utilizando teste de Mann-Kendall modificado, Spearman-Rho e de Sen, há indícios de existe uma boa concordância entre os resultados do SPI e SPEI, mas as incoerências tendem a aparecer diante da tendência significante da evapotranspiração sobre a região. Os resultados mostram que para todo o período a magnitude das tendências foi menos expressiva do que ao segmentar toda a janela temporal em três diferentes etapas. No geral, nota-se que através do SPEI uma maior quantidade de *grids* apresentou tendência se comparado aos resultados do SPI. O estudo traz resultados pertinentes que corroboram com diversos outros existentes na literatura e tem suma importância quanto ao processo de gerenciamento de risco das secas.

Na região semiárida da África, Byakatonda *et al.* (2018) utilizaram os testes de Mann-Kendall e de Sen para a avaliar as tendências das secas em múltiplas escalas de tempo ao longo de mais de 50 anos (1960–2016) com base no SPI e SPEI. Apesar de ambos os índices terem sido hábeis em identificar as secas históricas mais notáveis da região, percebeu-se que no tocante à análise das tendências, as declividades mais expressivas foram encontradas ao monitorar tais eventos perante uso do SPEI. Apesar de que em algumas zonas as tendências das secas de curto, médio e longo prazo foram concordantes e significativamente negativas, a partir da análise dos dois índices de seca, os autores ressaltam a importância de incluir outras variáveis no processo de caracterização desses fenômenos.

Recentemente, Rahman *et al.* (2018) utilizaram dados de 15 estações pluviométricas de uma província do Paquistão e realizaram análise de tendências dos índices SPI-1 e SPI-12. A partir do teste de Mann-Kendall, tanto as tendências da precipitação quanto as das secas foram feitas para todos os meses, o que garantiu robustez do estudo. Os resultados mostram que as secas de curto e longo prazo são similares, de modo que para as secas de curto prazo, o sudoeste apresentou tendências positivas em todos os meses, enquanto nordeste teve maioria de tendências negativas. O padrão espacial foi mantido para as secas de longo prazo, mas no geral, os resultados apontam que a tendência geral sobre a área de estudo é positiva.

Com base no índice SPEI, Guo *et al.* (2018a) desenvolveram um robusto trabalho para caracterizar as secas sobre a Ásia Central (1966–2015). Além de terem avaliado o padrão espaço-temporal das secas, sua frequência, periodicidade e relações com conexões climáticas, os resultados obtidos a partir dos testes de Mann-Kendall modificado e de Sen mostraram que ao avaliar o comportamento das secas nos 13 últimos anos (2003–2015), a região apresentou tendência negativa e esses resultados levantam dois fatos interessantes a serem discutidos: o primeiro é que ao considerar um período menor, as declividades de Sen passam a ser mais expressivas, independentemente da escala temporal avaliadas. O segundo é que, assim como em outros estudos, foi possível perceber que quando se aumenta a escala temporal, maior é a magnitude das tendências.

Conclui-se que a análise de tendências das secas e de suas principais características é um tema bastante atual e ainda pertinente na literatura, devido não só ao potencial extensivo das secas como frente à necessidade dos estudiosos de entender quais são as tendências desses fenômenos. Por outro lado, diante da variabilidade das características naturais encontradas em nosso planeta e da importância da identificação de zonas com comportamento homogêneo, métodos de agrupamento estão sendo desenvolvidos ao longo dos anos no intuito de viabilizar

a regionalização de diferentes áreas com base em características similares e assim, entender melhor o comportamento espaço-temporal das secas e de outros fenômenos climáticos entre as diferentes regiões do planeta.

3.6. ANÁLISE DE AGRUPAMENTO

Delimitar zonas com características homogêneas sempre foi uma das tarefas mais úteis e difíceis dentre as pesquisas climáticas. No geral, definir quais critérios serão empregados para regionalizar diferentes áreas envolve não só domínio de conhecimento como uma sensibilidade elevada por parte dos pesquisadores para tomar a decisão. No tocante ao monitoramento dos vários fenômenos naturais, é importante destacar que na maioria dos casos há uma supressão da real delimitação de regiões homogêneas e isso está relacionado ao fato de que predominantemente, a divisão política é adotada, mesmo que essa não seja condizente com os regimes naturais atuantes na região (Goyal e Gupta, 2014). Nesse contexto, técnicas estatísticas têm atraído à atenção de pesquisadores que buscam aumentar a compreensão da relação de causa e efeito entre os acontecimentos naturais e o padrão regional.

Recentemente, os processos multivariados de análises de *clusters* que são utilizados para zonear regiões homogêneas e identificar padrões climáticos regionais e globais tem se notabilizado por ser um método alternativo bastante eficaz para agrupar variáveis naturais distintas de acordo com certa característica definida. A aplicação desses métodos é um dos artifícios mais utilizados na literatura para classificar e agrupar variáveis que refletem o comportamento da natureza em caráter multidisciplinar, e sua relevância e versatilidade estão ligadas não só à gama de variáveis utilizadas, como em função da possibilidade de identificar padrões de similaridade e dissimilaridade entre e dentre essas variáveis.

A análise de *clusters* é uma técnica estatística pela qual as diferentes variáveis são organizadas em grupos homogêneos, tal que a dissimilaridade entre os componentes de um mesmo grupo é minimizada e as diferenças entre os diferentes grupos tendem a ser maximizadas (Wang *et al.*, 2015). Já de maneira mais detalhada, os *clusters* representam os grupos formados pelos diferentes objetos/variáveis/séries que se relacionam entre si conforme uma condição de similaridade ou dissimilaridade existente. Assim, a chuva, a temperatura, a evapotranspiração, os índices de seca e quaisquer outras variáveis podem ser empregadas nas análises de *clusters*, fato esse que realça a relevância e a flexibilidade dessa ferramenta nas análises que envolvem o zoneamento das características naturais.

Na literatura, é válido pontuar que existem diferentes algoritmos capazes de realizar a análise de *clusters*, e.g., análise de *clusters* hierárquica (HCA), os *Self-Organizing Maps* (SOM) e o método de *k-means*. Nesse sentido, cabe destacar que cada algoritmo utiliza uma solução distinta para separar os elementos em diferentes grupos homogêneos e que diante dessa diversidade, espera-se que cada uma desses apresente suas vantagens e desvantagens em relação aos outros (Rad e Khalili, 2015). Dentre os algoritmos, um dos mais simples, usuais e eficientes é o que se baseia na análise de *clusters* hierárquica, e esse tem sido muito utilizado ao longo do tempo. Esse método pode ser classificado em dois diferentes tipos, sendo os que se baseiam em métodos divisivos e em métodos aglomerativos (Araújo e Souza, 2012).

Nos métodos divisivos, assume-se que a partir de um grupo são feitas decomposições múltiplas formando vários *clusters*, enquanto que de acordo com os aglomerativos, os *clusters* se aglomeram de modo sucessivo até compor um único grupo que é formado por todos os componentes. Independentemente da análise desenvolvida, destaca-se que um dos motivos da popularidade da análise de *clusters* hierárquica é que ele agrupa as séries homogêneas com base em diferentes métodos e métricas de dissimilaridade e por isso, diante da variedade de combinações a serem empregados, essa técnica é considerada flexível e adequada a resolver diferentes problemas de regionalização que envolvem vários variáveis e propósitos (Santos *et al.*, 2019a).

De modo detalhado, o método de ligação é referente ao modo como a distância entre os *clusters* é calculada, tal que dentre os métodos mais comuns, destacam-se o método de ligação simples (*simple linkage*), ligação completa (*complete linkage*), ligação por centroides (*centroid linkage*), ligação média (*average linkage*) e o método de ligação de variância mínima (*Ward's minimum variance*) (Keller Filho *et al.*, 2005). As métricas, por sua vez, se relacionam à medida estatística que relaciona os elementos que compõem cada *cluster*, sendo as mais utilizadas na literatura o coeficiente de correlação linear, a distância euclidiana, os parâmetros de Spearman e *cityblocks* (Unal *et al.*, 2003). A Figura 1 ilustra a influência da métrica de dissimilaridade e do método de ligação entre os *clusters* quanto ao agrupamento.

A mudança na métrica de dissimilaridade escolhida implica no fato de que por mais que dois elementos possam ser similares e integrantes de um mesmo *cluster* sob o ponto de vista da distância euclidiana, ao utilizar o coeficiente de correlação como métrica, esses elementos podem passar a ser integrantes de diferentes *clusters*. A partir da Figura 1a, pode-se perceber que há possibilidade de agrupar os elementos de acordo com três métricas distintas, sendo elas, neste exemplo, a cor, o tamanho e o formato. Assim, fica mais simples entender

que ao alterar a métrica de agrupamento desses elementos, tende-se a modificar o modo como estes passam a se relacionar entre si.

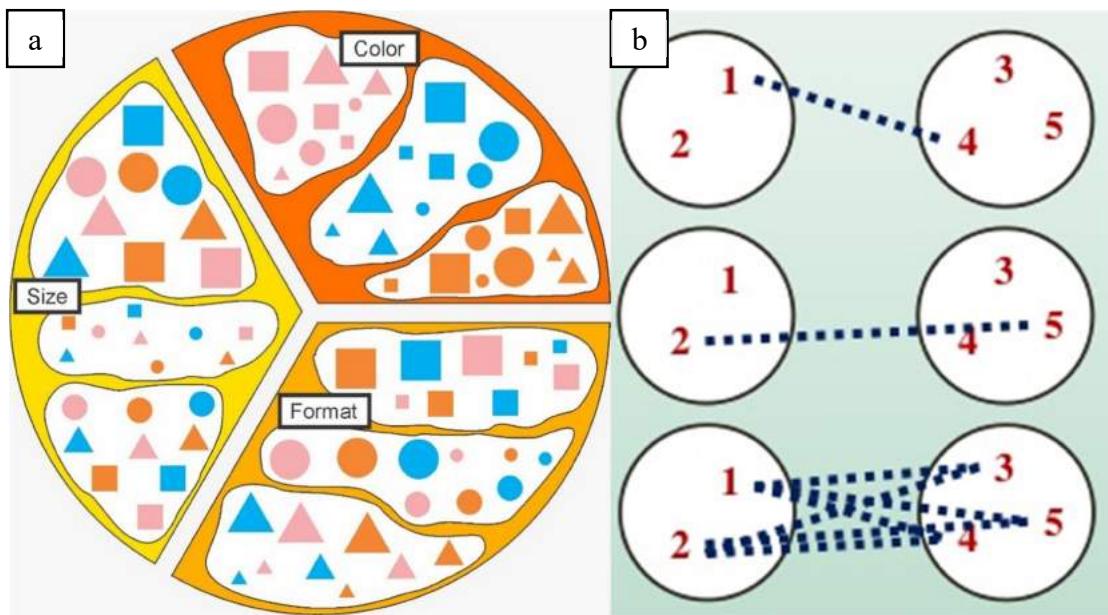


Figura 1– Influência da (a) métrica de dissimilaridade e do (b) método de ligação entre *clusters* na formação de diferentes grupos homogêneos.

Por outro lado, ao definir a métrica de dissimilaridade é provável que as distâncias entre os *clusters* mudem em função do método de ligação empregado. De modo explicativo, supõe-se que ao definir a métrica de dissimilaridade grupos distintos seriam formados, como mostrado na Figura 1a e, assim, esses grupos agora passam a se relacionar entre si, tal como mostrado na Figura 1b. No caso, ao definir dois *clusters* compostos por dois e três elementos cada e ao considerar que as linhas pontilhadas são as distâncias entre os *clusters*, destaca-se que há diferença na relação entre esses *clusters*. No caso, os métodos de ligação mostrados na Figura 1b são os de ligação simples, completa e média, respectivamente. Na ligação simples, a relação entre os *clusters* é definida a partir da mínima distância entre seus elementos e para os métodos de ligação completa e média, as distâncias são as máximas e as médias.

Conclui-se, portanto, que a escolha do método de dissimilaridade influencia no modo como os *clusters* se relacionam entre si e quão distantes estão uns dos outros, enquanto a métrica de dissimilaridade influencia na relação dentre as séries que compõem cada *cluster*. Além disso, é válido pontuar certas vantagens do método de análise de *clusters* hierárquica frente aos demais algoritmos de agrupamento. Em comparação ao de *k-means*, nota-se que a definição dos grupos envolve subjetividade do operador em relação a técnicas hierárquicas, pois há chance de obter um mínimo local de distância mínima entre os *clusters* diferentemente

do encontrado para as análises hierárquicas. Além disso, enquanto as análises hierárquicas permitem o uso de diferentes métricas de dissimilaridade, o *k-means* só se mostra adequado devido ao uso da distância euclidiana (Goyal e Gupta, 2014).

No caso de utilizar métodos de Fuzzy, por sua vez, é válido pontuar que o algoritmo é muito sensível em certos parâmetros. O número de *clusters*, o valor *fuzzyficator* e o critério de parada, por exemplo, são alguns dos parâmetros calibrados e utilizados para controlar o método de agrupamento, e esses precisam ser cuidadosamente escolhidos no intuito de se obter bons resultados. Dessa forma, ressalta-se que no tocante ao comportamento das secas, a identificação de zonas homogêneas com base em características como duração, severidade, intensidade e frequência é uma valorosa ferramenta no processo de entendimento desse fenômeno extremo, tendo em vista que padrões espaciais a nível regional e global podem ser mais facilmente identificados e relacionados com fenômenos climáticos influentes na área.

Todavia, apesar da importância do assunto, é possível perceber que muitos estudos desenvolvidos se atêm a avaliar e agrupar as regiões com base no comportamento das chuvas, enquanto que as análises de *clusters* desenvolvidas com base no comportamento das secas e de suas características são mais escassas. Na Turquia, foi desenvolvido um estudo pioneiro e de suma importância no tocante à aplicação das análises de agrupamento. Unal *et al.* (2003) redefiniram as zonas climáticas da Turquia utilizando a análise de *clusters* hierárquica com base nas informações de precipitação e de temperatura das regiões (1951–1998). Ao avaliar os resultados de cinco métodos de ligação diferente, o método de Ward foi o mais recomendado para a tarefa e as conclusões mostram que há sete regiões climáticas distintas sobre o país.

No Brasil, seguindo a mesma linha de pensamento de Unal *et al.* (2003), Keller Filho *et al.* (2005) desenvolveram um trabalho pioneiro que envolveu a análise de agrupamento no país. Com base nos métodos hierárquicos, os autores agruparam as regiões de acordo com as séries de probabilidade de chuva ao adotar a distância euclidiana e o método de Ward como métricas de dissimilaridade e método de ligação. No geral, os resultados revelam a existência de seis áreas distintas sobre o Brasil e essas tem comportamento bastante diversificado. Em detalhe, existem cerca de 25 zonas pluviometricamente homogêneas no país, o que realça a variabilidade das características físicas encontradas na região e a dificuldade de realizar um monitoramento eficaz da precipitação.

No estado de Alagoas, Nordeste do Brasil, Lyra *et al.* (2014) realizaram análises de *clusters* hierárquicas para entender a variabilidade espaço-temporal da precipitação na área.

Com base nos dados de 36 pluviômetros (1961–1990) espaçados sobre a região, os autores identificaram cinco zonas com padrão de chuvas similares ao longo da extensão do estado. A partir dos resultados, foi possível perceber que a delimitação encontrada certamente foi fruto de uma série de variáveis, destacando-se dentre tais a topografia e a distância até a costa de cada região. No mais, é notório que o nordeste brasileiro apresenta elevada variabilidade de características físicas e por isso, ressalta-se a contribuição desse estudo também no tocante à identificação dos sistemas climáticos atuantes na região.

Pouco depois, Teodoro *et al.* (2016) realizaram a releitura do estudo proposto por Lyra *et al.* (2014), adotando a região do Mato Grosso do Sul, no Centro-Oeste do Brasil como área de estudo. Nesse trabalho, a métrica de dissimilaridade foi a distância euclidiana e o método de ligação empregado foi a ligação de Ward, mas um ponto relevante é que a quantidade de *clusters* foi definida com base na distância euclidiana entre os grupos, que foi de 50%. Esse não é um método muito convencional na definição do número de *clusters*, mas foi adequado às necessidades da pesquisa. As conclusões apontam que existem cinco regiões homogêneas sobre a região e três períodos de chuva distintos, sendo eles o período seco, de transição e o úmido, também identificado a partir dos *clusters*.

Em outras regiões do Brasil, Oliveira-Junior *et al.* (2017) identificaram a existência de três regiões com padrão de precipitação homogêneos no estado do Tocantins e Brito *et al.* (2017) encontraram seis zonas pluviometricamente similares sobre o Rio de Janeiro. Dentre os trabalhos recentes, o desenvolvido por Santos *et al.* (2019a) merece destaque em função dos métodos empregados. Diferentemente do que já foi feito, a análise de *clusters* hierárquica sobre o estado da Paraíba foi feita utilizando estimativas de precipitação do satélite TRMM. Além disso, foram realizadas análises de agrupamento e regionalização para cada mês, fato esse que permitiu a identificação de similaridade das regiões em cada período. Os resultados foram satisfatórios e hábeis para identificar zonas similares no estado, corroborando com os resultados de outros estudos já realizados.

No tocante à análise de agrupamento das secas e de suas características de maneira mais particular, nota-se que apesar de mais escassos, estudos desse tipo também tem atraído a atenção dos estudiosos espalhados no mundo. Rad e Khalili (2015) desenvolveram um estudo de análise de agrupamento na região do Irã com base nos valores máximos e mínimos do SPI em múltiplas escalas temporais. Para tanto, foram utilizados nove algoritmos de agrupamento e quatro índices de validação para embasar a escolha da quantidade dos *clusters* e diante dessa metodologia, os pesquisadores apontaram a existência de cinco zonas homogêneas na região.

Apesar das técnicas hierárquicas terem tido resultados satisfatórios, os autores ressaltam a importância de ter disponível uma rede de dados especialmente no tocante ao monitoramento de secas meteorológicas.

Na China, Li *et al.* (2015) delimitaram regiões climáticas com base no comportamento espaço-temporal das secas agrícolas e avaliaram as características de cada uma das divisões. Com base nos resultados do SPI-3, as análises de *clusters* foram desenvolvidas a partir da aplicação conjunta dos métodos hierárquicos de Ward e não hierárquicos de *k-means*, e tais produtos foram bastante similares entre si. As conclusões indicam que existem oito diferentes zonas homogêneas na região e que essas são influenciadas pela variação das monções de inverno e verão, que afetam o regime das secas agrícolas. Por fim, os autores concluem que a divisão climática desenvolvida nessa pesquisa facilita a avaliação das secas a nível regional e a nível global, e ressaltam a importância do índice SPI-3 no cenário de produção agrícola.

Pouco depois e de maneira muito parecida ao estudo desenvolvido por Li *et al.* (2015), McGree *et al.* (2016) utilizaram análises de *clusters* hierárquicas com o objetivo de identificar não só a existência de regiões homogêneas sobre a Austrália como a relação com o fenômeno climático do El Niño. Ao utilizar o SPI-12 como índice primário, a distância euclidiana como métrica de dissimilaridade e o método de Ward como meio de ligação entre os *clusters*, pôde-se identificar a existência de 11 *clusters* sobre toda a região, o que demonstra a variabilidade notável no comportamento das secas. No geral, os resultados estão ligados às teleconexões climáticas atuantes, e.g., IPO (*Interdecadal Pacific Oscillation*) e o ENSO (*El Niño–Southern Oscillation*), fato que realça a aplicabilidade dessa técnica quanto à identificação de padrões homogêneos.

Shiau e Lin (2016) e Yang *et al.* (2017) desenvolveram dois estudos muito parecidos nos últimos anos. O primeiro trabalho foi desenvolvido na região de Taiwan e se baseou no emprego do índice SPI-3 para delimitar o comportamento de zonas homogêneas, enquanto o segundo utilizou a bacia do Rio Tarim, China, e o SPI-12 como índice de seca. Em ambos os casos, foram desenvolvidas análises com base nas séries de comportamento, duração e severidade das secas e os resultados mostram que a análise foi satisfatória e hábil para identificar padrões de similaridade entre as regiões. O produto final está ligado à frequência e à intensidade dos eventos de seca ocorridos na área e foi possível encontrar padrões de similaridade quanto às tendências dessas zonas homogêneas.

4. MATERIAIS E MÉTODOS

4.1. ÁREA DE ESTUDO

A área de estudo desta pesquisa é o estado da Paraíba, região que representa uma das 27 unidades federativas do Brasil e um dos nove estados que compõem a região Nordeste do Brasil (NEB). Limitado pelas latitudes 5,875°S e 8,375°S e pelas longitudes 38,875°O e 34,625°O, o estado da Paraíba faz fronteira com o estado do Ceará (a oeste), com o estado do Rio Grande do Norte (ao norte), com o Oceano Atlântico (a leste), e com o Pernambuco (ao sul) e tem área total de 56.469,78 km², que é maior do que a área de países como Croácia, Costa Rica e Dinamarca, por exemplo. Com uma população de cerca de quatro milhões de habitantes, o estado é formado por 223 municípios e subdividido em quatro mesorregiões: Mata Paraibana, Agreste Paraibano, Borborema e Sertão Paraibano (IBGE, 2016) (Figura 2).

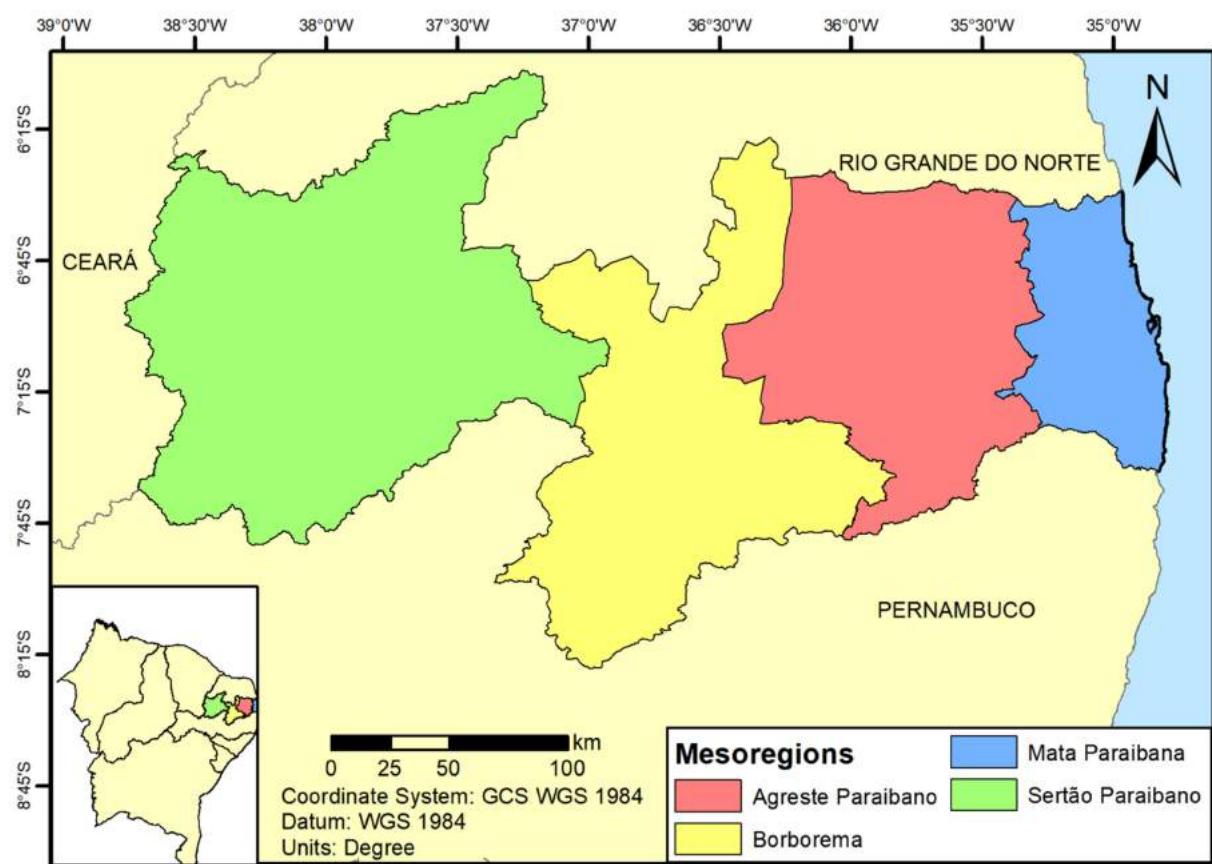


Figura 2 – Estado da Paraíba e suas mesorregiões.

A Mata Paraibana é a mesorregião que comprehende todo o litoral da Paraíba e se estende em direção ao interior do estado por uma distância aproximada de 80 km. Apesar de ser a menor mesorregião, a Mata Paraibana é a região mais populosa, onde importantes cidades como João Pessoa e Cabedelo estão localizadas. Quanto às suas características físicas,

a Mata Paraibana é predominantemente composta por planícies litorâneas e coberta por restos de Mata Atlântica, sendo o clima da região classificado como quente úmido litorâneo (As'), segundo Köppen. Essa região tem os maiores índices pluviométricos do estado, precipitação anual média variando de 900 a 1800 mm, período chuvoso concentrado de abril a junho, e período seco perdurando de agosto a dezembro (Soares *et al.*, 2016).

O Agreste, por sua vez, é a segunda menor mesorregião da Paraíba e a que apresenta a segunda maior população do estado. O Agreste é a mesorregião de transição entre as regiões da Mata Paraibana (a leste) e da Borborema (a oeste) e por isso, sua vegetação varia entre a Mata Atlântica da região litorânea e a vegetação arbustiva do interior da Paraíba. Quanto ao relevo, o Agreste pode ser dividido em Agreste Baixo e Agreste Serrano e há variabilidade da altitude, principalmente no limite com a zona da Mata Paraibana, com cotas altimétricas que chegam a manter a média de altitude de 600 m. Com um inverno seco (clima Aw, segundo Köppen), essa região tem precipitação anual média que varia de 800 a 1000 mm, período chuvoso de março a junho e período seco de agosto a dezembro (Soares *et al.*, 2016).

Na porção central da Paraíba está localizada Borborema, mesorregião menos populosa do estado e onde se encontra uma das formações geológicas mais características do NEB: o Planalto da Borborema. A partir dessa, as características encontradas no interior do estado se diferenciam das encontradas nas regiões litorâneas, tal que as altitudes passam a variar de 500 a 600 m e a vegetação passa a ser a caatinga, composta predominantemente por árvores arbustivas e rasteiras. Segundo a classificação Köppen, o clima da Borborema é um semiárido quente e seco (Bsh e Aw') e os níveis pluviométricos são os menores do estado, com destaque à cidade de Cabaceiras, município que recebe o título de cidade mais seca do Brasil, com precipitação média anual de 300 mm. A precipitação anual média varia de 300 a 800 mm, o período chuvoso vai de março a maio e é seco nos demais meses.

Na extremidade oeste do estado da Paraíba está o Sertão Paraibano, mesorregião de maior extensão territorial e que abrange várias cidades importantes como Patos e Sousa, por exemplo. Nessa região, o relevo é predominantemente formado pelas Depressões Sertanejas, formações geológicas compostas por um conjunto de terras baixas que ocupam áreas extensas, com altitudes que variam entre 200 e 400 m. Em geral, as características da região do Sertão se assemelham as da Borborema, sendo a vegetação predominante a caatinga e o clima é o semiárido quente e seco (Bsh e Aw', segundo Köppen). Entretanto, nas serras e depressões, o clima do Sertão é mais úmido e os índices pluviométricos maiores. No Sertão, a precipitação anual média varia de 400 a 1000 mm e o período chuvoso é entre fevereiro a março.

Quanto aos sistemas climáticos atuantes sobre o estado da Paraíba, Kousky (1979) apontou variabilidade climática existente no NEB, onde está inserido o estado da Paraíba, e identificou a existência de fenômenos de macro-, meso- e microescala que influenciam o padrão das chuvas na região. Dentre todos esses fenômenos, destacam-se principalmente a Zona de Convergência Intertropical (ZCIT) e os Vórtices Ciclônicos de Alto Nível (VCAN), que atuam especialmente no interior do estado, enquanto que na zona mais próxima ao mar, além da ZCIT e dos VCAN, também atuam os ventos alísios, as ondas de leste e a circulação da brisa marítima (Keller Filho *et al.*, 2005; Reboita *et al.*, 2010; Araújo e Souza, 2012; Rozante *et al.*, 2018). Além disso, pontua-se o relevo como agente expressivo e influente no regime de chuvas da região.

4.2.DADOS DE PRECIPITAÇÃO

4.2.1. DADOS DE PLUVIÔMETROS

Neste trabalho, os dados de chuva diária obtidos por medição de postos pluviométricos ao longo do período de 1998 a 2017 foram disponibilizados pela Agência Executiva de Gestão de Águas (AESÁ). Ao todo, existem 251 séries espaçadas por todo o estado e os dados diários foram acumulados a nível mensal para cálculo do índice SPI e desenvolvimento das análises de seca deste estudo. Entretanto, cabe destacar que foi realizada uma análise prévia da consistência das séries de precipitação disponibilizadas para avaliar a qualidade da rede pluviométrica sobre o estado da Paraíba ao longo do período. A Figura 3 mostra a distribuição espacial do percentual de falhas das séries de chuva, a distribuição percentual das falhas para cada mesorregião e a evolução temporal de dados disponíveis ao longo dos 20 anos.

A partir da Figura 3a, nota-se que considerável irregularidade na distribuição espacial dos postos pluviométricos sobre o estado da Paraíba. Em termos quantitativos, a região que tem a melhor instrumentação é o Sertão, seguida do Agreste, Borborema e da Mata Paraibana. Todavia, ao considerar a densidade de estações por km^2 para cada mesorregiões, a ordem de classificação se altera e a Mata Paraibana, passa a apresentar maior número de estações por km^2 , com taxa de uma estação a 120 km^2 . O Agreste, cujos postos estão concentrados na porção central, tem a segunda maior densidade pluviométrica do estado, com cerca de uma estação a cada 170 km^2 . Para o Sertão e a Borborema a situação é considerada a mais crítica da Paraíba, tal que só existe um posto a cada 230 e 300 km^2 , respectivamente.

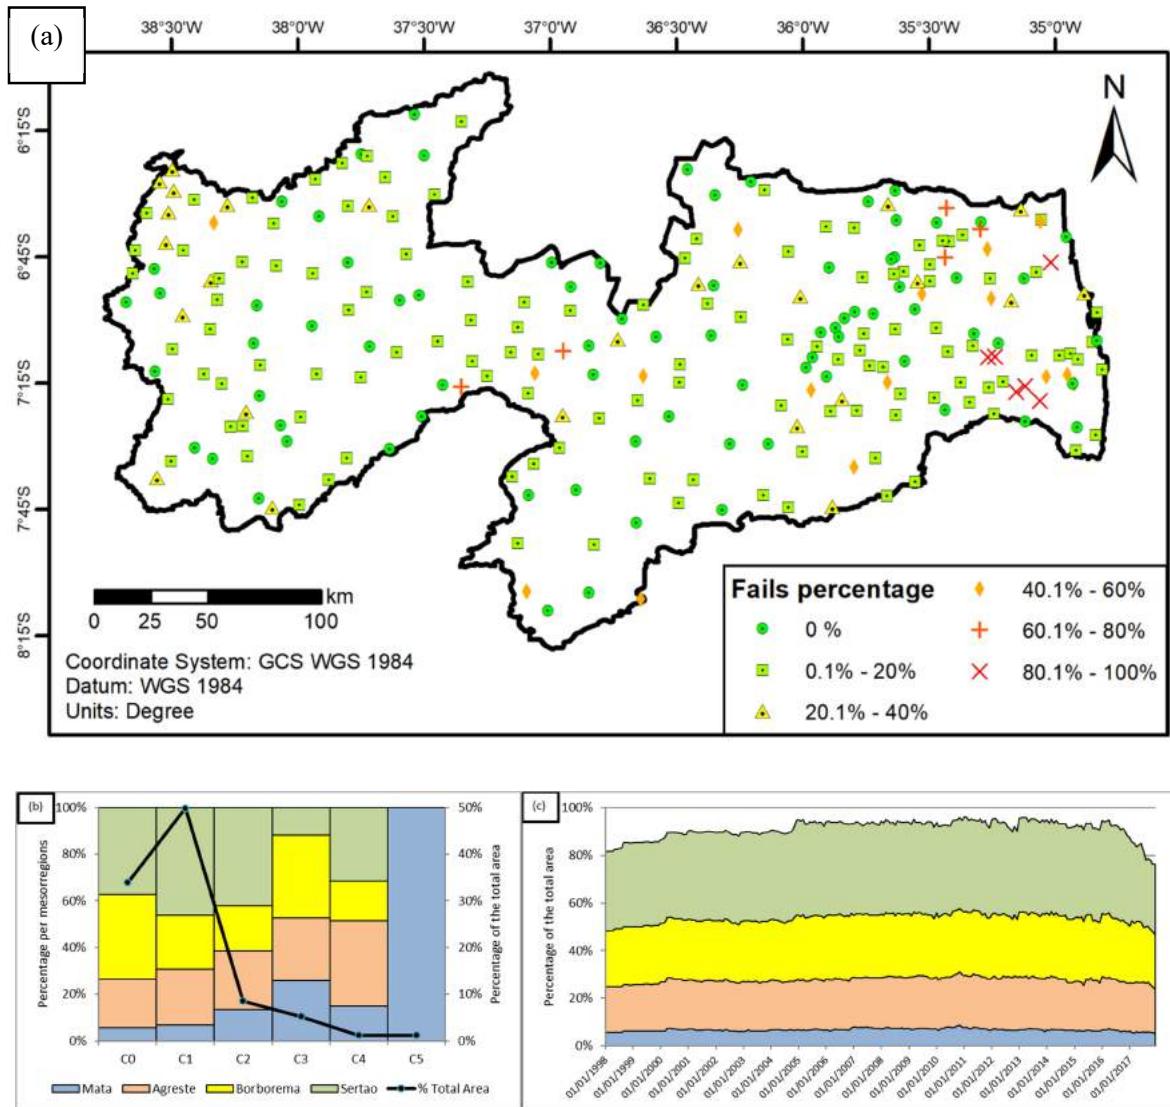


Figura 3 –(a) Distribuição espacial do percentual de falha das séries de chuva, (b) distribuição percentual das falhas para cada mesorregião e (c) evolução temporal do percentual de dados disponíveis ao longo dos 20 anos.

A WMO (1994) recomenda que, a depender das condições fisiográficas, a área mínima monitorada por cada estação deve ser de 575 km² ao considerar zonas com relevo plano e pouco ondulado. Já em zonas de topografia complexa, a quantidade de pluviômetros por km² deve ser maior a fim de realizar a correta caracterização do regime pluviométrico da região. Ao utilizar essa taxa de densidade como valor referencial, percebe-se que a instrumentação da Paraíba pode ser considerada satisfatória, especialmente em se tratando das regiões da Mata Paraibana e do Agreste. Todavia, a densidade descrita previamente foi computada levando em consideração todos os pluviômetros existentes em cada mesorregião, sem desconsiderar aqueles que apresentaram falhas em seus registros ao decorrer dos anos.

Por tal motivo, estima-se que a situação quanto à densidade pluviométrica sobre o estado da Paraíba é ainda mais crítica ao considerar apenas as estações pluviométricas que não apresentaram falha ao longo do período de 1998 a 2017. Ao excluir os postos com séries de dados incompletas dessa análise, a taxa passa a ser de um posto a cada 580, 540, 780 e 910 km² para as mesorregiões da Mata, Agreste, Borborema e Sertão, respectivamente. A Paraíba como todo tem uma taxa de densidade de cerca de um posto a cada 725 km², ultrapassando o valor limite estabelecido pela WMO e realçando a debilidade da instrumentação sobre a região.

Além da irregularidade no tocante à distribuição espacial, percebe-se a partir da Figura 3b que a rede pluviométrica do estado da Paraíba também apresenta significativas deficiências em termos qualitativos. Ao definir diferentes classes para avaliar a qualidade das séries de chuva do estado, i.e., C0 (0,0%), C1 (0,0–20,0%), C2 (20,0–40,0%), C3 (40,0–60,0%), C4 (60,0–80,0%) e C5 (80,0–100,0%), percebe-se que das 251 séries espaçadas sobre o território, em apenas 78 não houve falhas ao longo dos 20 anos analisados. A partir do cálculo das áreas de influência de cada pluviômetro estimadas pelo do método de Thiessen, nota-se que esses 78 pluviômetros representam um percentual apenas de cerca de 34% da área do estado, o que demonstra que apenas um terço do território da Paraíba apresentou continuidade de dados de chuvas ao decorrer de todo o período.

Analizando detalhadamente os postos que não apresentaram falhas ao decorrer da série histórica (C0), nota-se que grande parte de suas áreas estão inseridas na mesorregião do Sertão (37,1%), seguida da Borborema (36,4%), do Agreste (20,9%) e da Mata Paraibana (5,6%). Em relação aos postos categorizados como C1, que representam os postos com o menor percentual de falhas, percebe-se que esses cobrem cerca de 50% do território, tal que o Sertão abrange o maior percentual (46,1%), enquanto a Mata tem os menores percentuais (6,9%). Para as demais classes, há diminuição em relação ao percentual de área de influência como um todo, tal que todos os postos que apresentaram mais do que 20% de falhas, i.e., C2, C3, C4 e C5, totalizaram juntos uma cobertura de pouco mais que 16% do estado.

Dentre esses resultados, um destaque especial merece ser dados aos postos com o maior percentual de falhas, i.e., C5. Diferentemente das outras classificações, notou-se que toda área sob influência de postos com elevado percentual de falhas estava localizada na zona da Mata Paraibana, tal que esse mesmo comportamento pode ser observado nos postos tipo C3 (5,2%), compostos em mais de 25% por tal mesorregião. Isso demonstra que a região da Mata Paraibana apresenta um déficit não só na quantidade de postos como também quanto a

qualidade das séries de dados disponíveis se comparados as outras regiões. Quanto à evolução temporal dos dados disponíveis, nota-se a partir da Figura 3c que não houve momento em que todos os pluviômetros apresentaram dados.

Entretanto, em alguns casos mais que 95% do território teve a precipitação monitorada de modo simultânea e esse resultado traz uma discussão interessante quanto à qualidade dos pluviômetros da Paraíba. Fica comprovado que apesar do fato de que apenas um terço do território tenha apresentado séries completas, o percentual de área com disponibilidade de dados ao decorrer do tempo ainda assim foi alto. Isso significa que as falhas sobre o estado, de modo geral, não aconteceram de maneira simultânea, já que caso isso tivesse acontecido, os percentuais de área com dados em diversos momentos seriam baixos. Ainda sobre essa figura, nota-se que até o ano de 2004, o percentual de área com disponibilidade de dados se manteve em torno de 90%, enquanto que de 2005 a 2013, há aumento nos valores percentuais.

Por outro lado, a partir do ano de 2015, houve diminuição no percentual de área com disponibilidade de dados, tal que os menores valores chegaram a 75%. Em relação ao padrão de cada mesorregião, houve maior variação nos valores percentuais do Sertão, enquanto que na região da Mata, os valores percentuais foram praticamente constantes ao decorrer do tempo, i.e., o percentual de área com disponibilidade de dados na região litorânea se manteve inalterado ao longo do período, enquanto que houve variação significativa no Sertão. Diante dessa discussão, todas as séries que apresentaram falhas ao decorrer do período de 1998 a 2017 foram excluídas das análises seguintes, resultando em um total de 78 séries de chuva completas para serem utilizadas no presente estudo.

A decisão de descartar as séries pluviométricas incompletas é motivada pelo fato de que um dos propósitos é avaliar a acurácia do satélite TRMM em captar o comportamento das secas e de suas características. Assim, trabalhar apenas com séries de dados completas evita tanto o processo de preenchimento de falhas, como também expõe a situação da região quanto à disponibilidade de dados de precipitação. É válido destacar que os dados utilizados nesta pesquisa também foram avaliados em termos de erros e de consistência. De modo geral, não foram encontrados quaisquer erros grosseiros e no tocante a consistência e homogeneidade das séries, o método das duplas massas constatou quaisquer episódios relacionados à alteração nas condições físicas da região. Os resultados indicaram que todas as 78 séries são adequadas para as análises propostas.

4.2.2. DADOS TRMM

Para realizar o monitoramento das secas utilizando estimativas de chuvas completas e igualmente distribuídas sobre o estado da Paraíba, foram utilizados dados do satélite *Tropical Rainfall Measuring Mission* (TRMM), que como já explicado, é uma missão conjunta entre a agência espacial americana (NASA) e a agência espacial japonesa (JAXA) (Huffman *et al.*, 2007). Lançado ao final de 1997, o TRMM foi desenvolvido para realizar o monitoramento da precipitação nas regiões tropicais do planeta, mas sofreu problemas técnicos por volta de 2014 e passou a cair lentamente enquanto continuava a coletar dados (Xia *et al.*, 2018). Dentre os produtos disponíveis, o TRMM *Multi-satellite Precipitation Analysis* (TMPA) é o produto que combina os dados de precipitação estimados por medições de sensoriamento remoto com as observações de precipitação de estações pluviométricas e radares, quando disponíveis.

É válido pontuar que os produtos do TMPA são capazes de cobrir extensos domínios de espaço, i.e., entre latitudes 50°N e 50°S e longitude 180°O e 180°L, além de apresentarem uma refinada resolução espacial de $0,25^\circ \times 0,25^\circ$, permitindo o monitoramento da chuva em várias áreas do globo (Zhao *et al.*, 2018). Na Paraíba, vários estudos utilizaram as estimativas do TMPA e no geral, os resultados indicaram que essas estimativas são alternativas viáveis no tocante ao desenvolvimento de estudos relacionados aos recursos hídricos (Brasil Neto *et al.*, 2016; Brasil Neto *et al.*, 2017; Santos *et al.*, 2019a; Santos *et al.*, 2019b; Brasil Neto *et al.*, 2019a; Brasil Neto *et al.*, 2019b). Neste trabalho, foram utilizados as estimativas do TMPA 3B42v7 e a área de estudo foi dividida em 187 grids (11×17), cujo os centroides variam a cada $0,25^\circ$ das latitudes 5,875°S a 8,375°O e das longitudes 38,875°O a 34,875°O (Figura 4).

A Figura 4 mostra a distribuição espacial da grade TRMM e dos postos pluviométricos utilizados neste trabalho sobre o estado da Paraíba. É interessante destacar que as séries de precipitação diária foram acumuladas para se obter as séries de precipitação mensais desde janeiro de 1998 até dezembro de 2017, obtendo-se pouco menos de 45,000 dados de totais acumulados mensais (187 séries TRMM \times 20 anos \times 12 meses), estimados por satélite de sensoriamento remoto sobre toda a região de estudo. As estimativas são contínuas e cobrem o estado da Paraíba bem como suas redondezas, o que garante uma caracterização espacial robusta e completa de toda a área.

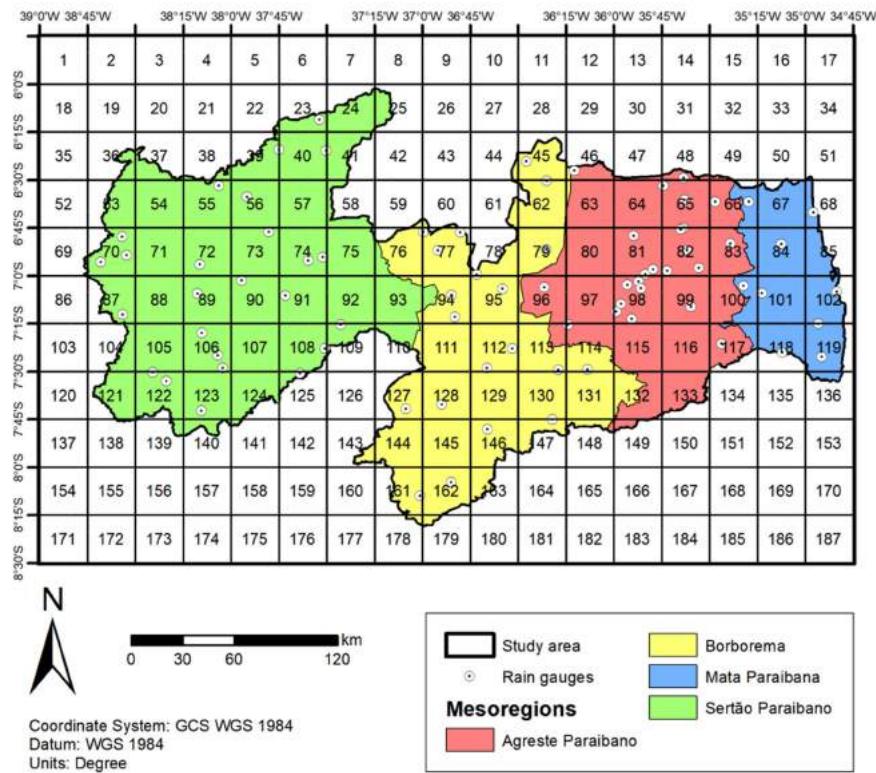


Figura 4 – Distribuição espacial da grade TRMM e dos postos pluviométricos utilizados sobre o estado da Paraíba.

4.3 STANDARDIZED PRECIPITATION INDEX (SPI)

4.3.1. METODOLOGIA DE CÁLCULO

Neste estudo, o monitoramento das secas e de suas características ao longo do período de 1998 a 2017 foi realizado através da aplicação do índice SPI. O cálculo do SPI foi baseado na adequação dos dados de chuva a uma distribuição gama de dois parâmetros α e β e foram utilizados oito diferentes índices para realizar o monitoramento das secas em múltiplas escalas temporais, sendo eles o SPI-1, SPI-3 e SPI-6 para caracterizar as secas de curto prazo, SPI-9 e SPI-12 para as secas de médio prazo, e SPI-18, SPI-24 e SPI-48 para as secas de longo prazo. O período utilizado para cálculo do SPI foi de janeiro de 1998 a dezembro de 2017 e todos os valores SPI de cada escala temporal e das séries disponíveis, i.e., 78 estações da AESA e as 187 quadrículas do TRMM, foram computados.

Além disso, foram utilizadas quatro diferentes classes de severidade para classificar os eventos secos e úmidos, tal que os secos são aqueles que cujos valores SPI são menores ou iguais a zero e os eventos úmidos apresentam SPI maior que zero. As classificações relativas

a severidade dos eventos variaram conforme o valor do SPI, i.e., eventos suaves ($0.0 < |\text{SPI}| \leq 1.0$), eventos moderados ($1.0 < |\text{SPI}| \leq 1.5$), eventos severos ($1.5 < |\text{SPI}| \leq 2.0$) e eventos extremos ($2.0 < |\text{SPI}|$) (Santos *et al.*, 2017). Para ilustrar como foi feito o cálculo do índice, o exemplo será baseado no cálculo do SPI-1 do mês de abril, mas a técnica se aplica aos outros índices SPI e meses. A Figura 5 mostra as etapas de cálculo para cálculo de uma série SPI.

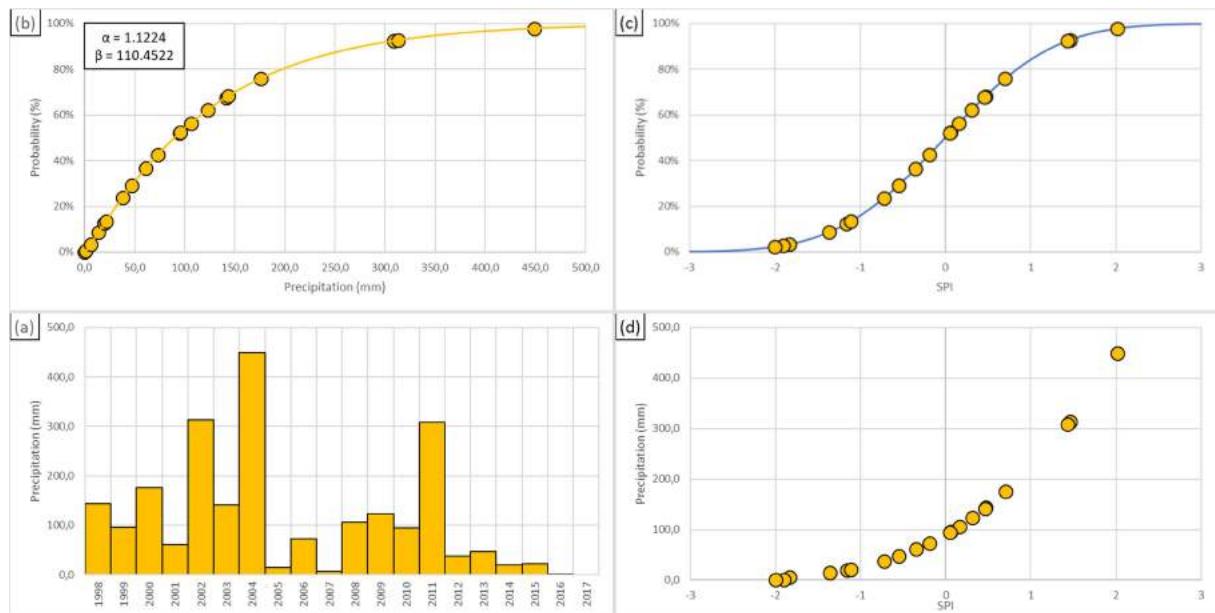


Figura 5 – (a) Histograma utilizado para o cálculo do SPI-1 do mês de abril, (b) adequação da série pluviométrica conforme uma distribuição gama $H(x)$, (c) padronização dos valores de $H(x)$ conforme uma distribuição normal $N(0,1)$ e (d) relação entre os valores de precipitação e de SPI.

De modo específico, o SPI-1 de abril de um determinado ano, por exemplo, compara a precipitação total de abril desse ano com as precipitações totais de cada abril de todos os anos, e então, classifica-se o determinado evento como seco ou úmido. De forma genérica, o índice SPI-X do mês Y compara a precipitação acumulada do período de X meses antecedentes ao mês Y, incluindo o mês Y, de determinado ano, com os acumulados de chuva do mesmo período. Logo, definida a escala temporal (SPI-1) e o mês avaliado (abril), a Figura 5a mostra o hietograma da precipitação acumulada do mês de abril de cada um dos 20 anos avaliados. Em abril de 2004, por exemplo, houve o maior acumulado de todos os anos e por isso é de se esperar que esse seja o evento categorizado como o mais úmido de toda a série.

Em contrapartida, a precipitação acumulada no mês de abril foi quase nula em 2017 e, portanto, ao ser comparada com as precipitações acumuladas do mês de abril dos demais anos, estima-se que esse seja o ano mais seco da série. Assim, ao tratar da análise do SPI-1 de

abril, toda série histórica mostrada na Figura 5a só considera o acumulado da precipitação do mês de abril de cada ano, mas caso o SPI-3 estivesse sendo analisado, a série utilizada como base de cálculo do índice SPI seria referente à precipitação acumulada dos meses de fevereiro, março e abril de cada um dos 20 anos. Em seguida, a série de precipitação mensal acumulada que foi mostrada na Figura 5a foi adequada a uma distribuição gama conforme mostrado na Equação 1:

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

onde α é o parâmetro de forma, β é o parâmetro escalar, x representa a quantidade total de precipitação e $\Gamma(\alpha)$ representa a função gama. Os parâmetros α e β foram estimados para cada uma das séries pluviométricas disponíveis, para cada diferente escala temporal e para cada mês com base na aproximação de Thom (1958), conforme mostrado nas Equações 2–4:

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (2)$$

$$\beta = \frac{\bar{x}}{\alpha} \quad (3)$$

$$A = \ln(\bar{x}) - \frac{1}{n} \sum_{i=1}^n \ln(x_i) \quad (4)$$

onde A é uma medida de assimetria de distribuição, \bar{x} é a precipitação média do período e n é o número de observações de precipitação. Com os parâmetros α e β , realizou-se o cálculo da probabilidade cumulativa $G(x)$ de um evento de precipitação para um determinado período e escala temporal conforme a Equação 5:

$$G(x) = \int_0^x g(x) dx = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^x x^{\alpha-1} e^{-x/\beta} dx \quad (5)$$

A Figura 5b mostra a etapa de adequação dos dados pluviométricos à distribuição gama cumulativa. Com os parâmetros α e β , a linha laranja mostra a probabilidade cumulativa $G(x)$ ajustada aos eventos de precipitação (Equação 5) e os pontos são os eventos de chuva acumulada de abril de cada ano (Figura 5a) adequados conforme a distribuição gama definida. No ano de 2004, por exemplo, a precipitação acumulada do mês de abril foi de mais de 400 mm e isso representou uma probabilidade cumulativa de quase 100%, resultado que mostra o quanto raro foi esse evento frente aos outros 19 ocorridos. Todavia, é válido destacar que a

distribuição gama não é definida para precipitações nulas e por isso, é realizada a adequação da Equação 5, de modo que uma probabilidade cumulativa ajustada $H(x)$ passe a considerar os eventos de precipitação nula, conforme a Equação 6:

$$H(x) = q + (1 - q)G(x) \quad (6)$$

onde q representa a probabilidade de eventos de precipitação nula dentre os avaliados no cálculo do índice SPI de determinada série (Figura 5a). De modo simples, considerando m a quantidade de eventos dentro do período avaliado cuja a precipitação foi igual a zero, o valor de q pode ser estimado pela razão entre m e n . No caso do exemplo, a precipitação acumulada no mês de abril não foi nula em nenhum dos anos e por isso essa etapa não foi necessária. Por fim, na etapa de padronização é feita a transformação dos valores de $H(x)$ em uma variável padrão, que é o próprio valor do SPI e que obedece a uma distribuição normal de média zero e desvio-padrão um. Neste trabalho, a conversão utilizada foi a sugerida por Abramowitz e Stegun (1965) e computada conforme as Equações 7–8:

$$SPI = - \left[t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \text{ e } t = \sqrt{\ln\left(\frac{1}{(H(x))^2}\right)}, \text{ para } 0,0 < H(x) \leq 0,5 \quad (7)$$

$$SPI = + \left[t - \frac{c_0 + c_1 t + c_2 t^2}{1 + d_1 t + d_2 t^2 + d_3 t^3} \right] \text{ e } t = \sqrt{\ln\left(\frac{1}{(1 - H(x))^2}\right)}, \text{ para } 0,5 < H(x) \leq 1,0 \quad (8)$$

onde $c_0 = 2,515517$, $c_1 = 0,802853$, $c_2 = 0,010328$, $d_1 = 1,432788$, $d_2 = 0,189269$ e $d_3 = 0,001308$.

A Figura 5c mostra a padronização dos valores $H(x)$ à distribuição normal com média zero e desvio-padrão um. A linha azul mostra a probabilidade cumulativa de distribuição normal $N(0,1)$ e os marcadores mostram os valores de $H(x)$ padronizados conforme essa nova distribuição. Assim, percebe-se que os valores SPI são calculados através de uma adequação de equiprobabilidade entre a distribuição gama cumulativa $H(x)$ e a distribuição Gaussiana, i.e., os eventos de chuva de $H(x)$ que tem certa probabilidade cumulativa gama são ajustados a valores padronizados regidos pela distribuição $N(0,1)$ e possuem a mesma probabilidade cumulativa. A Figura 5d mostra a relação entre a precipitação acumulada de todos os meses de abril e os valores de SPI-1 calculados, de modo que para cada valor de precipitação, há um valor equivalente de SPI.

Em 2004, o valor do SPI-1 foi maior que 2 e indica que esse evento foi extremamente úmido se comparado aos demais, mas por outro lado, quando a precipitação foi quase nula em

2017, o valor do SPI foi menor que $-1,5$, o que indica que esse evento foi severamente seco se comparado aos demais eventos ocorridos. De fato, esses resultados já eram esperados pois esses eram os eventos mais extremos da série analisada, sendo o primeiro o mais úmido e o segundo, o mais seco (Figura 5a). Neste trabalho, todos os valores de SPI para cada uma das oito escalas temporais e cada uma das séries disponíveis foram calculados. Para o SPI-1, foram computados 240 valores ($20\text{ anos} \times 12\text{ meses}$) de cada uma das 78 séries de chuva dos postos pluviométricos e de cada uma das 187 séries TRMM disponíveis, totalizando mais do que 60.000 dados apenas para essa escala (SPI-1). Mais detalhes quanto ao cálculo do índice SPI podem ser encontrados em Santos *et al.* (2017).

4.3.2. RUN THEORY E CARACTERIZAÇÃO DOS EVENTOS DE SECA

De posse das séries de dados SPI, foram utilizadas grandezas da literatura para realizar a caracterização dos eventos de secas sobre o estado da Paraíba. Neste trabalho, assumiu-se que um evento de seca é caracterizado pelo período em que há continuidade de SPI com valores que são negativos ou iguais a zero, i.e., de eventos secos, e a partir dessa premissa de *Run Theory* (Yevjevich, 1967), foi realizada a caracterização de cada um dos eventos quanto a sua duração, severidade, intensidade, frequência e percentual de área atingida. A compreensão dessas características é de suma importância para o desenvolvimento de análises de risco das secas e para aumentar o entendimento a respeito desse fenômeno danoso à população. Logo, a Figura 6 ilustra três eventos de seca distintos e suas principais características.

A duração (DD) de um evento de seca representa o número de meses entre o período de início e o período de fim da continuidade dos valores de SPI negativos ou iguais a zero ao longo da série. Assim, a duração média (MDD) dos eventos foi calculada para cada uma das séries de chuva e representa a razão entre o somatório da duração de todos os eventos de seca pela quantidade de eventos de seca N existentes, conforme a Equação 9. Da Figura 6, percebe-se que existem três eventos com durações de cinco, três e sete meses, respectivamente, e assim, conclui-se que a duração média para foi de cinco meses. A Figura 6 ainda expressa a série histórica de duração (DDS) de seca, cujos valores são zero quando $\text{SPI} > 0$ e aumentam unitariamente ao decorrer do evento de seca.

$$MDD = \frac{\sum_{i=1}^N DD_i}{N} \quad (9)$$

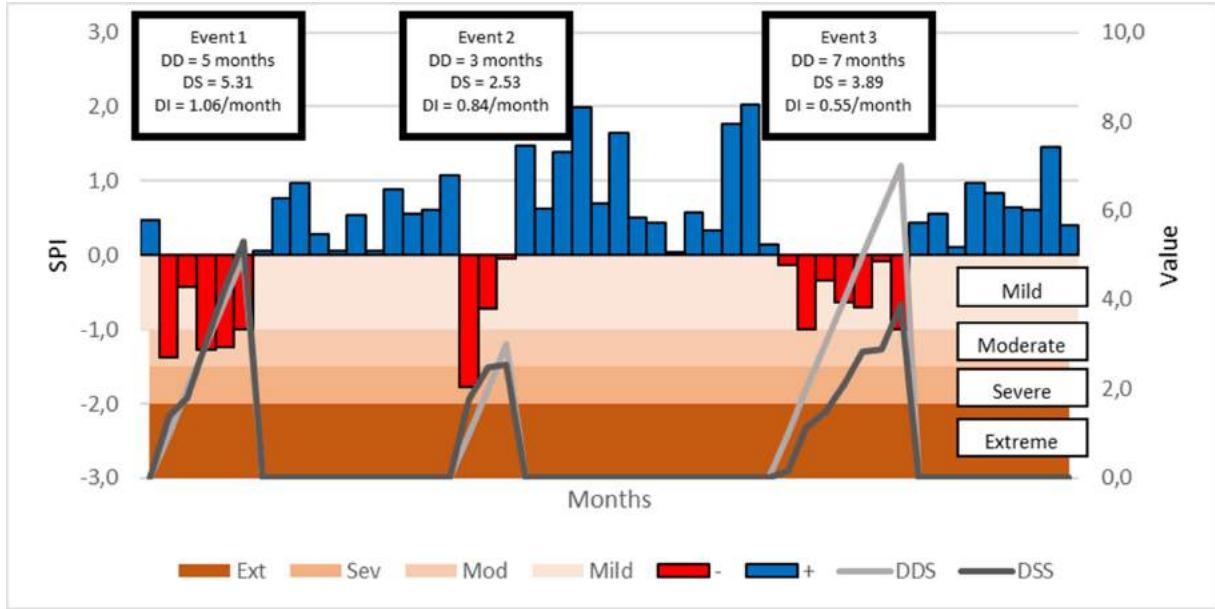


Figura 6 – Definição de um evento de seca e suas principais características.

A severidade (DS) de um evento é o acumulado dos valores SPI ao longo da duração de cada evento e a severidade média (MDS) é a razão entre o somatório da severidade de cada evento de seca pela quantidade de eventos N existentes, conforme a Equação 10. Da Figura 6, nota-se que os três eventos de seca diferem quanto a sua severidade e que o mais duradouro não é, necessariamente, o mais severo: o terceiro evento é o mais longo dentre os três, mas é menos severo que o primeiro. Da Figura 6, é possível notar a série de severidade (DSS) de seca, cujos valores SPI são somados continuamente ao decorrer da duração de cada evento e zeram quando $SPI > 0$. A severidade média dos três eventos de seca mostrados na Figura 6 é de 3,91.

$$MDS = \frac{\sum_{i=1}^N DS_i}{N}, DS = - \sum_{i=1}^{DD} SPI_i \quad (10)$$

Já a intensidade (DI) de cada evento de seca é calculada pela razão entre a severidade de cada evento e sua duração. De modo análogo ao cálculo da duração e da severidade média, a intensidade média (MDI) dos eventos representa a razão entre o somatório da intensidade dos eventos pela quantidade de eventos N (Equação 11). A partir da Figura 6, percebe-se que o primeiro evento é o mais intenso dentre os três, seguido do segundo e do terceiro. Todavia, nota-se que não necessariamente o evento mais intenso é o mais ou menos duradouro, nem o mais ou menos severo, e isso está relacionado ao fato de que a intensidade é uma relação entre

a severidade e a duração. No caso, a intensidade média dessa série é de 0,82, fruto da média da intensidade do primeiro (1,06/mês), segundo (0,84/mês) e terceiro evento (0,55/mês).

$$MDI = \frac{\sum_{i=1}^N DI_i}{N}, DI = \frac{\sum_{i=1}^{DD} SPI_i}{DD} \quad (11)$$

Além da duração, severidade e intensidade média dos eventos de seca, a frequência com que os eventos secos atingiram a região também foi avaliada. Desse modo, utilizando as classes de severidade, e.g., eventos suaves, moderados, severos e extremos, a frequência (DF) dos eventos foi calculada pela razão entre o número de vezes em que houve um evento seco de determinado tipo (f) pela quantidade de eventos secos e úmidos existentes (F) (Equação 12). A partir da Figura 6, nota-se que ao longo dos 50 eventos, apenas 15 foram eventos secos ($SPI \leq 0$), o que faz com o que o DF para os eventos secos seja de 30% (15/50). Entretanto, a análise de frequência desenvolvida também considerou as diferentes categorias de severidade e nesse sentido, a frequência para os eventos extremos, severos, moderados e suaves foi de 0/50, 1/50, 6/50 e 8/50, respectivamente.

$$DF = \frac{f}{F} \quad (12)$$

Por fim, para avaliar o potencial extensivo das secas em termos territoriais ao longo dos anos, foram estimadas as áreas de influência de cada uma das estações pluviométricas e de cada uma das séries TRMM disponíveis sobre o estado da Paraíba utilizando o método dos polígonos de Thiessen. Com essas áreas, o percentual de área atingida (DA) pelos eventos secos foi calculado para cada mês e é a razão entre a área atingida (a), onde ocorreram os eventos secos, e a área total disponível (A), que é a área total do estado (Equação 13).

$$DA = \frac{a}{A} \quad (13)$$

Neste trabalho, a duração, a severidade, a intensidade, a frequência e o percentual de área atingida por eventos secos foram computadas para cada série pluviométrica (78 postos e 187 *grids* TRMM) e para cada escala temporal (SPI-1, SPI-3, SPI-6, SPI-9, SPI-12, SPI-18, SPI-24 e SPI-48), possibilitando a caracterização espacial em várias escalas temporais dos eventos de seca sobre o estado da Paraíba. Além da análise pontual desenvolvida para cada uma das séries, análises por mesorregiões utilizando as duas bases de dados também foram realizadas a partir do cálculo da média ponderada das características analisadas com base nas áreas de influência utilizando os polígonos de Thiessen.

Por fim, é importante destacar que até o presente momento não se tem conhecimento de pesquisas que tenham avaliado diferentes características das secas em múltiplas escalas temporais sobre o estado da Paraíba de modo detalhado como proposto por este trabalho, nem tão pouco estudos que avaliaram diferentes características das secas mediante a utilização das estimativas de precipitação de sensoriamento remoto. Conclui-se que o desenvolvimento das análises propostas neste trabalho será de suma importância para realizar o monitoramento das secas sobre essa região de maneira contínua e sistemática, o que realça não só a utilidade desta pesquisa como também seu caráter inédito no meio científico a nível regional.

4.4. ANÁLISE DE TENDÊNCIAS

Neste trabalho, foram desenvolvidas análises para avaliar a existência de tendências nas séries de secas de curto, médio e longo prazo e determinar suas magnitudes. Desse modo, três tipos de séries que refletem importantes características das secas foram avaliados e dois testes não paramétricos foram escolhidos para realizar a análise de tendências dessas séries. As tendências das séries históricas de comportamento (SPI), duração (DDS) e severidade (DSS) (Figura 6) foram avaliadas com base nos testes de Mann-Kendall e Sen, tendo sido o primeiro teste utilizado para identificar a existência de tendência estatisticamente significante e o segundo foi empregado para estimar a magnitude linear dessas tendências. Primeiramente, o teste de Mann-Kendall (Mann, 1945; Kendall, 1975), é aplicável em casos em que a série pode se comportar conforme a Equação 14:

$$x_i = f(t_i) + \varepsilon_i \quad (14)$$

onde x_i são os dados da série, $f(t_i)$ é uma função monotônica contínua crescente/decrescente que varia ao longo do tempo e ε_i são os resíduos, componentes da distribuição dos dados x_i , mas com média da distribuição equivalente a zero. No geral, para identificar se há ou não uma tendência estatisticamente significante, o método proposto por Mann-Kendall se baseia na comparação do teste da hipótese nula H_0 , de que não há tendência, contra a hipótese não nula H_1 , de que há tendência positiva ou negativa na série de dados. Para computar a existência dessa tendência, o teste de Mann-Kendall considera a sequência de valores da série analisada. Desse modo, ao comparar os valores sequenciais da série, calcula-se a estatística S , tal como mostrado na Equação 15:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n sgn(x_j - x_k), \text{ e } sgn(x_j - x_k) = \begin{cases} +1, & \text{se } (x_j - x_k) > 0 \\ 0, & \text{se } (x_j - x_k) = 0 \\ -1, & \text{se } (x_j - x_k) < 0 \end{cases} \quad (15)$$

onde n representa o tamanho da série e x_j e x_k são os valores sequenciais j e k da série ($j > k$). Através dessa comparação, conclui-se que caso S seja maior do que zero, há indícios que a série tenha tendência positiva e caso S seja menor do que zero, há indícios de que a tendência da série seja negativa. 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 e Kendall (Gilbert, 1987). Por outro lado, caso a quantidade de dados seja maior que nove, utiliza-se a estatística Z_S para preencher essa lacuna conforme mostrado na Equação 16:

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

$$VAR(S) = \frac{1}{18} [n(n-1)(2n+5) - \sum_{p=1}^q t_p(t_p-1)(2t_p+5)] \quad (17)$$

onde n representa o tamanho da série, t_p representa o número de pontos de determinado grupo p e q representa o número de grupos. Avaliar se a tendência de determinada série temporal é importante para garantir embasamento estatístico dos resultados, e por tal motivo, a tendência de uma série temporal deve ser testada a um nível de significância específico. Nesse caso, se a tendência de uma série é significativa a um nível de significância α de 0,01, por exemplo, isso implica que há 99% de certeza ao rejeitar a hipótese nula H_0 , o que faz com que a existência dessa tendência, seja ela positiva ou negativa, seja muito provável.

Para avaliar se a tendência de uma série é estatisticamente significante a determinado nível de significância α , assume-se que a hipótese nula H_0 é rejeitada quando $|Z_S|$ é superior a $|Z_{1-\alpha/2}|$, onde $Z_{1-\alpha/2}$ é obtido através das tabelas de distribuição estatística. Para α igual a 0,05, o valor de $Z_{1-\alpha/2}$ é igual a 1,96 e portanto, caso o valor de Z_S seja superior a 1,96, a hipótese nula é rejeitada e se admite que a série tem tendência, sendo ela positiva caso Z_S seja positivo e negativa quando Z_S for negativo. Quando α é igual a 0,10, o valor de $Z_{1-\alpha/2}$ passa a ser 1,28 e por tal motivo, ao considerar que é mais fácil que $|Z_S| > 1.28$ do que $|Z_S| > 1.96$, fica provado

que quanto maior o nível de significância, menor será a confiança do teste e mais fácil é de se cometer um erro ao rejeitar a hipótese nula.

Verificada a existência da tendência significante ou não, o teste não paramétrico de Sen foi empregado para computar a magnitude dessas tendências. Ao utilizar um modelo linear para estimar a declividade das tendências, o teste de Sen traz várias vantagens com sua aplicação, já que esse teste não é afetado por erros, valores extremos ou ausentes. O teste de Sen foi usado para identificar a mudança dos valores analisados conforme a escala definida, e a tendência $f(t)$ se comporta conforme a Equação 18:

$$f(t) = Qt + B \quad (18)$$

onde Q representa a declividade da linha de tendência, t representa o tempo ao decorrer da série temporal e B representa a constante. As declividades de todos os pares de valores x_j e x_k , onde $j > k$ são calculados conforme a Equação 19. A declividade Q é a mediana dos valores de Q_i :

$$Q_i = \frac{x_j - x_k}{j - k} \quad (19)$$

Conforme discutido anteriormente, três diferentes tipos de séries foram avaliados neste trabalho, sendo elas: (a) a série de comportamento, composta pelos valores do SPI, (b) série de duração (DDS), composta pelos valores de duração de cada evento de seca, e (c) a série de severidade (DSS), constituída pelos valores de severidade de cada evento. Assim, a série de comportamento das secas é composta por 50 valores que variam de -3 a 3 , a série de duração DDS é composta pelos valores de duração (i.e., 5, 3 e 7 meses) e a série de severidade DSS é composta pelos três valores de severidade (i.e., 5,31, 2,53 e 3,89). Dessa forma, nota-se que a variação da série de comportamento que é estimada pelo teste de Sen é a cada mês, enquanto que para as séries de duração e de severidade a variação é dada por eventos.

Para as séries de comportamento, tendências negativas caracterizam o pior cenário possível, indicando que os valores de SPI tendem a ser mais negativos ao decorrer do tempo, enquanto que para as séries de duração e severidade das secas, tendências positivas apontam o pior cenário, indicando que os eventos de seca tendem a ser mais duradouros e severos ao longo do tempo. Foram utilizados três diferentes níveis de significância α (i.e., 0,01, 0,05 e 0,10) e foram realizadas análises pontuais e por mesorregiões considerando os dados advindos dos pluviômetros e das grades TRMM. Desse modo, mais de 6.000 análises de tendências foram desenvolvidas considerando todas as combinações possíveis (265 séries \times 8 índices SPI

$\times 3$ características) e mais detalhes quanto os testes de Mann Kendall e Sen podem ser encontrados em Santos *et al.* (2018) e Santos *et al.* (2019b).

A aplicação integrada dos testes de Mann-Kendall e de Sen para análises de séries temporais é uma prática comum na literatura em se tratando aos estudos envolvendo secas. Entretanto, é válido pontuar que na maioria dos casos só as séries de comportamento são avaliadas enquanto que as tendências da duração e severidade das secas são suprimidas. Até o presente momento, não se tem conhecimento de estudos que tenham avaliado as tendências de diferentes características das secas em múltiplas escalas temporais sobre o estado da Paraíba e nem feito isso utilizando estimativas de precipitação. Conclui-se, portanto, que os resultados a serem obtidos neste trabalho contribuirão para aumentar a compreensão acerca das secas, suas características e suas tendências, o que realça não só sua utilidade como seu caráter inédito.

4.5. ANÁLISE DE AGRUPAMENTO

Neste trabalho, foram utilizadas técnicas de análise de *cluster* hierárquica para zonear o estado da Paraíba em diferentes regiões homogêneas com base no comportamento das secas e de suas características. Para tanto, foram utilizados três tipos de séries de secas, sendo elas as séries de comportamento (SPI), de duração (DDS) e de severidade (DSS) das secas. Cabe destacar que as séries de duração e severidade não são compostas por apenas três valores cada, como foi no caso do exemplo anterior. Na análise de *clusters* hierárquica, as séries de duração e severidade têm 50 dados cada (Figura 6), tal que a DDS incrementa unitariamente ao decorrer de um evento de seca, a DSS resulta do acumulado dos valores de SPI ao decorrer do evento de seca e em ambos os casos o valor nulo é atribuído às séries quando os eventos secos ($SPI \leq 0$) deixam de ocorrer. A série de comportamento das secas permanece inalterada e é composta pelos 50 valores de SPI (Figura 6).

Como as secas são fenômenos naturais com elevado potencial extensivo, é apropriado avaliar seu comportamento e suas características em uma perspectiva regional, o que faz com que a análise de *cluster* hierárquica seja adequada ao objetivo deste estudo. No entanto, é válido pontuar que o propósito deste trabalho não é identificar o melhor algoritmo de análise de *clusters*, nem o melhor método de ligação entre os *clusters* ou a métrica de dissimilaridade mais adequada. O objetivo é desenvolver uma análise de agrupamento espacial com base no comportamento, duração e severidade das secas de curto, médio e longo prazo sobre o estado da Paraíba, e assim, avaliar se os resultados obtidos a partir da utilização dos dados oriundos

de pluviômetros e das estimativas do satélite são condizentes entre si, e condizentes com a divisão territorial adotada, i.e., com as quatro diferentes mesorregiões.

De todo modo, por mais que o propósito desta pesquisa não tenha sido desenvolver uma avaliação entre os diferentes algoritmos de agrupamento, a decisão das etapas básicas da análise de *clusters* hierárquicas como escolha da métrica de dissimilaridade, do método de ligação entre os *clusters* e do número ótimo de *clusters* (Keller Filho *et al.*, 2005) foi tomada a partir de critérios estatísticos, o que garante confiabilidade dos resultados e evita erros de subjetividade dos pesquisadores. As análises foram realizadas para as oito escalas temporais e consideraram os dados de chuva de pluviômetros e as estimativas de precipitação do satélite TRMM, resultando no desenvolvimento de 48 análises de agrupamento hierárquico distintas (2 bases de dados × 3 tipos de séries × 8 escalas temporais).

Em relação à métrica de dissimilaridade, como um dos objetivos foi regionalizar a estado da Paraíba em diferentes zonas homogêneas, o coeficiente de correlação entre as séries de secas se mostrou a métrica mais adequada a ser utilizada, tendo em vista que através dessa métrica as diferentes séries são agrupadas com base na similaridade do seu comportamento ao decorrer do tempo e não com base nas suas médias ou quaisquer que sejam as outras métricas. A partir dessa métrica, pode-se avaliar o quanto similar as séries de comportamento, duração (DDS) e severidade (DSS) das secas em múltiplas escalas temporais são ao longo do tempo, e essa informação é importante para avaliar padrões de similaridade como a influência dos sistemas climáticos atuantes na região, por exemplo.

Destaca-se que o mesmo foi desenvolvido por Santos *et al.* (2019a), que regionalizou o estado da Paraíba em zonas com comportamento de precipitação similares. Neste trabalho, a diferença é que estão sendo utilizadas três séries distintas, mas a ideia do agrupamento é semelhante. A Equação 20 mostra o como foi feito o cálculo da distância de correlação entre duas séries distintas e desse modo, para cada base de dados, para cada escala temporal e para cada diferente série de seca foram calculadas as distâncias existentes entre todos os pares de séries:

$$d = d(x_s, x_t) = 1 - \frac{\sum_{i=1}^n (x_s - \bar{x}_s)(x_t - \bar{x}_t)}{\sqrt{\sum_{i=1}^n (x_s - \bar{x}_s)^2} \sqrt{\sum_{i=1}^n (x_t - \bar{x}_t)^2}} \quad (20)$$

onde d é a distância de correlação entre duas séries x_s e x_t , \bar{x}_s e \bar{x}_t representam as médias das séries históricas x_s e x_t que contém n dados. Em seguida, buscou-se definir qual o método de ligação mais adequado entre os *clusters* e para tanto, utilizaram-se três tipos, sendo o *single*, o

complete e o *average*. Para auxiliar a escolha, o coeficiente de correlação cofenética, métrica empregada para avaliar a consistência e a similaridade de representatividade entre os *clusters*, foi computado. Esse coeficiente mensura quão adequada foi a escolha do par método-métrica para realizar a análise de *clusters* dos dados e seu cálculo foi realizado de acordo com a Equação 21:

$$c = \frac{\sum_{i=1}^j (x(i,j) - \bar{x})(t(i,j) - \bar{t})}{\sqrt{\sum_{i=1}^j (x(i,j) - \bar{x})^2 \sum_{i=1}^j (t(i,j) - \bar{t})^2}} \quad (21)$$

onde $x_{(i,j)}$ é a distância entre as séries i e j com base na métrica de dissimilaridade escolhida e $t_{(i,j)}$ é a distância dendrogrâmica entre as séries i e j com base no método escolhido. Nesse caso, quanto mais próximo de 1 for o valor desse coeficiente, mais adequada foi a escolha da métrica de dissimilaridade e do método de ligação. Foram avaliados três métodos de ligação distintos, sendo eles o *single* (Equação 22), o *complete* (Equação 23) e o *average* (Equação 24). A diferença entre eles é que para o método de *single* considera-se como distância entre os *clusters* a menor distância entre os componentes, para o método de *complete*, considera-se a maior distância entre os componentes de *clusters* distintos e para o método *average*, é a média das distâncias entre as séries do *cluster r* com o *cluster s* que são consideradas. A Figura 1b ilustra a diferença entre o cálculo das distâncias entre dois *clusters* distintos.

$$D(r,s) = \min(d(x_{ri}, x_{sj})) \quad (22)$$

$$D(r,s) = \max(d(x_{ri}, x_{sj})) \quad (23)$$

$$D(r,s) = \frac{1}{n_r n_s} \sum_{i=1}^{n_r} \sum_{j=1}^{n_s} d(x_{ri}, x_{sj}) \quad (24)$$

Onde $D(r,s)$ é a distância entre os *clusters* r e s , n_r é o número de componentes do *cluster r*, n_s é o número de elementos do *cluster s*, d representa a métrica de dissimilaridade entre as séries x_r e x_s , x_{ri} é o componente i do *cluster r*, e x_{sj} é o elemento j do *cluster s*. A partir da Figura 1b, pode-se perceber que ao considerar que cada seta representa a distância entre um componente e o outro, a distância entre os *clusters* r e s é uma medida que varia de acordo com o método de ligação definido.

O último passo é definir a quantidade de *clusters* a serem utilizados para realizar uma regionalização satisfatória e essa tarefa é um processo crucial no processo de agrupamento e tem grande complexidade. Por tal motivo, essa escolha não é definida por um simples critério

universal e objetivo (McGree *et al.*, 2016). Diante disso, alguns pesquisadores admitem que a escolha do número ótimo de *clusters* deve ser equivalente a um décimo da quantidade total de elementos e outros afirmam que essa escolha deve se basear na variação da distância entre os *clusters* e a quantidade de *clusters* (Li *et al.*, 2015). Neste trabalho, foram utilizados diferentes métodos para definir esse número, sendo eles o método das silhuetas (Rousseeuw, 1987), o critério de Calinski-Harabasz (Calinski e Harabasz, 1974) e o método que se baseia na curva de variação da distância entre os *clusters* por sua quantidade.

A curva de variação da distância entre *clusters* pelo número de *clusters* foi o primeiro método avaliado para definir o número de *clusters*. Para tanto, admitiu-se que a quantidade ótima é equivalente ao número de grupos em que a curva de variação mantivesse constância. A ideia de adotar esse critério pelo qual o número ótimo de *clusters* deve ser definido quando a derivada da curva for praticamente nula é que não há sentido em dividir as séries em vários *clusters* caso a variação entre esses *clusters* não seja tão significativa. Apesar de possível, não é vantajoso agrupar os elementos em vários *clusters* caso não haja alguma funcionalidade para a análise dos resultados e, por isso, essa escolha não pode ser dependente da quantidade de elementos existentes.

Em seguida, empregou-se o método das silhuetas para escolher o número ótimo de *clusters*. No geral, o método das silhuetas mensura o quanto similar as séries de determinado *cluster* são em relação ao *cluster* de origem quando comparado com séries de outros *clusters* (Equação 25). Os valores para o método das silhuetas variam de -1 a 1 e o melhor resultado é obtido quando o valor assumido é 1, que indica que os elementos se comportaram do modo mais similar possível ao seu *cluster* de origem e do modo mais dissimilar aos demais *clusters* que compõem a análise.

$$S_i = \frac{(b_i - a_i)}{\max(a_i, b_i)} \quad (25)$$

Onde S_i é o valor da silhueta da série i , a_i é distância média da série i às outras séries do *cluster* de origem e b_i é a distância da série i às outras séries que compõem os demais *clusters*. O valor final da silhueta é o valor médio dentre as séries. O critério de Calinski-Harabasz, por sua vez, expressa a razão entre a variância entre os diferentes *clusters* e a variância dentre os diferentes *clusters* (Equação 26). No geral, com base nesse critério, *clusters* bem definidos apresentam alta variância entre os diferentes *clusters* e pequena variância dentre os *clusters* e

por isso, é de se esperar que no caso da razão CH , quanto maior for o valor, mais adequada foi a análise de agrupamento desenvolvida e melhor foi a solução encontrada.

$$CH = \frac{SS_b}{SS_w} \times \frac{(N - k)}{(k - 1)} \quad (26)$$

Onde SS_b é a variância entre os *clusters*, SS_w é a variância dentro dos *clusters*, N é o número de séries analisadas e k é a quantidade de *clusters*. Apesar da importância de analisar o regime de similaridade entre as regiões quanto aos recursos naturais, nota-se que estudos referentes às secas e suas características ainda precisam ser desenvolvidos para garantir maior compreensão sobre esse fenômeno. Até o presente momento, não se tem conhecimento de estudos que tenham empregado a análise de *cluster* com base no comportamento, duração e severidade das secas em múltiplas escalas temporais sobre o estado da Paraíba e nem feito através de dados estimados por satélites de sensoriamento remoto. Fatos como esse realçam a importância do trabalho e seu caráter inédito na literatura, e por tal motivo, espera-se que os resultados sejam de elevado valor para essa linha de pesquisa.

4.6. ANÁLISE DE ACURÁCIA ESTATÍSTICA

A acurácia das estimativas do satélite TRMM em captar o comportamento das secas de curto, médio e longo prazo foi avaliada através do cálculo de diferentes métricas. Nesse caso, é válido pontuar que vários métodos podem ser utilizados para comparar as séries SPI calculadas a partir das estimativas de precipitação em forma de grade do satélite com as séries SPI calculadas a partir dos dados pontuais. Uma das alternativas para desempenho da tarefa é (a) realizar a interpolação dos dados pontuais para o centroide das grades (Fensterseifer *et al.*, 2011; Pereira *et al.*, 2013; Jiang *et al.*, 2017; Lelis *et al.*, 2018; Satgé *et al.*, 2019) ou ao contrário, ao realizar a interpolação do centro dos pontos grade para o local dos pluviômetros (Soares *et al.*, 2016; Ren *et al.*, 2018); em outros casos, pode-se (b) realizar a comparação da série em *grid* com a série média dos postos inseridos dentro dos limites dessa grade (Santos *et al.*, 2019b) ou realizar a comparação da série do pluviômetro com a série média dos pixels mais próximos (Cao *et al.*, 2018; Cruz *et al.*, 2018).

A partir do primeiro método (a), nota-se que a mudança na técnica de interpolação é capaz de influenciar o valor das séries sintéticas interpoladas para o determinado referencial. Ao utilizar o método *spline* para interpolar os dados SPI dos pluviômetros para o centro das grades TRMM, por exemplo, espera-se que seja obtido um resultado e uma série SPI sintética

diferente da obtida caso o método IDW (*Inverse Distance Weighting*) tivesse sido utilizado. É importante notar que esse método comparativo abre margem para subjetividade e distorção dos resultados, tendo vista que a alteração na escolha do método de interpolação empregado pelo pesquisador influencia no produto final.

O segundo método (b), apesar de constituir uma alternativa viável para desempenho da análise comparativa, não foi considerado adequado para o estudo. O motivo é que, conforme dito previamente, só existem 78 pluviômetros com séries de dados completas sobre o estado da Paraíba e por isso, existem grades TRMM que não contém postos dentre os seus limites. Por tal motivo, conclui-se que a irregularidade espacial das estações sobre a região inviabiliza a comparação das medições pontuais dessas estações com as estimativas em grid do satélite TRMM através desse método. Todavia, vale destacar que cada metodologia apresenta suas vantagens e limitações, principalmente em se tratando do monitoramento do SPI, índice que só se baseia em dados de precipitação, fenômeno de alta variabilidade espaço-temporal.

No intuito de evitar erros e inconsistências causadas por diferentes fatores, o método comparativo adotado foi o seguinte: caso um posto pluviométrico estivesse localizado dentro dos limites de determinado *grid* TRMM, a série histórica dessa estação seria comparada com a série do respectivo *grid*. Assim, para cada escala temporal, compararam-se as 78 séries pontuais distribuídas sobre o estado da Paraíba com as respectivas séries dos *grids* aos quais esses pluviômetros estavam inseridos, e para cada métrica, os 78 valores foram calculados e espacializados. É valido ressaltar que vários estudos já foram desenvolvidos com base nesse método comparativo e que os resultados foram consideravelmente satisfatórios (Almeida *et al.*, 2015; Barbosa *et al.*, 2015; Michot *et al.*, 2018; Nogueira *et al.*, 2018; Rozante *et al.*, 2018; Wei *et al.*, 2018; Xu *et al.*, 2019).

Desse modo, foram avaliadas 11 diferentes métricas para cada um dos oito índices SPI, totalizando mais que 600 comparações entre séries (78 séries × 8 escalas temporais) e mais de 6.800 valores espaçados por todo o território. Além disso, cabe destacar que também foram desenvolvidas tanto análises pontuais como por mesorregiões. No caso das análises pontuais, os 78 valores de cada métrica e escala temporal foram computados e espacializados. No caso das análises por mesorregiões, a média ponderada de cada métrica foi calculada a partir dos polígonos de Thiessen traçados conforme a distribuição dos pluviômetros da região, assim como feito por Li *et al.* (2013), Curtarelli *et al.* (2014) e Chen *et al.* (2015).

De modo geral, as métricas utilizadas foram divididas em três diferentes grupos, sendo elas (a) as métricas baseadas no valor do índice SPI ao decorrer do tempo, (b) as métricas baseadas nas diferentes classes de severidade dos eventos úmidos e secos, e (c) as métricas baseadas exclusivamente nos eventos úmidos e secos. No caso do primeiro grupo, os valores que foram utilizados para computar as métricas foram os próprios valores do índice SPI, i.e., os valores que teoricamente variam de -3 a 3 ao decorrer do tempo, e para tanto, foram calculado o coeficiente de correlação de Pearson R , o bias B , o bias relativo RB , o erro médio quadrático e a raiz do erro médio quadrático (Equações 27–31):

$$R(S_{RS}, S_G) = \frac{\sum_{i=1}^n (S_{RS,i} - \bar{S}_{RS})(S_{G,i} - \bar{S}_G)}{\sqrt{\sum_{i=1}^n (S_{RS,i} - \bar{S}_{RS})^2} \sqrt{\sum_{i=1}^n (S_{G,i} - \bar{S}_G)^2}} \quad (27)$$

$$B = \sum_{i=1}^n (S_{RS,i} - S_{G,i}) \quad (28)$$

$$RB = \frac{\sum_{i=1}^n (S_{RS,i} - S_{G,i})}{\sum_1^n (S_{G,i})} \quad (29)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (S_{RS,i} - S_{G,i})^2 \quad (30)$$

$$RMSE = \sqrt{MSE} \quad (31)$$

onde n é a quantidade de dados de cada série, $S_{RS,i}$ são os valores SPI calculados a partir dos dados do TRMM, $S_{G,i}$ são os valores SPI calculados a partir dos dados de pluviômetros e \bar{S}_{RS} e \bar{S}_G são as médias do TRMM e dos pluviômetros. No caso do coeficiente R , valores unitários indicam uma associação linear perfeita entre as séries, sendo essa associação positiva quando R é igual um, e negativa quando R é igual a -1 . Quanto mais próximo de 1 for o valor de R , maior a acurácia do satélite TRMM em captar o comportamento das secas sobre a região. Para as demais métricas, o valor ótimo e que indica maior precisão das estimativas do satélite é 0.

Para o segundo grupo de métricas, as diferentes categorias de severidade dos eventos úmidos e secos foram consideradas e os valores SPI foram reclassificados. Desse modo, os eventos extremamente secos ($SPI < -2$) tiveram classificação CL igual a 1 (CL1), os eventos severamente secos ($-1,5 < SPI \leq -2,0$) receberam a classificação CL igual a 2 (CL2) e assim foi feito sucessivamente até chegar ao CL igual a 8 (CL8) para os eventos extremamente úmidos. Feito o ajuste, o coeficiente de concordância de Kendall (Kd) (Kendall e Smith,

1939) e o índice de concordância kappa (K_p) (Cohen, 1960) foram calculados conforme as Equações 32–34:

$$Kd = \frac{12S}{m^2k(k^2 - 1)} \quad (32)$$

$$R_i = \sum_{j=1}^m CL_{ij}, \bar{R} = \frac{1}{k} \sum_{i=1}^k R_i, S = \sum_{i=1}^k (R_i - \bar{R})^2 \quad (33)$$

$$K_p = \frac{P_O - P_E}{1 - P_E} \quad (34)$$

onde m é a quantidade de bases de dados, k é a quantidade de eventos, CL_{ij} é a classificação do evento i da base de dados j , P_O é concordância relativa observada das classificações CL entre as bases de dados, e P_E é concordância hipotética de probabilidade de chance. No geral, admite-se que o índice kappa é mais rigoroso do que o coeficiente de concordância de Kendall e esse rigor está ligado ao fato de que ainda que um evento seja extremamente seco (CL1) com base nas estimativas TRMM e como severamente seco (CL2) com base nas medições dos pluviômetros, sob o ponto de vista do satélite houve erro a detectar a classe de severidade do evento. Em outras palavras, já que não houve concordância exata do TRMM em identificar o tipo de evento, ainda que essa tenha se aproximado da classificação *in loco*, computa-se essa situação como erro.

Já no cálculo do índice de concordância de Kendall, leva-se em consideração o fato de que ainda que os eventos não tenham sido exatamente iguais, suas categorias são próximas, i.e., CL1 e CL2. Desse modo, o cálculo do Kd assume que o erro cometido ao categorizar um evento CL1 como CL2 é menor do que o erro cometido ao classificar um evento CL1 como CL8 ($SPI > 2$). Os valores de Kd variam de zero a um, sendo 0 adiscordância perfeita entre as bases de dados e 1 a concordância perfeita entre as classificações. Já os valores de Kp , podem ser negativos e podem assumir o valor máximo de 1. Quanto mais próximos de 1 forem os valores de Kd e Kp , melhor é desempenho do TRMM em identificar os tipos de eventos secos e úmidos ao longo do tempo.

Para análise do terceiro grupo de métricas, as séries SPI foram reajustadas e passaram a considerar apenas duas classes de eventos: os eventos úmidos ($SPI > 0$) e os eventos secos ($SPI \leq 0$). Seguindo a lógica de reclassificação dos valores de SPI adotada para o cálculo do Kd e do Kp , mas considerando apenas duas classes de eventos, quatro índices de desempenho

foram avaliados com base em uma tabela de contingência 2×2 (Figura 7). Ao admitir que as séries SPI calculadas a partir das medições de postos são as séries referenciais, o índice de proporção correta (PC), a probabilidade de detecção (POD), o índice de alarme falso (FAR) e o índice de sucesso crítico (CSI) foram avaliados (Equações 35–38):

$$PC = \frac{A + D}{A + B + C + D} \quad (35)$$

$$POD = \frac{A}{A + C} \quad (36)$$

$$FAR = \frac{B}{A + B} \quad (37)$$

$$CSI = \frac{A}{A + B + C} \quad (38)$$

A Figura 7 mostra a tabela de contingência 2×2 utilizada para avaliar os índices, onde A é a quantidade de eventos categorizados como secos a partir dos dados de pluviômetros e das estimativas do TRMM, B é o número de eventos que foram categorizados como úmidos com base nas estimativas de pluviômetros e como secos segundo as estimativas do satélite, C é quantidade de vezes que os eventos foram considerados secos de acordo com as medições dos postos pluviométricos e como úmidos de acordo com os dados do TRMM e D é o número de vezes em que o evento foi categorizado como úmido tanto pelas estimativas do satélite quanto pelas medições das estações. Todas as métricas podem variar de 0 a 1, tal que para o PC , POD e CSI , os valores iguais a 1 indicam perfeita concordância entre as bases de dados, enquanto que no caso do FAR , o valor de 0 indica a situação de melhor acurácia do satélite.

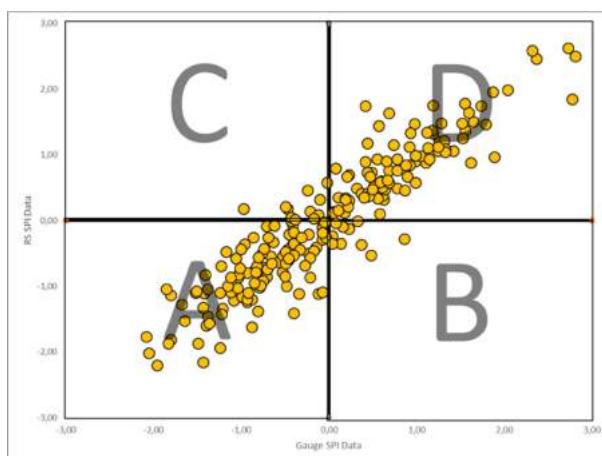


Figura 7 – Tabela de contingência para avaliação de índices de desempenho.

Realizar a análise de acurácia estatística das estimativas de precipitação de satélites de sensoriamento remoto envolve o processo de identificação e quantificação dos erros, passos cruciais para validar a utilização desses dados em vários estudos. No geral, nota-se que apenas os dados de precipitação são avaliados em termos estatísticos, enquanto as análises das secas são mais escassas. Sobre a Paraíba, à exceção do estudo desenvolvido por Brasil Neto *et al.* (2019a), não há conhecimento de outro trabalho que tenha utilizado tantas métricas para avaliar a acurácia estatística do satélite TRMM em captar o regime das secas em múltiplas escalas de tempo. Diante do exposto, espera-se que os resultados a serem obtidos na pesquisa possam contribuir significativamente para definir se as estimativas de precipitação do TRMM podem ser consideradas como uma alternativa viável para monitorar as secas sobre a região.

4.7. ANÁLISE DE RISCO DAS SECAS

Além do processo de caracterização e regionalização das secas, um dos propósitos deste estudo é propor um índice geoespacial capaz de mensurar o risco e a vulnerabilidade de determinada região quanto à ação das secas. No geral, sabe-se que o desenvolvimento de um índice composto envolve a integração de vários parâmetros distintos e que essa temática tem atraído à atenção de diversos estudiosos ao longo dos últimos tempos (Thomas *et al.*, 2016; Ghosh, 2018). Entretanto, apesar de saber da notória importância em avaliar a vulnerabilidade de certa região considerando parâmetros socioeconômicos, energéticos ou naturais, é possível perceber que essas análises requerem um leque de dados confiáveis que na maioria dos casos são ora inexistentes, ora inconsistentes.

Diante dessa problemática, a proposta deste estudo é o NIDS-Trend, um índice de seca geoespacial composto que considera apenas as características das secas. Computado com base em seis diferentes parâmetros obtidos exclusivamente a partir das séries SPI, o NIDS-Trend é um índice padronizado que varia de 0 (baixo risco) a 100 (alto risco) e considera o conjunto de dados distribuídos no espaço, o que realça seu caráter geoespacial. A Tabela 1 mostra os parâmetros utilizados para compor o índice NIDS-Trend e a relação lógica de cada parâmetro, de onde é possível perceber que cada uma das seis variáveis apresenta valores, unidades e relações distintas com o NIDS-Trend. Para a quantidade de eventos de seca, é fácil deduzir que quanto maior for a quantidade de eventos, maior o risco dessa região e maior será o valor do NIDS-Trend.

Por outro lado, para a magnitude da declividade Sen das séries de comportamento da seca, parâmetro com relação negativa com o índice NIDS-Trend, é fácil perceber que quanto mais expressiva e negativa a declividade Sen, mais secos tenderão a ser os eventos e maior será o risco da região à ação das secas. Diante do exposto, conclui-se que o NIDS-Trend é um índice relevante, pois considera tanto parâmetros que caracterizam o risco da região quanto as situações já ocorridas, i.e., número de eventos de seca, intensidade média dos eventos de seca e frequência dos tipos de eventos secos, quanto aos cenários que ainda ocorrerão, i.e., análise de tendências do comportamento dos valores de SPI, da duração e da severidade dos eventos de secas. Além disso, o NIDS-Trend pode ser aplicado em múltiplas escalas temporais, i.e., SPI-1, SPI-3, SPI-6, SPI-9, SPI-12, SPI-18, SPI-24 e SPI-48, fato que garante a caracterização quanto à exposição da região às secas de curto-, médio- e longo-prazo.

Tabela 1 – Parâmetros de seca e suas relações lógicas com o índice NIDS-Trend.

ID	Parâmetro	Consideração lógica	Relação
A	Número de eventos de seca	Maior quantidade, maior risco	+
B	Intensidade média dos eventos de seca	Maior intensidade, maior risco	+
C	DS (Santos <i>et al.</i> , 2019b)	Maior DS, maior risco	+
D	Tendência de comportamento da seca	Maior declividade negativa Sen, maior risco	-
E	Tendência da duração dos eventos	Maior declividade positiva Sen, maior risco	+
F	Tendência da severidade dos eventos	Maior declividade positiva Sen, maior risco	+

Para computar o índice NIDS-Trend e transformá-lo em um índice adimensional, foi feita padronização linear das variáveis a partir da condição lógica entre os parâmetros e o NIDS-Trend. Nesse sentido, Equação 39 foi empregada no caso de existir relação positiva entre o parâmetro j e o índice NIDS-Trend, e a Equação 40 foi utilizada quando a relação foi negativa entre o parâmetro j e o índice NIDS-Trend:

$$X_{ij} = \frac{x_{ij} - \text{Min}(x_j)}{\text{Max}(x_j) - \text{Min}(x_j)} \quad (39)$$

$$X_{ij} = \frac{\text{Max}(x_j) - x_{ij}}{\text{Max}(x_j) - \text{Min}(x_j)} \quad (40)$$

onde x_{ij} representa o valor real do parâmetro j da série i , $\text{Max}(x_j)$ representa o valor máximo do parâmetro j dentre as séries i , $\text{Min}(x_j)$ representa o valor mínimo do parâmetro j dentre as séries i disponíveis, e X_{ij} representa o valor padronizado da série i e parâmetro j . Para ilustrar o método, suponhamos que o valor máximo da intensidade média dos eventos de seca de todos os *grids* TRMM seja 1,50/mês, o valor mínimo $\text{Mix}(x_j)$ seja de 0,00/mês e o valor da intensidade média de determinado grid i seja de 0,90/mês. Logo, com base na Equação 39, estima-se que o valor padronizado X_{ij} será de 0,60.

Todavia, é válido notar que a padronização desenvolvida considerou uma base de dados por vez. Em outras palavras, os valores $\text{Max}(x_j)$ e $\text{Mix}(x_j)$ obtidos mediante o uso dos dados de pluviômetros não interferem nos valores $\text{Max}(x_j)$ e $\text{Mix}(x_j)$ encontrados a partir das estimativas do TRMM. Seguindo o exemplo anterior, suponhamos que a máxima intensidade média dentre os 78 postos pluviométricos tivesse sido 1,80 /mês e que valor mínimo tivesse se mantido igual a zero. No caso, como a análise é realizada de modo independente, o valor de X_{ij} do grid TRMM continua sendo igual 0,60, pois o valor $\text{Max}(x_j)$ utilizado para padronizar essa variável é computado apenas com base nos dados estimados pelo satélite TRMM. Caso a padronização fosse integrada, o valor $\text{Max}(x_j)$ seria ajustado para 1,80/mês, e daí o valor de X_{ij} resultante seria de 0,50, inferior ao resultado original (0,60).

Essa consideração é importante pois por mais que os valores estimados pelo TRMM não sejam necessariamente iguais aos obtidos a partir dos dados de pluviômetros, ainda assim há possibilidade de avaliar a capacidade do TRMM de identificar as regiões com mais ou menos risco à ação das secas sobre o estado da Paraíba. Assim, foram feitas mais que 1.500 operações de padronização de variáveis para cada índice SPI (265 séries \times 6 parâmetros), totalizando quase 13.000 valores de X_{ij} calculados para os oito índices SPI. Em seguida, com os valores padronizados, foram atribuídos diferentes pesos ω para cada uma das variáveis j , no intuito de compor o índice NIDS-Trend, assim como feito por Murthy *et al.* (2017). Nesse sentido, o valor do índice é calculado através do somatório entre o produto dos pesos ω_j e as variáveis padronizadas X_{ij} , conforme mostrado nas Equações 41–42:

$$\text{NIDS-Trend}_i = \sum_{j=1}^K \omega_j X_{ij} \quad (41)$$

$$\omega_j = \frac{\left[\sum_{j=1}^K \frac{1}{\sqrt{\text{var}(X_j)}} \right]^{-1}}{\sqrt{\text{var}(X_j)}} \quad (42)$$

onde $var(X_j)$ representa a variância entre os valores X_{ij} do parâmetro j . Percebe-se no caso, que os valores ω_j variam em função da variância entre os valores X_{ij} de cada parâmetro e que parâmetros que apresentam menor variância apresentam maior peso, enquanto parâmetros com maior variância apresentam pesos menores. Destaca-se também que a atribuição de pesos aos parâmetros é uma decisão importante porque evita a consideração particular desse método de que sejam atribuídos os mesmos pesos a todos os parâmetros.

Por fim, é relevante levantar uma questão a respeito do NIDS-Trend. Como o processo de padronização das variáveis e de atribuição dos pesos aos K parâmetros é realizado levando em consideração a rede de dados e séries disponíveis, é de suma importância que esteja sendo analisada uma quantidade de postos pluviométricos (ou *grids*) considerável, no intuito de que o resultado final seja satisfatório. De fato, é de se esperar que quanto mais representativa for a base de dados disponível, maior a probabilidade de se obter resultados mais significativos. Ao trabalhar com poucos dados ou em regiões com baixa variabilidade, os resultados obtidos a partir da utilização do NIDS-Trend podem ser inconclusivos, i.e., não expor com tanta nitidez quais são as regiões com mais ou menos vulneráveis à ação das secas.

Neste trabalho, foram feitas análises pontuais e por mesorregiões, considerando as duas bases de dados disponíveis e cada uma das oito escalas temporais. É importante pontuar que a metodologia proposta neste estudo é inovadora e que não se tem conhecimento de outro trabalho que tenha integrado tais parâmetros de secas para compor um índice geoespacial. O NIDS-Trend permite o desenvolvimento de estudos quanto ao risco de ação das secas e sua aplicação sobre o estado da Paraíba e sobre outras regiões que são corriqueiramente afetadas pelas secas contribuirá para as tomadas de decisões e para o manejo dos recursos hídricos de diferentes áreas do planeta. Aliando isso à capacidade de avaliação do desempenho do satélite TRMM em reproduzir os resultados do NIDS-Trend, fica comprovada não só a robustez deste trabalho como também seu caráter inédito na literatura.

5. RESULTADOS E DISCUSSÃO

5.1. AVALIAÇÃO DAS SECAS SOBRE A PARAÍBA

No intuito de realizar uma análise mais ampla a respeito do comportamento das secas, a precipitação média sobre o estado da Paraíba foi calculada a partir da média ponderada da precipitação dos postos e das grades TRMM utilizando o método dos polígonos de Thiessen

de 1998 a 2017 (Figura 8a). Em geral, nota-se que o comportamento da precipitação das duas séries é muito similar ao decorrer do período e as métricas apontam que o desempenho do satélite TRMM ao captar o regime de chuvas foi extremamente satisfatório. Para o coeficiente de correlação de Pearson, o valor obtido entre a série de precipitação dos pluviômetros e a precipitação estimada pelo satélite TRMM foi de 0,976, o que indica que há uma associação linear quase perfeita entre essas duas séries.

O *RB* indica que as estimativas do satélite TRMM superestimaram os valores obtidos a partir dos dados de postos pluviométricos em menos de 8%, valor satisfatório ao considerar que as séries comparadas resultam da precipitação média sobre toda a Paraíba, região extensa e de diferentes características. Os valores de *RMSE* foram inferiores a 20 mm, resultado que comprova a precisão do satélite para captar o regime pluviométrico sobre a região ao longo dos anos. Vale ressaltar que esses resultados corroboram com os de outras pesquisas que avaliaram a acurácia do TRMM no Nordeste brasileiro (NEB) e na Paraíba. Pereira *et al.* (2013) e Melo *et al.* (2015) indicaram que o coeficiente de correlação encontrado entre os dados de pluviômetros e as estimativas do TRMM é alta ($R > 0,90$) para o NEB, e Soares *et al.* (2016) concluíram que a ordem de grandeza dos valores *RMSE* sobre o estado da Paraíba são satisfatórios, resultado condizente com o obtido neste trabalho.

No geral, as estimativas TRMM identificaram com precisão os anos mais (e.g., 2004, 2008 e 2009) e menos chuvosos (e.g., 1998 e 2012) da região. Todavia, apesar da similaridade entre as séries, ressaltam-se os erros de superestimativa e subestimativa dos dados TRMM. Na maior parte dos casos, os erros de superestimativa ocorreram nos meses chuvosos, quando as chuvas mensuradas a partir dos postos foram superiores a 150 mm. Por outro lado, as estimativas do TRMM foram subestimados quando a precipitação foi menos expressiva e não ultrapassou os níveis de 50 mm mensais. De certo modo, esse erro demonstra a imprecisão do satélite ao estimar a magnitude da precipitação de maneira mais detalhada e destaca-se que isso pode estar relacionado à escala espacial das estimativas do TRMM, à variabilidade da chuva na região e ao fato comparar de estarmos comparando os resultados pontuais dos postos com os resultados em formato de grid do satélite.

Feita a análise prévia a respeito do comportamento da precipitação média sobre o estado da Paraíba, foram calculadas as séries SPI em múltiplas escalas temporais com base nos dados de chuva dos pluviômetros (Figura 8b) e nas estimativas do satélite TRMM (Figura 8c). Assim, foi realizada a avaliação do comportamento das secas em 48 escalas temporais diferentes, i.e., SPI-1 ao SPI-48, ao longo de 1998 a 2017 com base na precipitação média

sobre o estado da Paraíba. A partir dos resultados, nota-se grande similaridade entre o padrão das secas obtidos independentemente da escala temporal e assim, é possível concluir que a acurácia do satélite em captar o regime das secas de curto, médio e longo prazo sobre o estado da Paraíba também foi satisfatória de um modo geral.

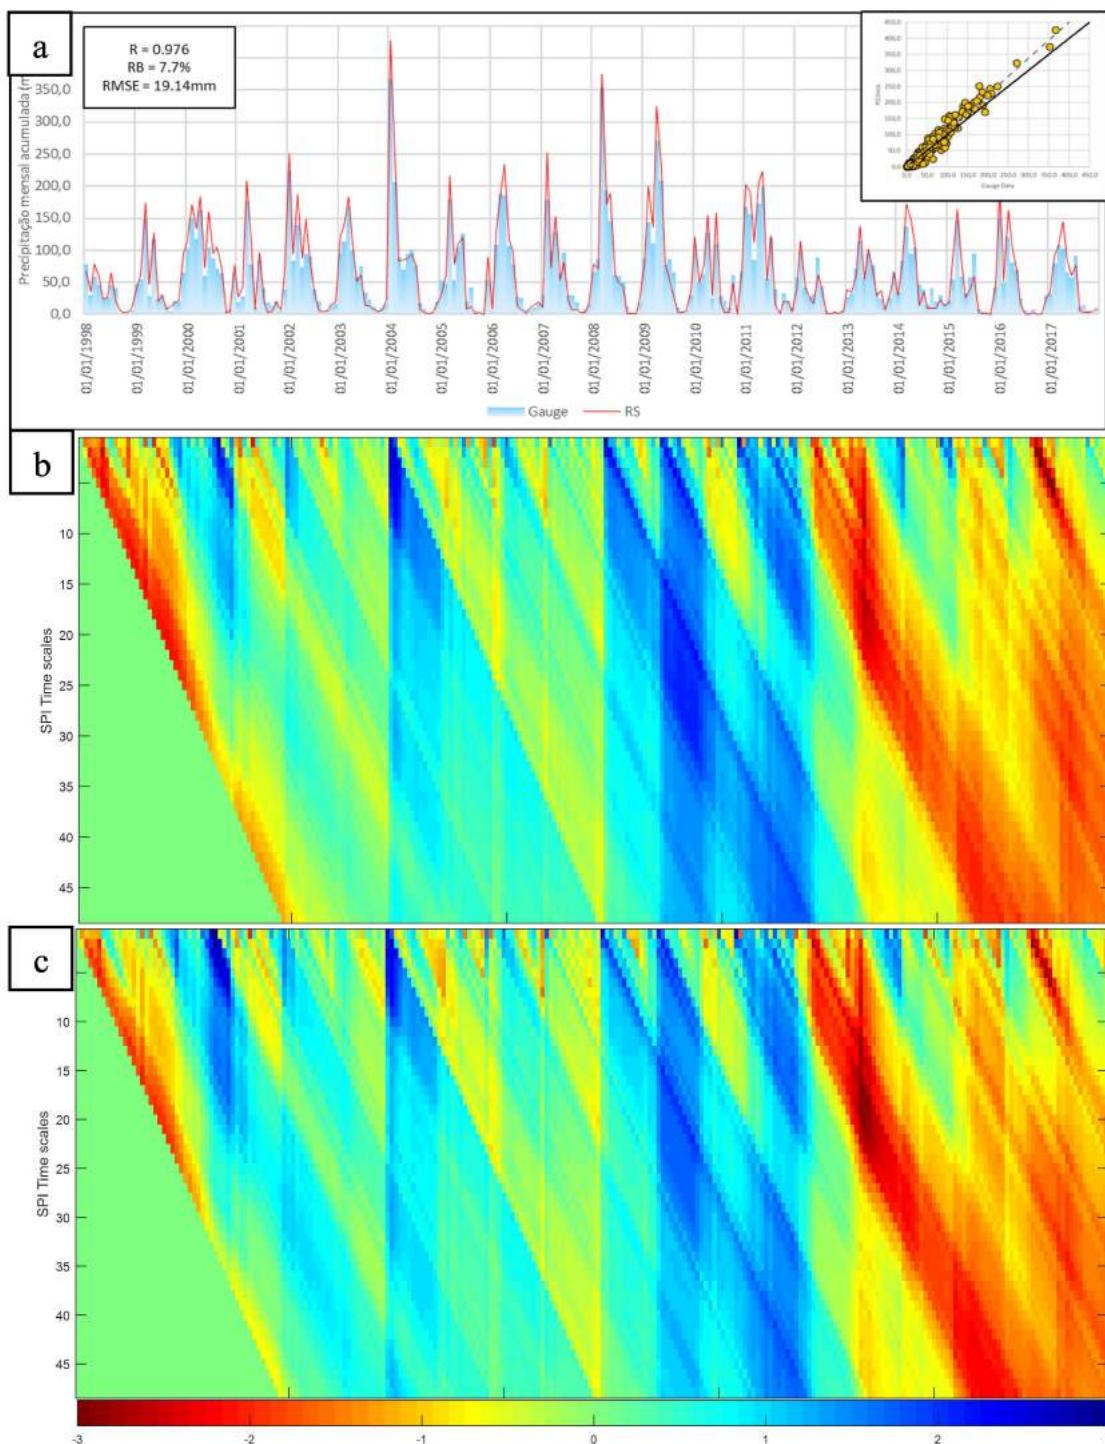


Figura 8 – (a) Hietograma e gráfico de dispersão da precipitação média mensal sobre o estado da Paraíba usando pluviômetros e estimativas do TRMM, e comportamento do SPI 1-48 com base nos: (b) dados de pluviômetros e nas (c) estimativas do TRMM (1998–2017).

De certo modo, é válido destacar que esses resultados já eram esperados diante das conclusões que puderam ser tiradas da Figura 8a. Por ser um índice que se baseia somente em dados de precipitação e diante da acurácia do satélite TRMM em captar o regime das chuvas sobre o estado da Paraíba, era de se esperar que os resultados para os índices SPI obtidos a partir dessas duas séries de precipitação também fossem similares entre si. De todo modo, é importante destacar que por mais que esses dados de chuva apresentem elevada similaridade entre si, avaliar o comportamento das secas com base nos valores do SPI é a decisão mais prudente. Na realidade, o que pode acontecer é que apesar de existir uma boa concordância entre os dados de chuva, os resultados em relação às secas em diferentes escalas de tempo podem não ser tão precisos assim, tal como discutido por Tao et al. (2016).

Ainda com base nesses resultados, percebe-se que a partir da aplicação do índice SPI é possível não só identificar com maior precisão quais foram os períodos secos e úmidos, mas, principalmente, estimar quanto úmidos ou secos eles foram em relação a todo período, fato esse que caracteriza uma das contribuições importantes do uso do índice. Ademais, é conveniente destacar que existe um padrão de similaridade entre os resultados, tal que é possível perceber a existência de linhas verticais bem delimitadas que demarcam o início dos períodos úmidos (e.g., 2004) e secos (e.g., 2012). A partir dessa marca, há alteração no comportamento do índice SPI em múltiplas escalas temporais e tais valores tendem a ser positivos ou negativos em sentido diagonal descendente, assim como encontrado nos estudos de Tan *et al.* (2017) e de Yang *et al.* (2017).

Entretanto, é necessário destacar que existem algumas divergências entre os valores SPI obtidos a partir dos pluviômetros e das estimativas TRMM. De 1998 a 2001, os valores SPI computados a partir dos dados de satélite superestimaram os obtidos a partir das medições por postos pluviométricos. Na prática, isso significa que sob o ponto de vista do TRMM, os eventos foram mais úmidos do que os mensurados a partir das estações. Além desse resultado ter uma provável ligação com a comparação realizada entre dados pontuais e dados espaciais, um dos possíveis motivos para esse fato pode ter sido a mudança da altura orbital do satélite ocorrido nesse período. Curtarelli *et al.* (2014) avaliaram a influência desse episódio na região central do Brasil e apontam que não houve alteração significativa entre as estimativas de precipitação pré e pós evento. No entanto, não se sabe de algum estudo feito no NEB e assim, estima-se que a mudança possa ter relação com esse fato.

A partir de 2008, por outro lado, os valores SPI oriundos das estimativas do TRMM foram subestimados quando comparados aos obtidos a partir dos pluviômetros, independente

da escala temporal. A partir de 2012, um dos mais secos dentre os 20 anos analisados, essa subestimativa dos valores SPI intensificou, especialmente em se tratando das secas de longo prazo. É válido destacar que as inconsistências mais significativas entre essas duas bases de dados ocorreram mediante as análises de curto prazo, e o que motiva esse fato é que essas escalas temporais consideram a precipitação acumulada de poucos meses ao computar o SPI, o que as tornam mais sensíveis frente à ocorrência de eventos extremos de precipitação se comparados ao SPI-48, por exemplo.

Nesse sentido, apesar das divergências pontuais, conclui-se que o satélite TRMM foi capaz de captar o comportamento das secas em múltiplas escalas temporais sobre o estado da Paraíba ao longo dos 20 anos. Contudo, é importante destacar que a análise foi desenvolvida com base na série de precipitação média sobre todo o estado da Paraíba, i.e., a variabilidade espaço-temporal da precipitação de todas as mesorregiões foi incorporada em uma única série. Nesse sentido, sabe-se que para fazer a completa caracterização, considerando todas as séries pluviométricas, deveriam ser feitas 78 figuras análogas à Figura 8, resultado inviável de ser exposto neste trabalho. Todavia, apesar de representar uma análise mais ampla a respeito do comportamento das secas sobre a região, os resultados encontrados são valiosos no processo de caracterização das secas da área.

Ainda com base na precipitação média mensal sobre a Paraíba, realizou-se uma análise detalhada a respeito do comportamento dos oito índices SPI utilizados neste trabalho. Assim, a Figura 9 mostra as oito séries SPI calculadas com base nos dados dos postos pluviométricos e nas estimativas do TRMM e o percentual de ocorrência de cada tipo de evento úmido e seco ao decorrer do período. De certo modo, a Figura 9 é uma extensão mais detalhada da Figura 8, onde foram analisadas oito escalas temporais das Figuras 8b-c. A primeira linha da Figura 8b-c, por exemplo, refere-se a série de valores SPI-1 da Figura 9, com o acréscimo também da análise de frequência dos diferentes tipos de eventos úmidos e secos.

Para as secas de curto prazo, percebe-se que os valores SPI tendem a variar com mais frequência entre positivos e valores negativos ao decorrer do tempo, i.e., há uma quebra na continuidade dos eventos secos e úmidos, assim como encontrado por Santos *et al.* (2017). No caso, destaca-se que os índices de menor escala temporal são mais sensíveis à ocorrência de eventos de chuva extremos e por isso, caso um evento chuvoso ou seco de maior magnitude ocorra é provável que nesse período, o evento passe a ser categorizado como úmido ou seco, respectivamente. De todo modo, destaca-se que apesar dessa sensibilidade dos índices SPI à

ocorrência de eventos de precipitação extremos, há similaridade relevante entre os resultados obtidos a partir das duas bases de dados disponíveis.

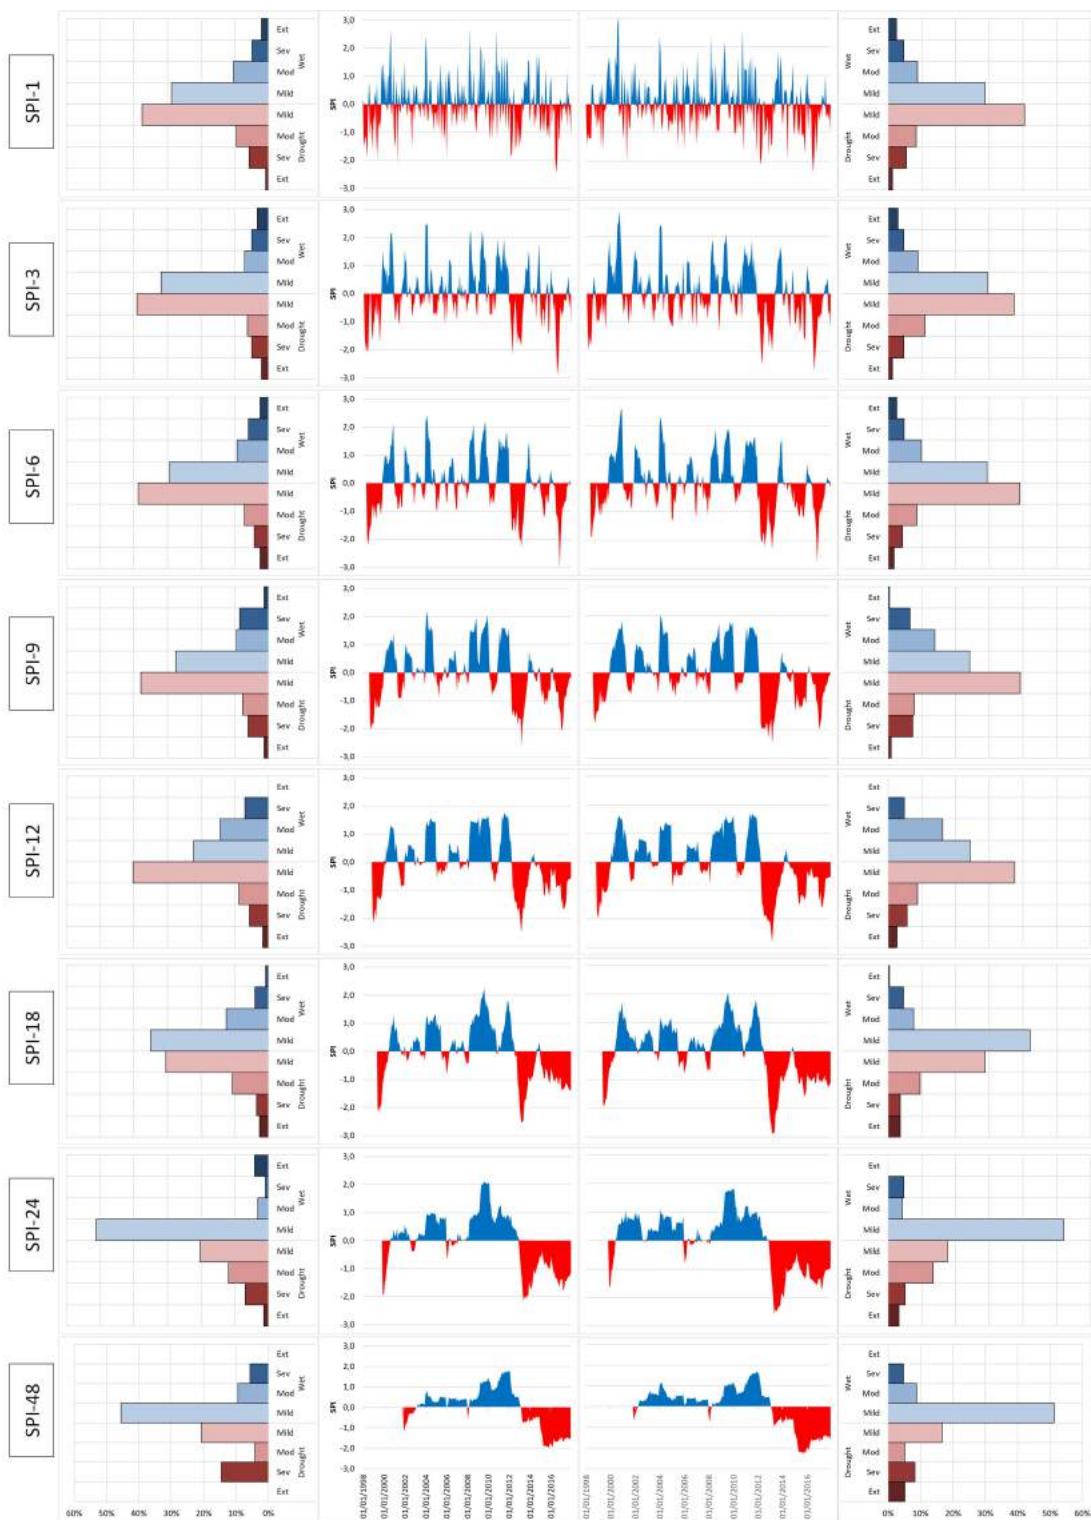


Figura 9 – Variação temporal do índice SPI e análise de frequência dos tipos de eventos em múltiplas escalas temporais com base na série de precipitação média sobre a Paraíba, utilizando dados de pluviômetros (à esquerda) e as estimativas do TRMM (à direita).

Em relação à frequência dos tipos de eventos úmidos e secos, os resultados obtidos foram muito similares entre si e os percentuais de eventos suavemente secos foram os maiores para o SPI-1, SPI-3 e SPI-6 considerando as duas bases de dados. Para o SPI-1, cerca de 55% dos eventos foram categorizados como secos usando as estimativas do TRMM e os dados das estações, enquanto que para o SPI-3 e SPI-6 esse valor foi um pouco inferior. Mesmo assim, é válido pontuar que os resultados obtidos a partir das estimativas TRMM ora superestimaram os valores SPI (e.g., entre 1998 e 2001), ora subestimaram tais valores (e.g., a partir de 2008). Dentre os maiores erros por parte do TRMM, destaca-se especialmente a superestimativa de eventos moderadamente secos ao avaliar o índice SPI-3.

Diferentemente do comportamento das secas de curto prazo, nota-se que para as secas de médio prazo, há continuidade de eventos secos e úmidos ao longo do tempo, o que facilita a identificação dos períodos úmidos e secos, tal como definido por Wable *et al.* (2019). A partir da análise do SPI-9 e SPI-12, fica evidente não só quão úmidos foram os anos de 2004, 2008 e 2009 e quão secos foram os anos de 1998, 1999 e 2012, como o quão preciso foram as estimativas do TRMM em captar esse o padrão das secas nessas escalas de tempo. Apesar da similaridade entre as séries, ainda assim existem divergências por parte das estimativas do satélite TRMM, que superestimou os valores SPI até o ano de 2002. Com base no percentual de ocorrência dos eventos, destacam-se semelhanças no padrão dos resultados encontrados quando comparados aos das secas de curto prazo.

O percentual de eventos secos aumentou, principalmente em se tratando dos resultados obtidos a partir dos dados de postos. Para o SPI-12, o percentual total de eventos secos foi de 56%, com base nos dados de postos pluviométricos e nas estimativas do TRMM, o que reflete um aumento de 3% em relação ao índice SPI-3 e SPI-6. Os eventos suavemente secos foram os mais frequentes do período, resultado análogo ao obtido para as secas de curto prazo. Em contrapartida, o percentual de eventos extremamente úmidos basicamente zerou ao serem avaliadas as secas de médio prazo, mas os eventos moderadamente úmidos foram os mais frequentes. Nota-se que para o SPI-9, as frequências dos eventos severamente e suavemente úmidos foram subestimadas pelo TRMM, enquanto que a dos eventos moderadamente úmidos foi superestimada. Já para o índice SPI-12, o percentual dos eventos severamente úmidos foi subestimado, assim como para os resultados do SPI-9.

Para as secas de longo prazo, os valores SPI negativos ou positivos tendem a ser ainda mais contínuos se comparados às análises desenvolvidas para as secas de curto e médio prazo. Por outro lado, apesar do padrão das secas de longo prazo ter sido identificado ao longo do

tempo, os valores SPI computados pelo satélite superestimaram (ou subestimaram) os valores SPI de maneira mais acentuada. Até 2003 houve superestimativa considerável dos valores obtidos a partir dos dados de pluviômetros, especialmente para o SPI-18 e SPI-24, enquanto que a partir de 2012, houve subestimativa agravante dos valores SPI-18, SPI-24 e SPI-48. Além disso, em comparação com os resultados das secas de curto e médio prazo, nota-se uma mudança quanto ao comportamento no padrão de frequência dos tipos de eventos.

Para os índices SPI-18, SPI-24 e SPI-48, os eventos suavemente úmidos foram os eventos mais frequentes ao decorrer dos 20 anos e a frequência dos eventos secos como um todo caiu consideravelmente. Para o SPI-48, por exemplo, esse percentual foi de 39% e 35% com base nos dados de postos pluviométricos e nas estimativas do TRMM, respectivamente, valores mais baixos do que os encontrados para as secas de curto e médio prazo. Todavia, pode-se perceber que a frequência dos eventos extremamente e severamente secos aumentou bastante e esse resultado corrobora com o padrão obtido em outras pesquisas. No geral, nota-se que ao serem avaliadas as secas de longo prazo, a quantidade de eventos secos diminui em frequência, mas aumenta em severidade (Santos *et al.*, 2019b).

5.2.QUANTO À ACURÁCIA ESTATÍSTICA

Depois de realizar a análise mais ampla sobre a qualidade da rede pluviométrica, iniciou-se o processo de avaliação da acurácia do TRMM em captar o padrão das secas em múltiplas escalas temporais. Desse modo, a Figura 10 mostra a relação de dispersão entre os dados SPI oriundos dos postos pluviométricos e estimados pelo satélite TRMM, e a distribuição espacial do coeficiente de correlação R , do índice de concordância de Kendall (Kd) e do índice de concordância kappa (Kp) sobre a Paraíba para oito escalas temporais. No geral, os resultados apresentam elevada variabilidade dentre as métricas, regiões e escalas temporais, fato que realça a importância desse resultado no processo de avaliação da acurácia espaço-temporal do TRMM quanto ao monitoramento das secas.

No tocante à relação de dispersão entre os dados, destaca-se que para o SPI-1 quase 19.000 (78 séries \times 240 meses) pontos foram plotados na Figura 10, indicando a relação entre os valores SPI-1 oriundos dos pluviômetros *versus* os valores SPI-1 oriundos das estimativas dos *grids* TRMM. Independentemente da escala temporal, há boa associação linear entre as séries SPI computadas a partir das duas bases de dados, mas é notório que existem algumas divergências entre os produtos. Para as secas de curto prazo, por exemplo, os piores resultados

foram os SPI-1, enquanto os melhores foram os do SPI-6. Já para as secas de médio prazo, há uma associação linear maior entre os dados, especialmente ao tratar dos eventos suavemente úmidos e secos. Por fim, dentre as secas de longo prazo, o pior resultado foi o do SPI-48, que apresentou um nível de dispersão um pouco mais elevado se comparado às demais escalas.

Apesar da relação de dispersão ser, em geral, um bom indicativo quanto à acurácia do TRMM em captar o comportamento dos diferentes tipos de seca, é importante ressaltar que na figura estão contidos os resultados de 78 comparações entre as séries SPI dos pluviômetros e das estimativas do satélite, o que torna impossível identificar quais as regiões apresentaram maior (ou menor) acurácia em caracterizar o regime das secas em múltiplas escalas temporais. Para preencher a lacuna, os valores do coeficiente de correlação R foram espacializados sobre o estado da Paraíba, possibilitando a visualização da variabilidade espacial dos resultados. No geral, os resultados corroboram com o padrão da dispersão, mas variam significativamente de região para região, o torna essa resultado valioso para desenvolver análise mais completa.

Para as secas de curto prazo, os melhores resultados foram obtidos ao avaliar o SPI-6, principalmente nas mesorregiões do Sertão e Borborema, enquanto os piores resultados foram encontrados na região mais próxima ao litoral sob avaliação do SPI-1. Apesar da variabilidade espacial entre os valores, nota-se que esses variaram de 0,60, nos piores casos, até 0,90 nos melhores cenários, o que demonstra alta acurácia do TRMM no tocante à caracterização das secas de curto prazo sob as regiões. Para as secas de médio prazo, os resultados foram ainda melhores do que os das secas de curto prazo, e também foi possível notar que as regiões do Sertão e Borborema foram as que apresentaram os maiores valores, enquanto as mesorregiões do Agreste e Mata Paraibana foram as que apresentaram os piores resultados.

Surpreendentemente, os melhores e piores resultados dentre os três tipos de secas são encontrados simultaneamente ao avaliar as secas de longo prazo. Para o SPI-48, há associação linear quase perfeita entre as bases de dados na área limítrofe entre a Borborema e o Agreste, mas por outro lado, no sudeste do Agreste e no litoral da Mata Paraibana, os resultados foram insatisfatórios, já que os coeficientes de correlação linear chegaram a atingir valores nulos. Na China, Li *et al.* (2013) afirmaram que o aumento da escala temporal influencia positivamente na precisão do TRMM, assim como encontrado no interior da Paraíba. Por outro lado, Tan *et al.* (2017) concluíram que as estimativas se tornam mais imprecisas com o aumento da escala temporal na Malásia e relacionam tal resultado ao tamanho da série de dados TRMM. Esses resultados indicam que é necessário investigar a acurácia do TRMM dentre as regiões já que essas podem ter resultados variáveis, o que realça a importância desse estudo na Paraíba.

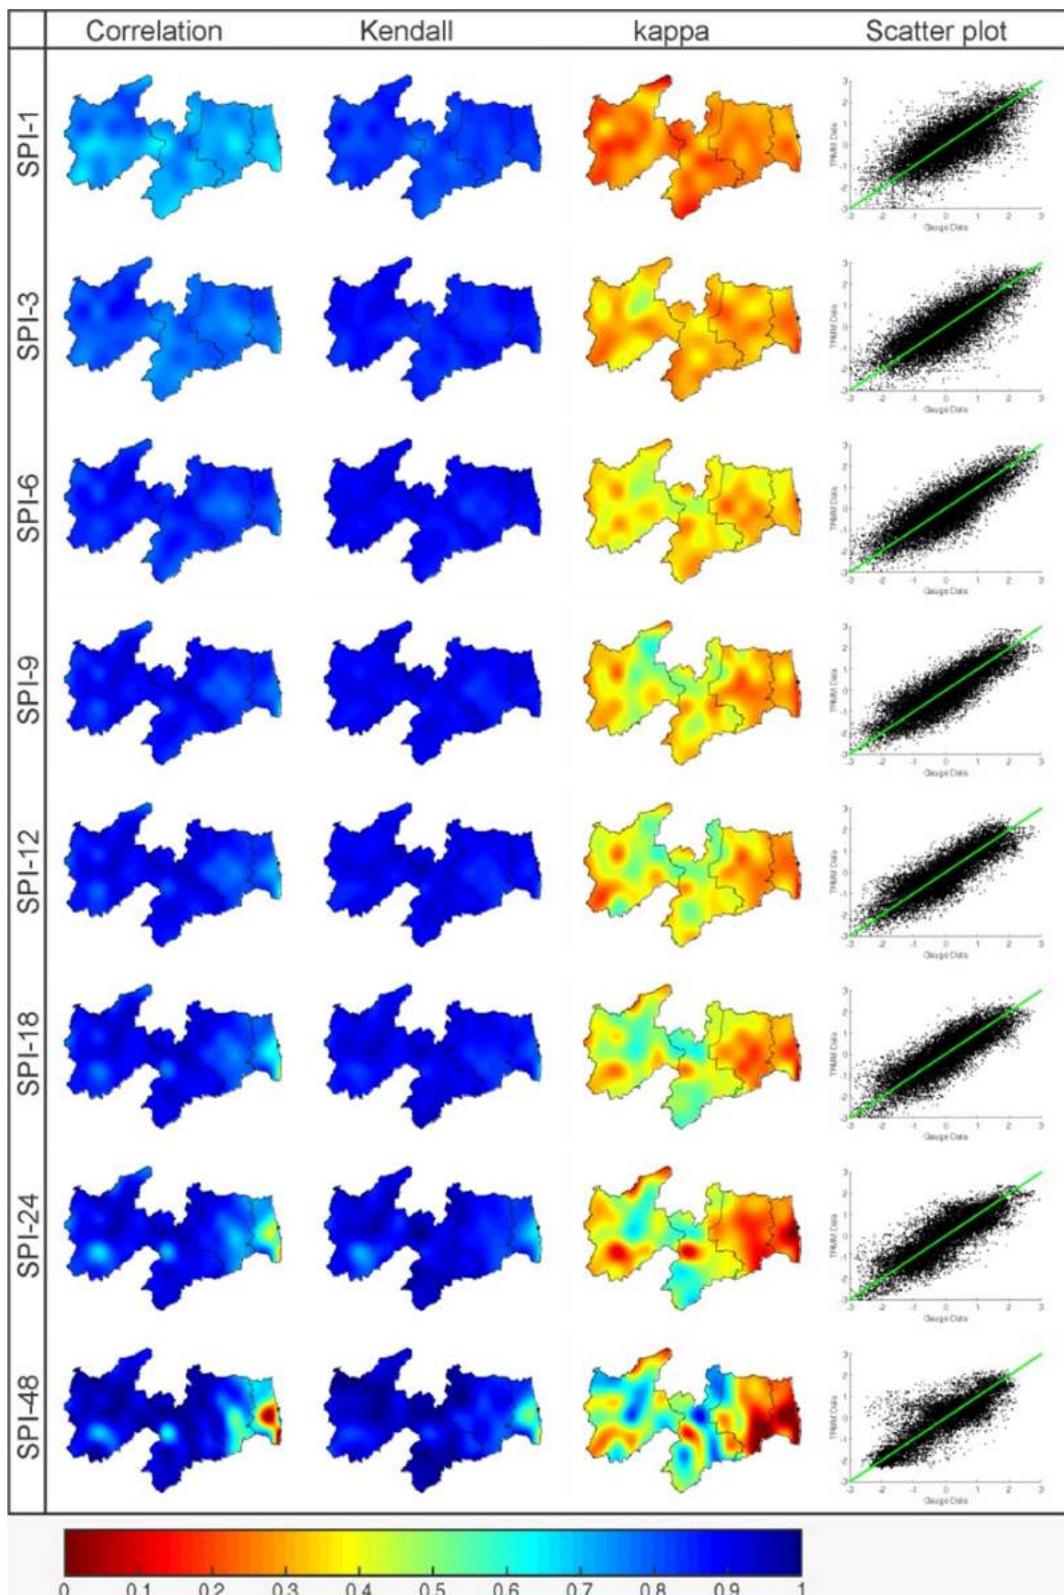


Figura 10 – Distribuição espacial dos índices R , Kd e Kp sobre o estado da Paraíba.

Em seguida, foi feita a distribuição espacial dos índices de concordância de Kendall e de kappa, métricas escolhidas para mensurar a acurácia do satélite para identificar os tipos de eventos úmidos e secos e suas categorias. De modo geral, nota-se que existe alta variabilidade

espacial dos resultados e esses se assemelham aos obtidos para o coeficiente de correlação R . Para as secas de curto prazo, os valores de Kd são homogêneos em todas as regiões e maiores que 0,80, em sua maioria. Os valores do índice de concordância de kappa, por sua vez, foram mais baixos que os de Kd e apresentaram maior variabilidade espacial. O SPI-1 foi a escala de tempo que apresentou os piores resultados, enquanto que para o SPI-6 houve maior acurácia do TRMM. Para o SPI-9 e SPI-12, os valores de Kd foram menos variáveis, mas apresentaram aumento se comparados às secas de curto prazo.

Os valores de Kp aumentaram no centro do estado da Paraíba, tal que o Sertão e a Borborema apresentaram os maiores valores, enquanto que nas regiões próximas ao litoral, os resultados indicaram a baixa acurácia na captação dos tipos de eventos secos e úmidos. Para as secas de longo prazo, os valores de Kd e Kp passam a ter maior variabilidade quanto à sua magnitude e sua distribuição espacial. Para o Kd , fica mais evidente a melhoria na precisão do TRMM no Sertão e Borborema, e uma piora do desempenho do satélite na região litorânea da Paraíba, com valores que chegam a 0,50. Já para Kp , a diversidade dentre cada região dificulta a definição das mesorregiões que tiveram melhor (ou pior) desempenho, principalmente para o SPI-48. Todavia, percebe-se que o interior do estado teve os resultados mais significativos.

No geral, os resultados obtidos a partir da avaliação dessas métricas se complementam e corroboram entre si, tal que o aumento da escala temporal resultou no aumento da acurácia do TRMM em captar o comportamento das secas, à exceção da Mata Paraibana. Os resultados indicam por unanimidade que no Sertão e na Borborema, os resultados são mais satisfatórios que no Agreste e na Mata Paraibana. Ao comparar o desempenho das três métricas, destaca-se que já era esperado que os valores de R e Kd fossem superiores aos obtidos para o Kp , e pode-se concluir que a depender da mesorregião analisada, o satélite TRMM pode ser utilizado como alternativa precisa para monitorar o comportamento das secas e para identificar os tipos de eventos secos e úmidos em múltiplas escalas temporais.

Em continuidade à essa análise de acurácia estatística do satélite TRMM, a Figura 11 mostra a distribuição do bias (B), do bias relativo (RB), do erro médio quadrático (MSE) e da raiz do erro médio quadrático ($RMSE$) sobre a Paraíba para os oito índices SPI (1998–2017). Diante da variabilidade dos resultados, é justo desenvolver uma análise detalhada a respeito de cada um dos tipos de seca. Para as secas de curto prazo, nota-se um padrão muito particular ao analisar o B dos índices SPI-1 e SPI-3. Os resultados indicam que os valores do SPI-1 que foram computados a partir dos dados TRMM superestimaram os dados SPI calculados a partir

dos dados de pluviômetros na Mata Paraibana e na porção limítrofe sul entre a Borborema e o Agreste, enquanto que no interior do estado, esse padrão se inverteu (i.e., subestimados).

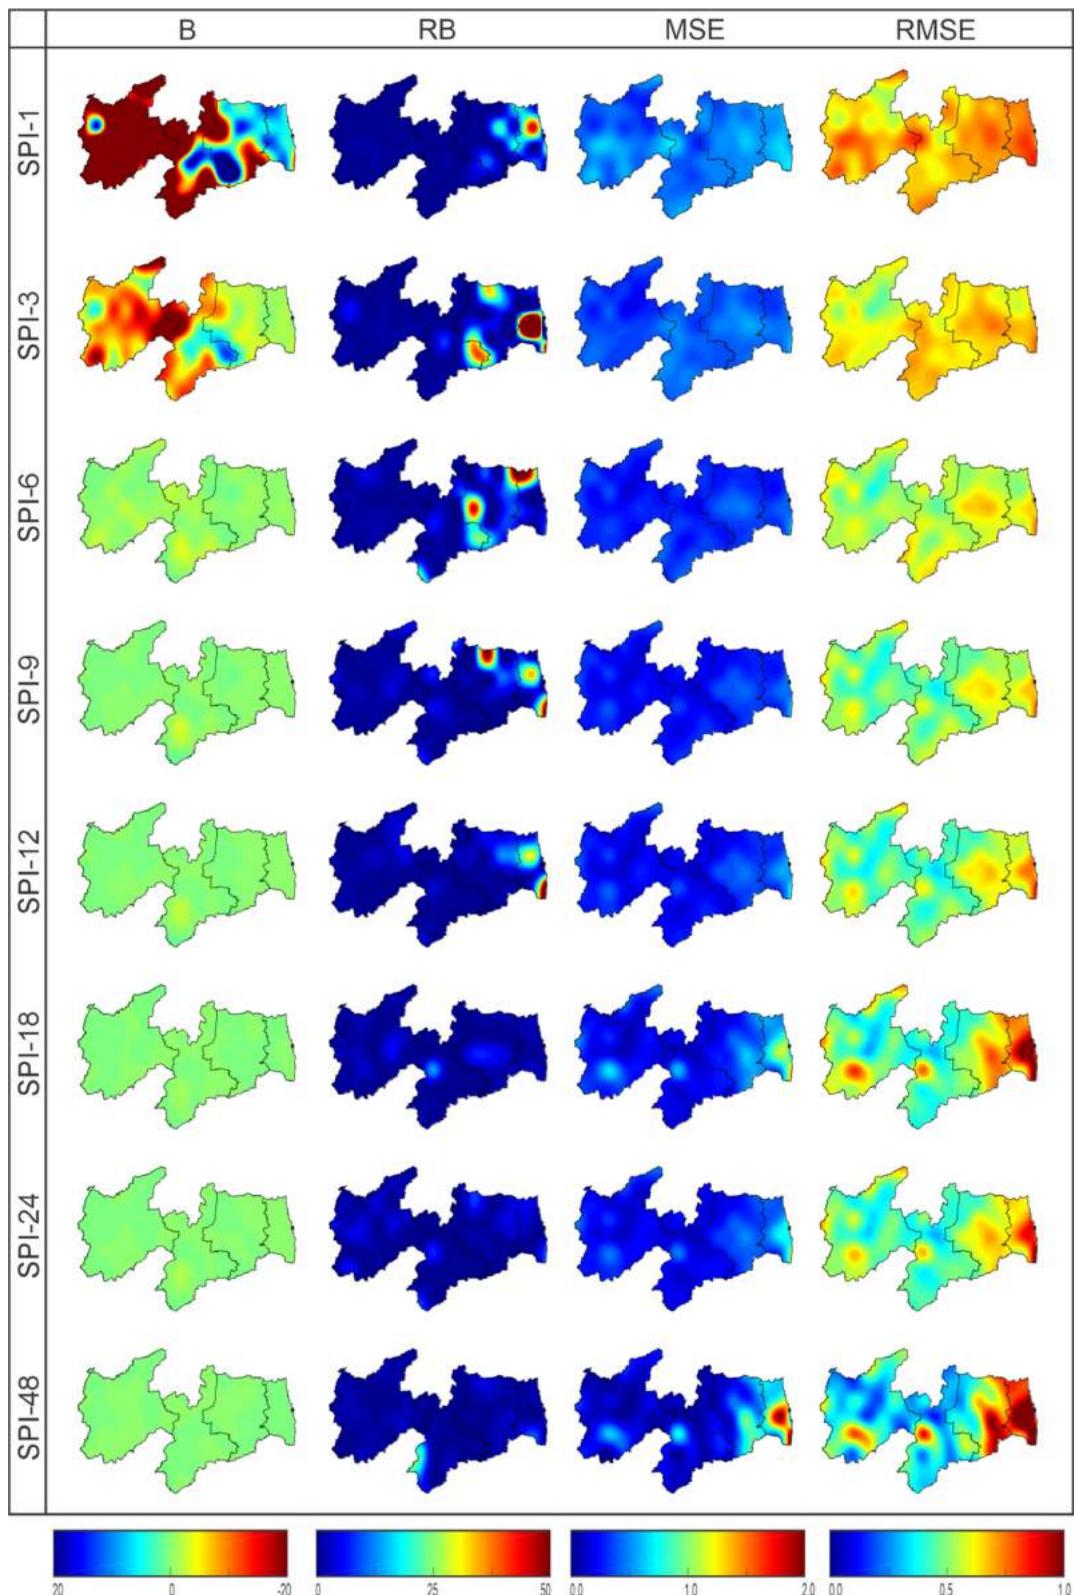


Figura 11 – Distribuição espacial dos índices *B*, *RB*, *MSE* e *RMSE* sobre o estado da Paraíba.

Nesse sentido, há indícios que os eventos monitorados a partir do TRMM foram mais úmidos nas mesorregiões da Mata Paraibana e em grande parte do Agreste, e mais secos no Sertão e Borborema. Para o SPI-3, foi mantida a mesma distribuição espacial dos valores, mas em menor magnitude, tal que os valores de B já foram mais baixos. Os resultados encontrados para o SPI-6 indicam que essa foi a escala temporal, dentre as utilizadas para avaliar as secas de curto prazo, em que houve maior acurácia do TRMM. No caso das secas de médio e longo prazo, os valores B foram nulos. A partir do bias relativo, nota-se o quanto superestimados (ou subestimados) os valores SPI dos pluviômetros foram em relação aos valores obtidos a partir dos dados de satélite.

Para o SPI-3, por exemplo, os resultados indicam que na maior parte da Mata houve superestimativa de mais de 50 vezes da série SPI dos pluviômetros por parte da série oriunda dos dados TRMM. Duas são as possíveis explicações para tal resultado: a primeira é que os dados SPI que foram computados a partir das duas bases são realmente diferentes e há uma forte tendência de superestimativa (ou subestimativa) por parte de alguma série, situação que pode ser identificada a partir da análise do B . Contudo, como os valores de bias foram muito baixos nessa e em outras regiões, tal motivo está descartado como causa desse resultado. Por outro lado, a segunda e a mais adequada explicação para essa situação, é que em alguns casos houve compensação entre os valores positivos e negativos do SPI pelas séries da AESA, tal que a somatória dos valores ao longo do período foi quase nula.

Por tal motivo, como a comparação do RB deste estudo é feita com base na série SPI dos postos, a razão entre os valores de B por esses produtos quase nulos resultam em valores de RB altos. Daí, esse erro mostra a ineficácia do satélite TRMM em captar os valores SPI na região litorânea da Paraíba, já que houve uma superestimativa considerável dos dados *in loco*. Todavia, apesar de que para as demais regiões e escalas temporais os valores de RB tenham sido próximos a zero, destaca-se que esses também precisam passar por outras investigações a fim de se ter uma análise mais completa. De fato, vale destacar que apesar do B e RB serem próximos a zero, isso não significa que os valores de SPI das estimativas do satélite são iguais aos das medições de pluviômetros.

Os baixos valores de B e RB podem ser fruto da compensação entre os valores SPI das bases de dados ao decorrer da série temporal, i.e., por mais que os valores SPI estimados pelo TRMM e obtidos por postos pluviométricos possam divergir muito uns dos outros em alguns momentos, o resultado final da diferença entre as séries é nulo, e por tal motivo os valores B e RB são baixos. Nesse sentido, a avaliação do MSE e do $RMSE$ se faz necessária para aumentar

o entendimento a respeito da acurácia do TRMM em captar os valores de SPI sobre o estado da Paraíba. Ao avaliar o erro médio quadrático e a raiz do erro médio quadrático, nota-se uma alteração na distribuição espacial dos valores, tal que diferentemente do encontrado para a análise do B e RB , os resultados das secas de longo prazo apresentaram maior variabilidade.

Para as secas de curto prazo, os valores de $RMSE$ foram relativamente satisfatórios sobre a região, variando de 0,40 nos melhores casos (e.g., no Sertão para o SPI-6), a 0,80 nos piores casos (e.g., na Mata Paraibana para o SPI-1). Em comparação aos resultados de B e RB , assume-se que os resultados se complementam, pois nas zonas em que houve superestimativa (ou subestimativa) mais exprevissiva dos valores, também foram obtidos os maiores erros sob ponto de vista do MSE e $RMSE$. Para as secas de médio prazo, por sua vez, há aumento da variabilidade dos valores de $RMSE$ entre as mesorregiões. No geral, os resultados indicam melhora na acurácia do TRMM no Sertão e na Borborema, cujo os valores de $RMSE$ chegam são menores que 0,40, e queda dessa acurácia especialmente no Agreste e na Mata Paraibana, com valores que ultrapassam 0,80.

É interessante notar que esse padrão se intensifica ainda mais em se tratando das secas de longo prazo, já que os valores de $RMSE$ variam de 0,20 a 1,00, para o SPI-48. Tal resultado se torna ainda mais intrigante mediante a análise da distribuição do B e do RB , já que para as secas de médio e longo prazo, os valores foram quase nulos em toda região e assim, de modo geral, esperava-se que os valores de $RMSE$ também fossem baixos. Entretanto, a explicação para que os valores de B e RB tenham sido baixos e os valores de MSE e $RMSE$ tenham sido altos está exatamente na compensação entre os valores positivos e negativos do SPI. Para as secas de médio e longo prazo, diferentemente ao que aconteceu para as secas de curto prazo, os valores do índice SPI oriundos do satélite TRMM e dos pluviômetros foram compensados ao decorrer dos 20 anos, o que resultou nos valores de B e RB quase nulos.

De todo modo, esse erro foi detectado a partir da análise do MSE e do $RMSE$, o que ressalta a importância de realizar uma avaliação conjunta entre diferentes métricas estatísticas. Ainda em relação à análise dessas métricas, cabe destacar que de acordo com alguns estudos, valores de $RMSE$ inferiores a 0,50 são um bom indicativo da precisão dos satélites remotos (Satgé *et al.*, 2019). Ao adotar esse valor como referência, pontua-se a acurácia estatística do satélite TRMM como muito boa em grande parte do estado ao avaliar as secas em diferentes escalas temporais. Além disso, os resultados obtidos no nosso trabalho corroboram com os de Sahoo *et al.* (2015) na maior parte do estado da Paraíba ($RMSE < 0,60$). A ressalva quanto ao

desempenho do satélite TRMM é na região litorânea e especialmente ao avaliar as secas de amplitude temporal mais expressivas, tal que o desempenho do TRMM não foi relevante.

Por fim, depois de realizar a análises das métricas dos dois primeiros grupos, fez-se a avaliação espaço dos índices de desempenho que compõem o terceiro grupo de métricas. A Figura 12 mostra a distribuição espacial do índice de proporção correta *PC*, da probabilidade de detecção *POD*, do índice de alarme falso ($1 - FAR$) e do índice de sucesso crítico *CSI* sobre o estado da Paraíba em várias escalas temporais (1998–2017). Em relação ao padrão das métricas, os melhores resultados foram obtidos ao avaliar o *PC*, *POD* e ($1 - FAR$); em relação à escala temporal, os resultados mais expressivos foram obtidos ao avaliar as secas de médio prazo; e no tocante a distribuição espacial dos valores, destaca-se a precisão nas mesorregiões do Sertão e Borborema. De todo modo, há considerável variabilidade dos resultados diante da diversidade de características físicas sobre o estado da Paraíba e por isso há necessidade de uma análise mais detalhada.

O *PC* é a métrica que representa o número de vezes em que as estimativas TRMM e os dados das estações pluviométricas corroboraram ao categorizar os eventos como úmidos ou secos, sem distinção. Os resultados foram bons e revelam alta precisão do satélite TRMM em categorizar os eventos secos e/ou úmidos ao longo dos 20 anos. Ao avaliar o padrão das secas de curto prazo, os piores resultados foram obtidos para o SPI-1 no oeste do Sertão e em parte da Borborema, com valores próximos de 0,65. Os melhores resultados, por sua vez, foram encontrados para o SPI-6 no Sertão e na Borborema, ultrapassando o valor de 0,85. Para as secas de médio prazo os valores de *PC* foram ainda mais altos se comparados aos das secas de curto prazo, tal que na maior parte da Paraíba chegaram a ultrapassar o valor de 0,90, o que demonstra alto índice de concordância entre as bases de dados. Para as secas de longo prazo, percebe-se que no Sertão, Agreste e principalmente na Mata Paraibana há queda nos valores, que chegam a ser inferiores a 0,40, tendo sido o pior resultado dentre as escalas temporais.

Em relação aos resultados para as secas de curto prazo, é interessante destacar que isso pode estar relacionado ao comportamento da precipitação no Sertão e na Borborema. Nessas regiões, os níveis pluviométricos não são tão altos e há predomínio de pancadas de chuvas. Assim, ao tratar das secas de curto prazo que são as que consideram a precipitação acumulada de um período curto, qualquer oscilação no padrão das chuvas que possa não ser corretamente identificado pelo satélite pode fazer com que os diferentes eventos passem a ser classificados como secos ou como úmido pelas diferentes bases de dados. Nesse sentido, nota-se que o erro

por parte do TRMM se torna mais suscetível para as secas de curto prazo, mas à medida que a escala de tempo aumenta, a acumulação da chuva resulta no aumento no acurácia do satélite.

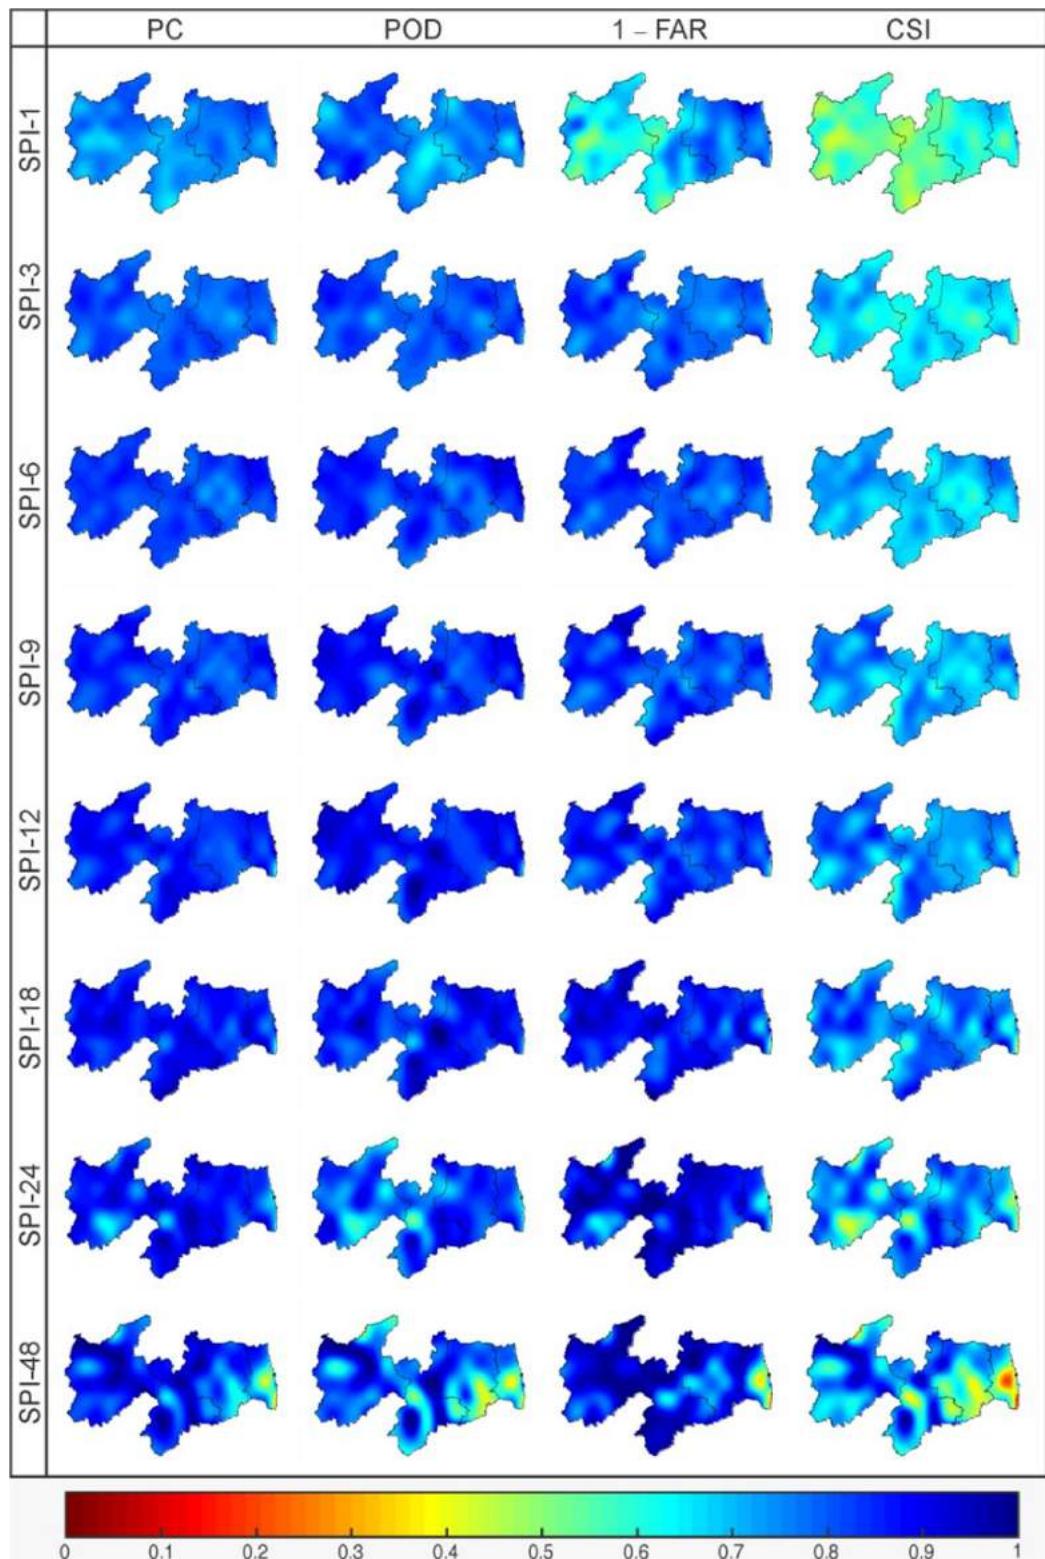


Figura 12 – Distribuição espacial dos índices *PC*, *POD*, $(1 - FAR)$ e *CSI* sobre o estado da Paraíba.

Ao avaliar a precisão do TRMM em identificar corretamente os eventos secos uma vez que esses eventos ocorreram segundo os dados das estações, nota-se considerável semelhança do padrão do *POD* com os resultados obtidos para o *PC*. De modo explicativo, quando o valor do *POD* é 0,80, isso significa que dentre todos eventos categorizados como secos a partir dos dados de pluviômetros, houve acerto de 80% por parte do satélite ao classificá-los desse modo também, i.e., como seco. Para as secas de curto prazo, as áreas na parte central da Borborema, foram as que tiveram os piores resultados ao avaliar o SPI-1, assim como para o *PC*. De todo modo, os valores de *POD* foram geralmente maiores que 0,65, o que indica que há elevada acurácia das estimativas do sátelite ao detectar corretamente a ocorrência de eventos secos.

Para as secas de médio prazo, por sua vez, os resultados de *POD* são ainda melhores e se estendem por todas mesorregiões, variando de 0,80 até quase 1,00 em áreas da Borborema. Para as secas de longo prazo foram obtidos os piores resultados, destacando-se especialmente os resultados da zona da Mata Paraibana, da porção sul do Agreste e da zona limítrofe entre a Borborema e o Sertão. Nessas regiões, os valores de *POD* foram menores do que 0,50, o que indica certa imprecisão do satélite TRMM em detectar o acontecimento dos eventos secos. No mais, também é válido destacar que os altos valores de *POD* na Borborema podem estar ligados à frequência dos eventos secos nessa mesorregião. De fato, ao comparar os resultados do *B* com os *POD*, nota-se que nessa região os valores SPI calculados a partir das estimativas TRMM foram subestimados, o que indica maior ocorrência de eventos mais secos.

Além disso, diante do comportamento da precipitação sobre a região, é fácil entender que a possibilidade de acerto do satélite ao identificar um evento seco em zonas em que esses tipos de eventos são mais frequentes é maior do que em outras áreas em que os eventos secos acontecem de modo raro, como é o caso do Agreste e da Mata Paraibana, tal como feito por Soares *et al.* (2016). A partir dos resultados encontrados por Santos *et al.* (2019a) e Santos *et al.* (2019b), percebe-se que essa mesorregião é a menos chuvosa do estado, o que embasa ainda mais os resultados desta pesquisa. Ao avaliar o *FAR*, nota-se um padrão semelhante aos dos índices de *PC* e de *POD*: ao assumir que o valor do *FAR* é de 0,10, significa que dentre todos os eventos classificados como secos pelo TRMM ao decorrer do tempo, em apenas 10% dos casos os eventos foram categorizados como úmidos a partir dos dados de pluviômetros. Neste trabalho, utilizou-se a expressão $(1 - FAR)$ apenas para manter a mesma escala de cores entre as figuras, tal que 0 indica o pior cenário de acurácia e 1, o melhor.

Para as secas de curto prazo, há um padrão muito singular no comportamento do SPI-1, tal que no oeste do Sertão e grande parte da Borborema, os valores foram de cerca de 0,45,

resultado não tão satisfatório em comparação ao obtido para os índices *PC* e *POD*. Ao tratar do SPI-3 e SPI-6, os resultados voltaram a apresentar precisão mais adequada sobre todo o estado, ultrapassando os valores de 0,80. Para as secas de médio prazo, houve incremento na acurácia do satélite TRMM, tal que os valores em algumas regiões do Sertão e da Borborema ultrapassaram 0,90. Para as secas de longo prazo, admite-se que os resultados foram melhores que os dos índices *PC* e *POD*, tal que para SPI-18, os valores foram de 0,90 sobre a Paraíba. Para o SPI-24 os resultados menos satisfatórios foram encontrados no sul do Sertão e para o SPI-48, na região do Agreste e no litoral da Paraíba.

Por fim, ao desconsiderar os acertos quando ambas as bases de dados categorizam um mesmo evento como úmido, nota-se queda nos valores de *CSI*, em comparação aos resultados dos índices *PC*, *POD* e *FAR*. De modo geral, isso mostra o quanto o satélite TRMM é preciso ao estimar corretamente a ocorrência dos eventos úmidos pois caso essa quantidade de acertos não fosse significativa, os valores de *PC* e *CSI* deveriam ser muito próximos. Apesar de ser notória a queda dos valores de *CSI*, é válido destacar que o padrão espacial dos resultados é basicamente o mesmo que os dos outros índices de desempenho. Para as secas de curto prazo, os valores são menores nas mesorregiões do Sertão e da Borborema ao tratar do SPI-1, mas tendem a aumentar com o aumento da escala temporal.

Para o SPI-9 e SPI-18 foram encontrados os melhores resultados sobre o estado, mas para o SPI-24 e SPI-48, há uma queda ainda mais brusca dos valores do *CSI*, especialmente no sul do Sertão e em grande parte do Agreste e da Mata Paraibana. Ressalta-se que apesar da área de estudo ser diferente, tal resultado corrobora com o encontrado por Jiang *et al.* (2017) na China, que também percebeu que o aumento da escala influenciou na queda do *CSI*. Tendo desenvolvido a distribuição espacial das 11 métricas sobre o estado da Paraíba em múltiplas escalas, realizou-se a análise de acurácia considerando o comportamento das mesorregiões da Paraíba. A Figura 13 mostra a análise dos índices *R*, *RMSE*, *Kd*, *Kp* e *PC* para cada uma das mesorregiões do estado e para tanto foram selecionadas duas métricas de cada um dos grupos existentes no intuito de ter um panorama geral sobre a precisão do satélite TRMM na região.

Para o coeficiente de correlação *R*, houve aumento dos valores com aumento da escala temporal e esse padrão foi encontrado em todas as mesorregiões, a exceção da zona da Mata Paraibana, que apresenta os valores mais baixos ao avaliar as secas de longo prazo. No geral, a Borborema e Sertão são as regiões que apresentam os valores *R* mais expressivos, enquanto o Agreste e principalmente a Mata Paraibana apresentam os resultados menos satisfatórios. De todo modo, os resultados encontrados para a Paraíba são relevantes e variam de 0,70, para

o SPI-1, até mais que 0,80, no caso das secas de médio e longo prazo. Ainda sobre a avaliação das métricas do primeiro grupo, nota-se que no caso do *RMSE*, o aumento da escala temporal provocou queda dos valores de *RMSE*, indicando maior precisão do satélite ao estimar a magnitude do SPI.

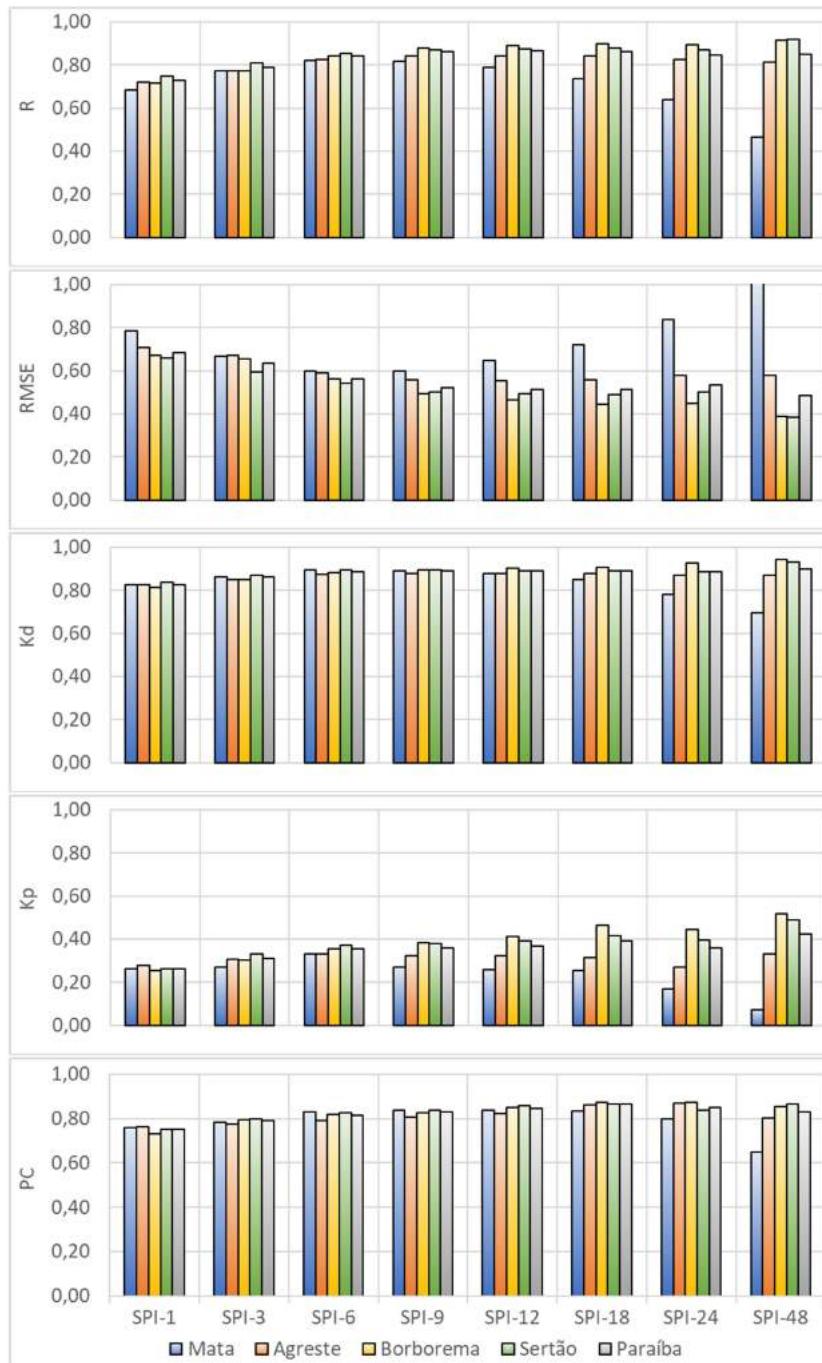


Figura 13 – Análise de acurácia estatística dos índices *R*, *RMSE*, *Kd*, *Kp* e *PC* para cada uma das mesorregiões do estado da Paraíba (1998–2017).

É válido pontuar que ao considerar as secas de curto e de médio prazo, os resultados obtidos entre as mesorregiões são homogêneos, mas é possível notar que o padrão encontrado

na Mata Paraibana é o menos satisfatório dentre as mesorregiões. No caso das secas de maior prazo, por sua vez, os resultados do Agreste e principalmente da Mata Paraibana tendem a se distanciar dos encontrados para o Sertão e Borborema, indicando queda relevante na acurácia estatística do satélite, tal como encontrado no caso do coeficiente de correlação. Os valores do *RMSE* para a Paraíba de modo geral não ultrapassam 0,70, o que dá indícios de que a precisão do satélite ao captar as magnitudes das séries SPI ainda é satisfatória. No caso dos índices de concordância de Kendall *Kd* e de kappa *Kp*, nota-se grande semelhança entre esses resultados.

Para o *Kd*, destaca-se que em todas as escalas temporais, à exceção do comportamento da Mata Paraibana no caso do SPI-48, o valor mínimo de todas as mesorregiões é igual a 0,80, o que indica uma acurácia estatística extremamente satisfatória do TRMM em captar o padrão de ocorrência dos diferentes tipos de eventos secos e úmidos. Além disso, é válido destacar que esses resultados são melhores do que os do coeficiente de correlação de Pearson e que há homogeneidade dos valores dentre as mesorregiões, i.e., não há variabilidade tão significativa entre as zonas do estado, especialmente ao avaliar as secas de curto e de médio prazo. No caso das secas de longo prazo, ressalta-se a precisão na Borborema, Sertão e na Paraíba como um todo.

Os valores do *Kp*, por sua vez, foram os mais baixos dentre os de todas outras métricas empregadas neste trabalho, variando de 0,10 na Mata Paraibana, até 0,50 no Sertão, ao avaliar o SPI-48. Diferentemente dos resultados do *Kd*, é possível notar que há variabilidade dentre os resultados das mesorregiões, e que existe relação mais notória entre o *Kp* e a variabilidade da escala temporal. Para as secas de curto e médio prazo, os valores não ultrapassam a ordem de 0,40, enquanto que para as secas de longo prazo as regiões da Borborema e Sertão têm os resultados mais expressivos. No geral, os resultados para a Mata Paraibana e para o Agreste são os piores, tendo a Paraíba apresentado comportamento regular, como o das outras regiões.

Ao avaliar o índice de proporção correta *PC*, destaca-se similaridade desses resultados com os obtidos para o índice de concordância de Kendall não só no tocante ao comportamento dentre as mesorregiões mas também quanto à magnitude dos valores. Apesar de se notar leve aumento dos valores com o aumento da escala temporal, o comportamento das mesorregiões é homogêneo e os valores médios são de cerca de 0,80, o que mostra acurácia muito elevada do TRMM em identificar a ocorrência dos eventos secos e/ou úmidos. Assim como no caso do *R*, *RMSE*, *Kd* e *Kp*, os piores resultados foram encontrados na Mata Paraibana, no caso do SPI-48; mas nessa situação, esses não são tão ruins assim como nas outras métricas, tal que há um

percentual de acerto de 0,65. No geral, não há distinção entre o padrão das mesorregiões de modo significativo e os valores para o estado da Paraíba são satisfatórios (i.e., $PC > 0.80$).

Por fim, no intuito de avaliar o desempenho do satélite em captar a ocorrência dos eventos secos e/ou úmidos relacionados ao terceiro grupo de métricas, utilizou-se o diagrama de desempenho proposto por Roebber *et al.* (2009) para avaliar a probabilidade de detecção dos eventos secos POD , o índice de alarme falso ($1-FAR$) e o índice de sucesso crítico CSI para as mesorregião do estado da Paraíba em múltiplas escalas temporais (Figura 14). O eixo das abscissas é a probabilidade de detecção dos eventos secos, o eixo das ordenadas representa o índice de alarme falso e as linhas contínuas caracterizam o índice de sucesso crítico. Nesse sentido, percebe-se que os resultados entre as mesorregiões e escalas temporais revelam boa precisão do satélite quanto à identificação de eventos secos e/ou úmidos, mas alguns pontos merecem destaque nessa análise.

No geral, grande parte dos resultados estão sob a linha de inclinação de $\theta = 45^\circ$, o que caracteriza a melhor situação de precisão do satelite TRMM, pois indica que a relação entre o índice de alarme falso e probabilidade de detecção é linear, sem haver erros de subestimativas ou superestimativas dentre as métricas. Entretanto, ao avaliar as secas de longo prazo, nota-se que há uma tendência de que os valores de probabilidade de detecção sejam menores do que os do índice de alarme falso, o que faz com que vários pontos fiquem abaixo da linha $\theta = 45^\circ$. Por outro lado, ao avaliar as secas de menor escala de tempo, o cenário se inverte e os valores dos eixos das ordenadas ($1-FAR$) passam a ser maiores do que os das abscissas (POD). De todo modo, os resultados indicam que maior parte das mesorregiões apresenta o índice de sucesso crítico médio superior a 0,70 e menor do que 0,80, o que indica uma acurácia elevada.

Para a Mata Paraibana, os piores resultados foram encontrados ao avaliar o SPI-48, pois tanto o POD quanto o $1-FAR$ foram de cerca de 0,60 e CSI inferior a 0,50, menor valor dentre todas as análises. Para essa mesorregião, os resultados foram mais expressivos no caso das secas de médio prazo, pois tanto o índice de alarme falso quanto o POD foram maiores que 0,80, e o índice de sucesso critico manteve acurácia superior a 0,70. Já para o Agreste, os resultados do POD foram similares aos da Mata Paraibana, mas tiverem leve melhora. Para o índice de alarme falso, os resultados encontrados em relação aos da Mata foram quase iguais no caso das secas de curto prazo e médio prazo, mas notoriamente melhores que os das secas de longo prazo. O índice CSI nessa mesorregião variou de 0,60 a 0,75, nos melhores casos.

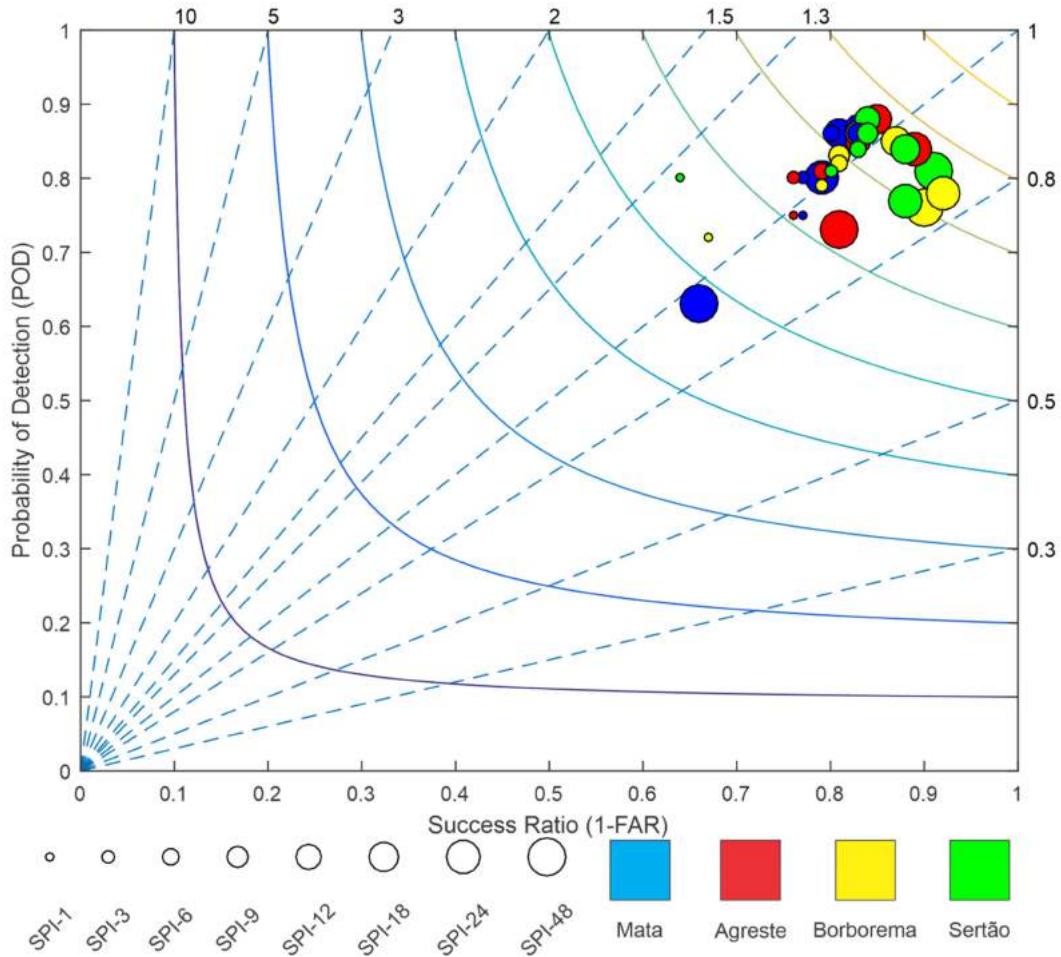


Figura 14 – Diagrama de desempenho de Roebber *et al.* (2009) para as mesorregiões da Paraíba.

Para a Borborema, os valores de *POD* são maiores do que os das regiões da Mata e do Agreste, a exceção do comportamento do índice SPI-48. O índice de alarme falso apresentou valores mais expressivos do que os dessas regiões, especialmente ao tratar das secas de longo prazo. Ao avaliar o índice de sucesso crítico, cabe pontuar o resultado obtido ao avaliar o SPI-1, que representou um dos piores dentre as análises, mas os demais resultados variaram entre 0,65 e 0,75. No caso do Sertão, os valores de *POD* são os maiores dentre as mesorregiões e variam em torno de 0,80, sendo os resultados das secas de médio prazo os melhores dentre as escalas de tempo. No caso do índice de alarme falso, a exceção do índice SPI-1, os resultados indicam alta precisão do satélite TRMM e esses valores em sua maioria foram os melhores do estado.

Além disso, destaca-se que há tendência de que os valores do índice de alarme falso sejam mais expressivos que os de probabilidade de detecção, tal como no caso da Borborema. Por fim, vale notar que o índice de sucesso crítico teve mesma grandeza de valores da região

da Borborema, com detalhe particular para o comportamento do índice SPI-1, cujo valor foi de 0,55. De certo modo, esse padrão de imprecisão do satélite TRMM nas regiões litorâneas do NEB já tinha sido discutido por outros estudos. Melo *et al.* (2015) e Rozante *et al.* (2018) avaliaram o desempenho dos produtos do TRMM no Brasil e concluíram que no Nordeste do país, região ao qual está inserida o estado da Paraíba, as estimativas TRMM não apresentam acurácia satisfatória na costa. Em contrapartida, na região semiárida, onde está inserido 80% da Paraíba (Macedo *et al.*, 2010), estudos apontam a precisão extremamente mais satisfatória, como comprovado com os resultados obtidos neste presente estudo. De modo mais específico, os resultados corroboram com os obtidos por Soares *et al.* (2016), que também identificaram que no litoral que apresenta os maiores níveis de chuvas, a acurácia do TRMM é reduzida.

5.3.QUANTO À CARACTERIZAÇÃO DAS SECAS

Após realizar a análise de acurácia estatística do satélite TRMM em captar o padrão das secas em múltiplas escalas temporais a partir de diferentes métricas, desenvolveu-se o processo de avaliação das principais características dos eventos de secas sobre a Paraíba. Nesse sentido, a Figura mostra a distribuição espacial da quantidade (*N*) e da intensidade média (*MDI*) dos eventos de seca e a Figura 16 mostra a distribuição espacial da severidade (*MDS*) e da duração média (*MDD*) desses eventos sobre o estado da Paraíba em múltiplas escalas temporais. Em geral, apesar da variabilidade espaço-temporal dessas características é possível perceber que há alta similaridade entre os resultados obtidos a partir dos dados de pluviômetros e das estimativas TRMM. Por outro lado, é preciso pontuar que também existem divergências entre os resultados e essas variam dentre as regiões e as escalas de tempo.

Em relação à quantidade de eventos atingiram o estado da Paraíba ao longo desses 20 anos, destaca-se elevada variabilidade dentre os valores ao avaliar os diferentes tipos de secas, tal que a quantidade é maior ao analisar o padrão das secas de curto prazo do que ao avaliar o comportamento das secas de longo prazo. Para o SPI-1, por exemplo, nota-se que em algumas regiões do Agreste ocorreram mais que 45 eventos, enquanto que para o SPI-48 esse valor não ultrapassou mais que cinco ocorrências. A causa desse resultado está intimamente ligada ao período de acumulação dos dados e à metodologia de cálculo do índice SPI: de fato, o SPI-1 é mais sensível às variações da precipitação do que o SPI-48 e por isso já era esperado que a sucessão de eventos secos ($SPI \leq 0$) fosse interrompida e reiniciada com maior frequência em se tratando das secas de curto prazo do que para as de longo prazo.

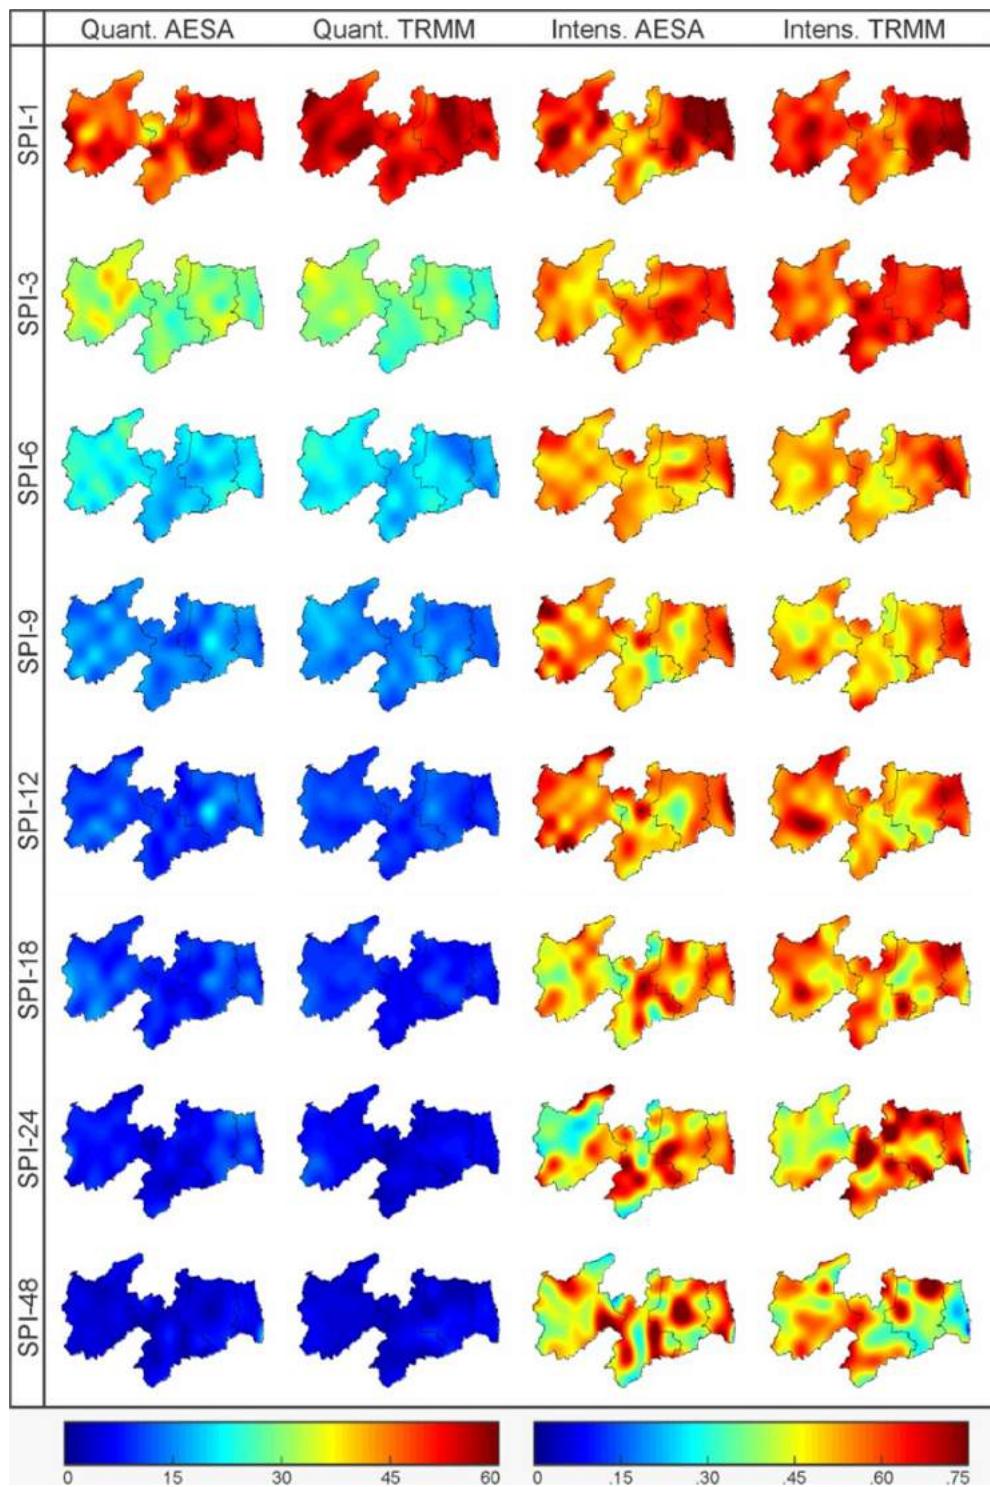


Figura 15 – Distribuição espacial da quantidade e da intensidade média dos eventos de seca sobre o estado da Paraíba (1998–2017).

Logo, é em função dessa frequente quebra da sucessão de eventos secos que o número de eventos de seca para as secas de curto prazo foi maior. Além disso, é possível perceber que o número de eventos de seca cai drasticamente com o aumento da escala temporal, tal que ao avaliar o SPI-6 a quantidade de eventos passa a ser de 20 em grande parte da região. Por outro

lado, ao avaliar os resultados estimados pelo TRMM, nota-se que as maiores inconsistências por parte do satélite foram encontradas ao avaliar o SPI-1, principalmente na região do Sertão e da Borborema, onde a quantidade de eventos estimada foi maior do que a encontrada com base nos dados de postos pluviométricos. Para o SPI-3 e o SPI-6, a quantidade de eventos de seca foi mais semelhante na maior parte do estado, destacando-se apenas a leve subestimativa na leste do Sertão no caso do SPI-3, e nas regiões do Agreste e Mata Paraibana para o SPI-6.

Para as secas de médio prazo, a quantidade de eventos foi ainda menor, principalmente em se tratando do SPI-12. Além disso, os resultados estimados pelo satélite foram parecidos com os obtidos a partir dos dados de pluviômetros, especialmente no caso do SPI-9. Já para o SPI-12, nota-se uma subestimativa do TRMM no centro do Agreste, assim como para as secas de curto prazo. Para as secas de longo prazo, a quantidade de eventos que atingiram a Paraíba foi muito inferior em comparação às demais escalas de tempo e também foi possível perceber que os valores estimados pelo satélite foram menores do que os obtidos a partir dos dados das estações em quase toda a Paraíba. Ao avaliar a duração e a severidade média dos eventos, por sua vez, nota-se que os resultados entre essas características são muito parecidos entre si, mas diferem notavelmente dos encontrados para a quantidade de eventos de seca.

De fato, esperava-se que os eventos mais duradouros fossem também os mais severos, bem como que quanto maior for à quantidade de eventos, menos duradouros e severos esses tenderão a ser. Desse modo, enquanto as secas de curto prazo apresentaram uma quantidade elevada de eventos, os índices SPI que caracterizam as secas de médio e longo prazo tiveram maiores valores de duração e severidade média. Ao avaliar o padrão das secas de curto prazo, nota-se que a duração e a severidade média dos eventos pouco ultrapassam três unidades, e.g., SPI-1. Em outras palavras, isso significa que os 45 eventos de seca que atingiram o Agreste apresentaram duração e severidade média de três meses e três unidades SPI, respectivamente. Para SPI-6, os eventos já passaram a apresentar duração e severidade maior que cinco meses e cinco unidades, valor de quase o dobro em comparação aos resultados do SPI-1.

Para as secas de médio prazo, os valores de duração e severidade média aumentaram quando comparados aos das secas de curto prazo, ultrapassando 15 meses e unidades SPI na zona limítrofe entre Borborema e Agreste com base nos dados de pluviômetros, e na fronteira entre Agreste e Borborema com base nas estimativas TRMM para o SPI-12. Em relação à similaridade entre os resultados das duas fontes de dados, destaca-se que as diferenças não são tão significativas no caso do SPI-9, mas ao avaliar o padrão do SPI-12 é possível perceber que nas regiões mais próximas ao litoral, os eventos tenderam a ser mais duradouros e severos

com base nas estimativas do satélite, enquanto que no interior do estado há subestimativa dessas grandezas.

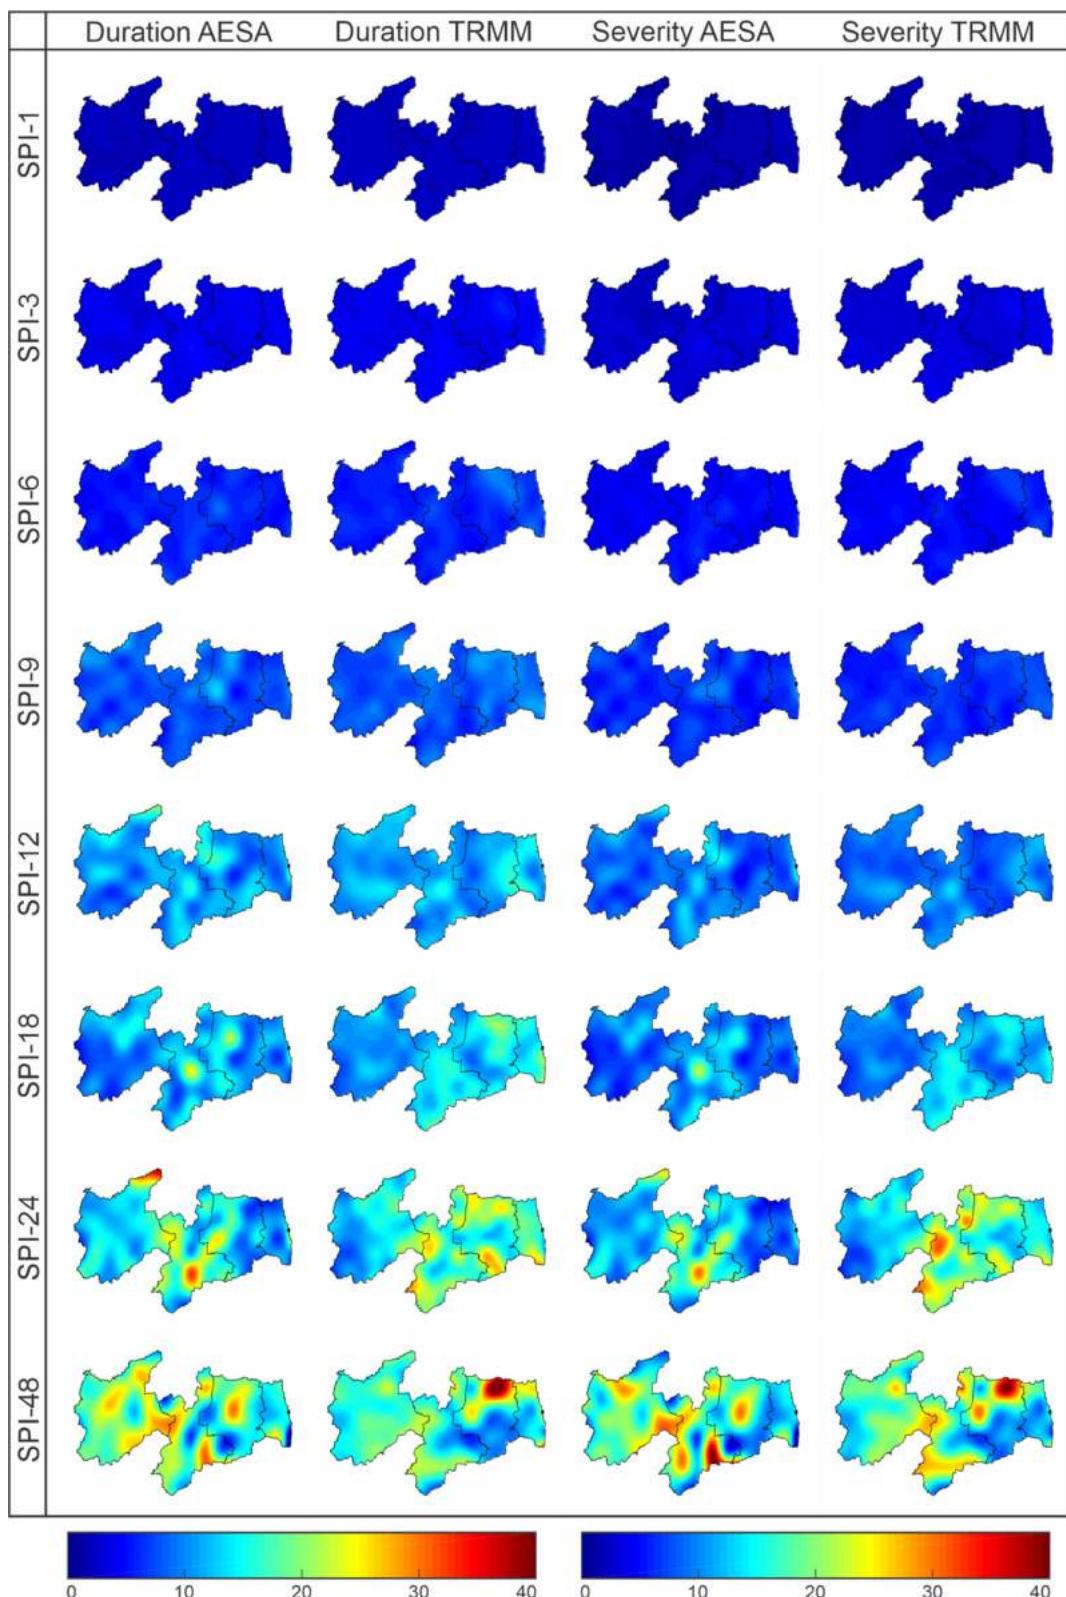


Figura 16 – Distribuição espacial da duração e da severidade média dos eventos de seca sobre o estado da Paraíba (1998–2017).

Para as secas de longo prazo foram encontrados os maiores valores de duração e de severidade média dentre os eventos de seca, tal que para o SPI-48, a duração média chegou a ultrapassar 30 meses e a severidade média a mais do que 30 unidades SPI. Esses valores são cerca de dez vezes maiores que os encontrados para as secas de curto prazo e indicam que os eventos de seca que atingiram o estado da Paraíba duraram mais do que três anos em algumas regiões. Em comparação com as secas de curto e médio prazo, destaca-se considerável perca de similaridade entre os resultados obtidos a partir das duas bases de dados e divergências significativas ao avaliar o comportamento do índice SPI-18, SPI-24 e SPI-48.

Para o SPI-18, houve alta superestimativa da duração e severidade média dos eventos de seca na Borborema, no nordeste do Agreste e em grande parte da Mata, mas na porção central da Borborema e no Sertão, os valores foram subestimados pelo satélite TRMM. Para o SPI-24, tal comportamento se intensifica e em grande parte da Borborema, do Agreste e da Mata Paraibana os eventos passaram a ter duração e severidade média maiores com base nos dados TRMM. No caso do SPI-48, destaca-se de modo particular o padrão dos resultados que foram encontrados no nordeste do Agreste, onde o satélite apontou eventos consideravelmente mais duradouros e severos se comparados aos resultados dos pluviômetros. Por outro lado, o comportamento contrário foi obtido no sudeste da Borborema, onde houve subestimativa do TRMM.

Ao avaliar a intensidade média dos eventos, destaca-se que os valores obtidos para os diferentes tipos de seca, i.e., curto, médio e longo prazo, não são tão diferentes uns dos outros assim como ocorreu ao avaliar a quantidade, a duração e a severidade média. Além disso, é possível perceber que os valores obtidos a partir da utilização das duas bases de dados foram muito similares e atingiram valor máximo de 0,75/mês. De modo ilustrativo, isso implica que em média, todos os eventos secos que compuseram um evento de seca tiveram magnitude de 0,75. De todo modo, apesar da homogeneidade mais acentuada da intensidade média entre os tipos de seca, é possível destacar variabilidade espaço-temporal dos resultados sobre o estado da Paraíba.

Para as secas de curto prazo, os eventos com maior intensidade média se concentraram especialmente no Agreste e na Mata no caso do SPI-1. Esse padrão foi mantido para o SPI-3 e SPI-6, mas com notória queda dos valores de intensidade nessas regiões. No geral, a porção central do Sertão e a sudeste da Borborema foram as zonas que com menor intensidade média dentre o comportamento das secas de curto prazo. Apesar da similaridade dentre os resultados das duas bases de dados, nota-se que em certas situações houve imprecisão do satélite TRMM

para captar corretamente a magnitude da intensidade média. Para o SPI-1, esses valores foram superestimados entre a Borborema e o Sertão e subestimados no norte da fronteira entre a Mata Paraibana e o Agreste.

Para o SPI-3, a intensidade média dos eventos de seca foi superestimada pelo TRMM sobre a região, principalmente no Sertão e na Borborema. Os resultados do SPI-6, por sua vez, são muito similares, destacando-se apenas a incoerência na parte central da Borborema e norte e no sul do Agreste. A ordem de grandeza da intensidade média das secas de médio prazo não se alterou significativamente em comparação às secas de curto prazo, mas é possível perceber que houve queda desses valores em algumas regiões a partir do uso de dados de pluviômetros. Em geral, o comportamento do SPI-9 em muito se assemelha ao do SPI-6 para ambas as bases de dados, tendo sido os valores mais expressivos encontrados próximos ao litoral e em grande parte do Sertão, enquanto os eventos menos intensos se concentraram na Borborema.

Apesar da similaridade entre os resultados, os valores estimados pelo satélite menores do que os obtidos a partir dos pluviômetros no noroeste do Sertão e no norte da fronteira entre a Borborema e Agreste, mas foram precisos nas demais regiões. No caso do SPI-12, destaca-se a similaridade entre esse índice e o SPI-9, especialmente em se tratando dos resultados de pluviômetros. Todo o Sertão e a faixa que se estende da porção central do Agreste até o litoral tiveram os eventos mais intensos, enquanto a zona limítrofe entre Agreste e Borborema foi a zona com os menores valores de intensidade. Todavia, a distribuição espacial obtida ao usar as diferentes bases de dados é semelhante, o que de mostra a precisão do satélite TRMM para monitorar essa característica das secas.

Para as secas de longo prazo, fica o evidente aumento na variabilidade entre os valores de intensidade média, tendo sido encontrados os maiores (e.g., $MDI = 0.80/\text{mês}$) e os menores (e.g., $MDI = 0.20/\text{mês}$) valores dentre os demais tipos de secas. Destaca-se que não há padrão definido entre as escalas temporais, e por tal motivo, em alguns casos o litoral é a zona com os eventos menos intensos (e.g., SPI-48) e em outros é a que apresenta os mais altos valores de intensidade média (e.g., SPI-24). Para o SPI-18, houve superestimativa dos resultados dos pluviômetros no Sertão e no sudoeste da Borborema, assim como no caso do SPI-24, e para o SPI-48 os resultados entre as bases de dados foram incoerentes sobre o estado, especialmente na Borborema, no Agreste e na Mata Paraibana, assim como no caso da análise da duração e severidade média dos eventos de secas (Figura 16).

Feita a distribuição espacial dessas quatro características sobre o estado da Paraíba, foi desenvolvida a análise considerando o comportamento de cada mesorregião e nesse sentido, a Figura 17 mostra a análise do número, duração, severidade e intensidade média dos eventos de seca para as mesorregiões da Paraíba em múltiplas escalas temporais. A partir dessa figura, é possível perceber há queda considerável na quantidade de eventos de seca a medida que a escala temporal aumenta, e os resultados variam de mais de 50 no caso do SPI-1, até menos de cinco, para o SPI-48. No geral, o maior número de eventos aconteceu no Sertão e Agreste e em menor quantidade nas regiões da Mata Paraibana e da Borborema.

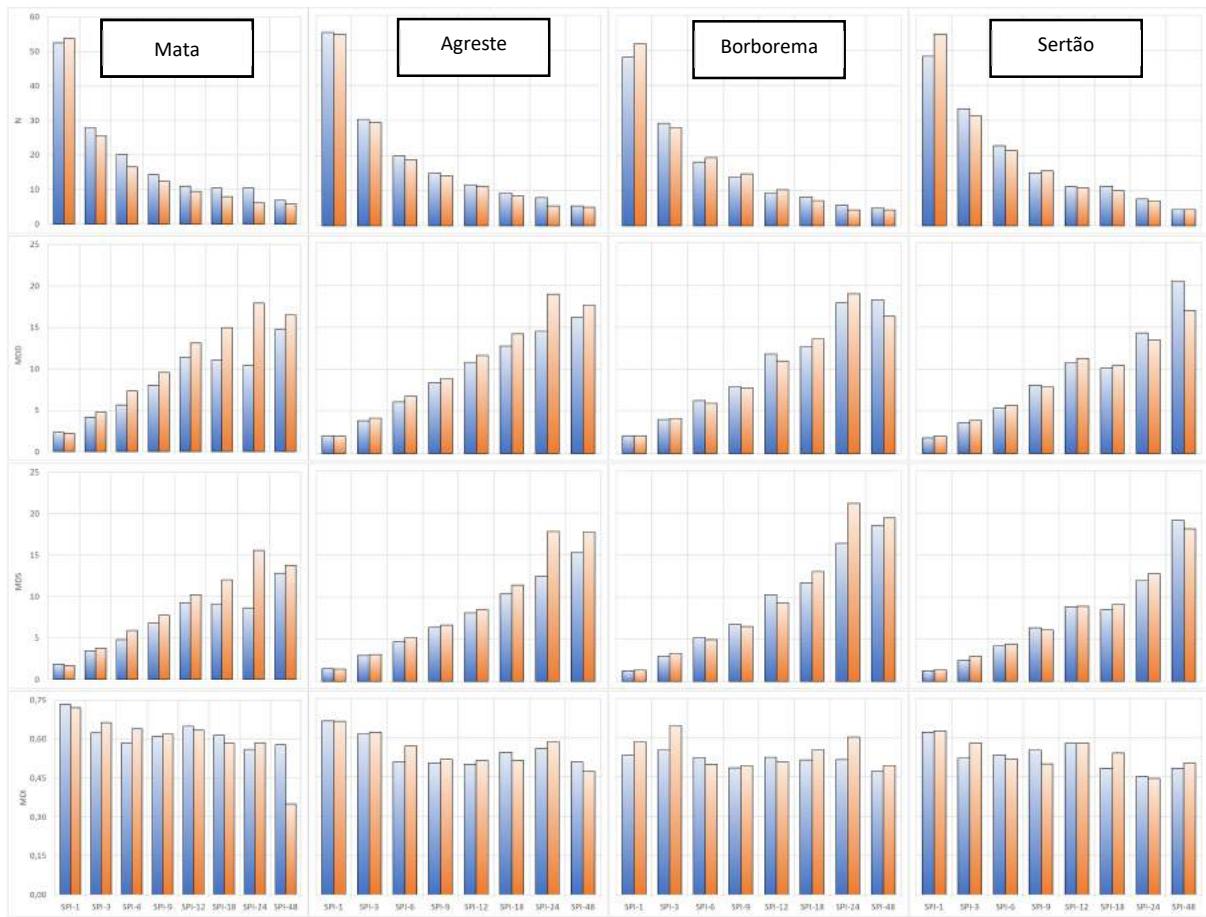


Figura 17 – Análise do número de eventos de secas e duração, severidade e intensidade média dos eventos de secas para as mesorregiões do estado da Paraíba em múltiplas escalas temporais (1998–2017). Os dados de postos pluviométricos estão em azul e os do TRMM em vermelho.

Além disso, é possível perceber que na maioria dos casos os resultados do TRMM são subestimados em todas as mesorregiões, salvo as exceções que ocorrem ao avaliar o SPI-1 na Mata Paraibana, Borborema e Sertão, e o padrão dos índices SPI-6 e SPI-9 na Borborema. De todo modo, a quantidade de eventos ao longo desses 20 anos para cada mesorregião indicam

que existe precisão do TRMM ao captar essa característica. Para a duração e severidade média dos eventos de seca, nota-se que diferentemente da análise desenvolvida para a quantidade de eventos, há crescimento notório da durabilidade e da severidade com o aumento da escala de tempo. A duração média dos eventos a quase 20 meses e a severidade média fica na ordem de 16 unidades SPI no caso das secas de longo prazo, o que realça a variabilidade dos resultados.

No tocante à duração, pode-se perceber que diferentemente da análise desenvolvida ao avaliar a quantidade de eventos, as regiões da Mata Paraibana, Agreste e Borborema foram as que tiveram os valores mais expressivos, enquanto o Sertão teve os eventos mais curtos. Além disso, há tendência do TRMM em superestimar os valores de duração na Mata e no Agreste e isso ocorreu de modo mais significativo ao avaliar as secas de longo prazo. Para a Borborema e o Sertão a duração foi predominantemente subestimada pelo TRMM, mas as inconsistências entre as bases de dados não ocorreram de maneira tão expressiva como nas mesorregiões do litoral. Ao avaliar a severidade média dos eventos de seca, nota-se que as mesorregiões mais próximas ao litoral apresentaram os valores mais expressivos especialmente para as secas de curto e médio prazo, enquanto as zonas do interior apresentam severidade das secas de longo prazo mais acentuadas.

Para a Mata e Agreste quase todos os valores de severidade foram superestimados pelo TRMM, assim como na análise de duração. Para a Borborema e Sertão, esse comportamento se manteve no caso das secas de longo prazo, mas para as secas de curto e médio, esse padrão se inverteu. Além disso, ao comparar esses resultados com os obtidos ao avaliar a quantidade de eventos, destaca-se que as inconsistências entre as bases de dados são mais expressivas no caso dessas duas últimas características do que para a análise da quantidade de eventos. Em se tratando da intensidade média, nota-se que não há variabilidade signifíca dos valores entre os diferentes tipos de secas para uma mesma mesorregião, apesar de que os eventos de curto prazo são levemente mais intensos do que os de médio e longo prazo.

A intensidade média dos eventos de seca da Mata Paraibana foi maior entre as outras regiões, e isso é mais evidente ao tratar das secas de médio e longo prazo. Ao realizar uma análise comparativa entre as bases de dados, é possível perceber que para as secas de curto prazo os valores de intensidade média são superestimados em quase todas as mesorregiões. Para as secas de médio prazo, os resultados são mais similares, e para as secas de longo prazo há subestimativa dos valores estimados pelo TRMM na Mata e no Agreste e superestimativa na Borborema e no Sertão. Ao discutir sobre os resultados encontrados nesta pesquisa com os de outros estudos, destacam-se alguns pontos relevantes.

Awange *et al.* (2016) monitoraram os eventos de seca no Brasil por mais 100 anos e não encontraram diferenças notáveis entre as intensidades médias dos eventos de seca nessas múltiplas escalas de tempo sobre a Paraíba. Recentemente, Brito *et al.* (2018) caracterizaram os eventos de seca na região Nordeste do país com base no SPI-12 e concluíram que há forte relação entre duração e severidade média dos eventos de seca e que esses eventos foram mais expressivos entre os períodos de 1996–2001 e 2011–2016. Nessas duas ocasiões, foi possível perceber que as mesorregiões da Borborema e do Agreste foram as zonas mais atingidas pelos eventos de seca, tal como exposto pelos nossos resultados.

Do mesmo modo, Macedo *et al.* (2011) avaliaram a evolução das secas no município de Campina Grande, no Agreste da Paraíba, em diferentes escalas de tempo e concluíram que ao aumentar a escala temporal, há aumento na duração e severidade média, enquanto que para a intensidade dos eventos de seca a ordem de grandeza dos valores é constante. O mesmo se aplica aos resultados encontrados por Farias *et al.* (2014), que desenvolveram uma pesquisa sobre o município de Taperoá, na região da Borborema, e mostraram que os eventos tenderam a apresentar intensidade média entre 0,50 e 0,75, assim como obtido no presente estudo. Assim, mesmo que tais estudos tenham considerado outros períodos e dados de precipitação e apesar de saber que isso influencia os resultados, pontua-se a consistência dos resultados obtidos.

Feita a caracterização dos eventos de secas quanto à quantidade, duração, severidade e intensidade média, a análise de frequência dos diferentes tipos de eventos secos sobre o estado da Paraíba foi realizada. Desse modo, a Figura 18 e Figura 19 mostram a distribuição espacial da frequência dos eventos suavemente, moderadamente, severamente e extremamente secos sobre o estado da Paraíba ao longo do período de 1998 a 2017. Ao comparar os resultados dos diferentes tipos de eventos secos, nota-se que os maiores valores percentuais são encontrados para os eventos suavemente secos, seguidos dos eventos moderados, severos e extremos. Cabe destacar que esse resultado era esperado e corrobora com a metodologia de cálculo do SPI; como o cálculo do índice leva em consideração as probabilidades de ocorrência de cada tipo de com base em sua raridade, espera-se que os eventos extremamente secos, que são os mais raros dentre os tipos de eventos secos sejam menos frequentes que os eventos suaves.

Além disso, para um mesmo tipo de evento há grande variabilidade entre o percentual de ocorrência dentre os diferentes índices SPI utilizados para caracterizar o comportamento das secas de curto, médio e longo prazo. Para os eventos suavemente secos, há grande desvio entre os valores percentuais, tal que esses variam de 10% ao avaliar as secas de longo prazo, até 60% no caso das secas de curto prazo. Com base nos dados dos postos pluviométricos, o

Agreste e o Sertão foram as regiões que apresentaram os maiores valores percentuais ao serem avaliadas as secas de curto, médio prazo e longo prazo. No caso do SPI-1 e SPI-3, os valores mais notáveis também se estenderam na região da Borborema, e para os índices SPI-18 e SPI-24, até a Mata Paraibana. Em comparação aos resultados estimados pelo satélite, observa-se similaridade entre os produtos obtidos em diversas ocasiões.

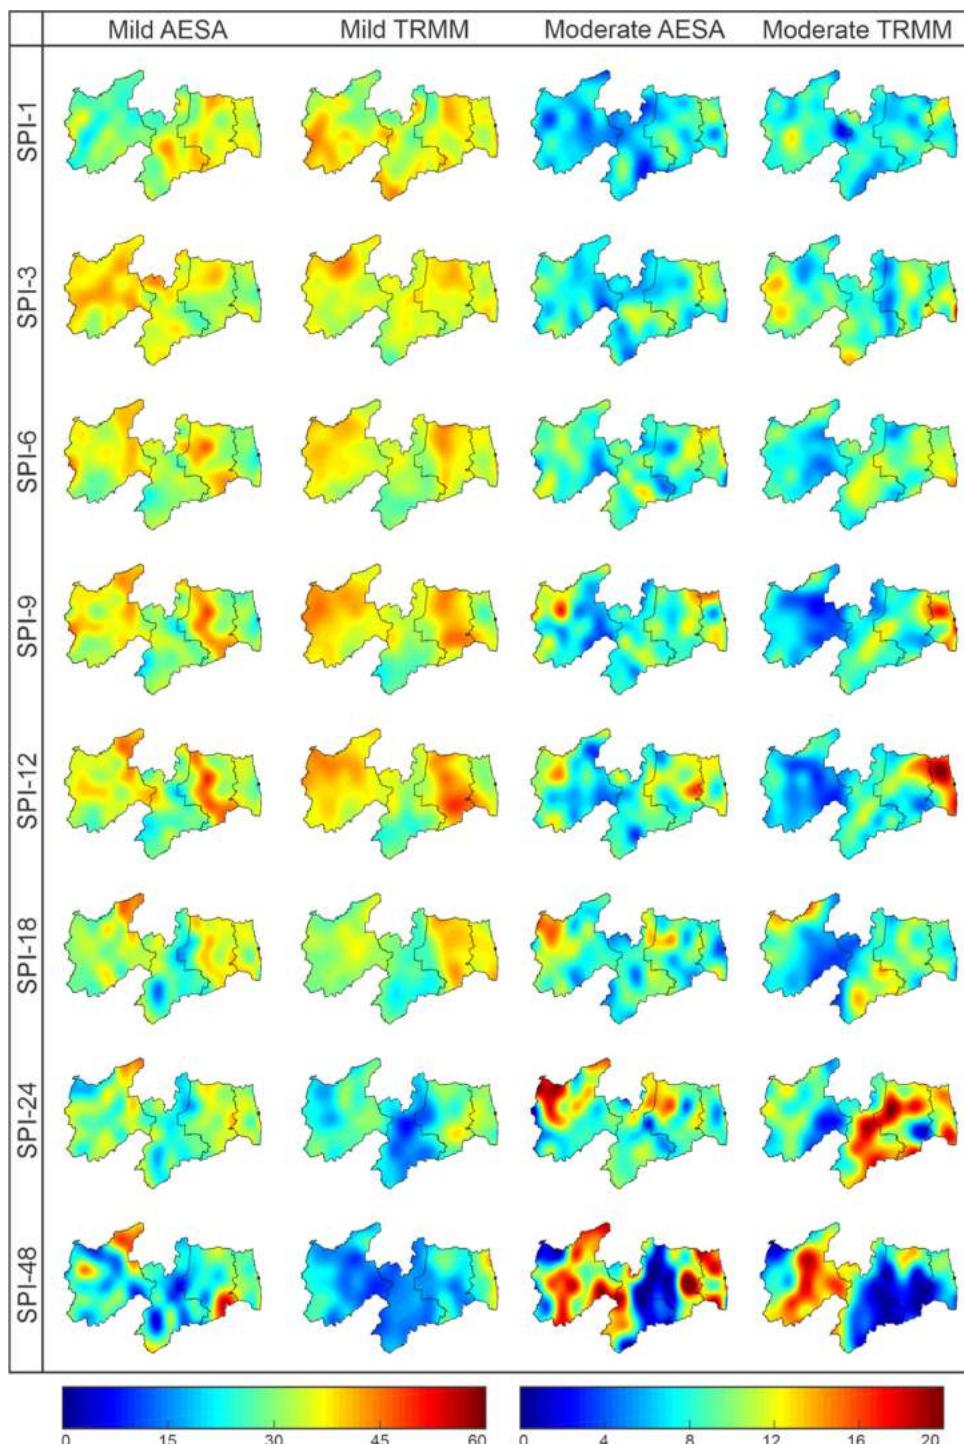


Figura 18 – Distribuição espacial do percentual de ocorrência de eventos suavemente e moderadamente secos sobre o estado da Paraíba (1998–2017).

Apesar de erros relacionados à superestimativa e subestimativa, nota-se que no geral, as estimativas do TRMM foram capazes de captar a distribuição espacial da frequência de eventos suavemente secos sobre o estado da Paraíba. De todo modo, é válido destacar que os percentuais foram superestimados pelo TRMM, de maneira mais expressiva no sudoeste do Sertão no caso do SPI-1, e no noroeste do Sertão e no Agreste como um todo no caso do SPI-9 e SPI-12. Todavia, os erros relacionados à subestimativa ocorreram de modo mais notável no caso dos índices SPI-24 e SPI-48 no Sertão e Borborema. Para os eventos moderadamente secos, por sua vez, a variabilidade entre os percentuais de ocorrência diminuíram e variaram de 0 a 20%.

Apesar da diminuição, ainda existe grande variabilidade no comportamento dentre as regiões e escalas de tempo. Além disso, diferentemente dos resultados obtidos para os eventos suavemente secos, nota-se que os maiores percentuais dos eventos moderadamente secos ocorreram predominantemente ao avaliar o padrão das secas de médio e de longo prazo, em especial para os índices SPI-12, SPI-24 e SPI-48. Com base nos dados da AESA, os valores percentuais mais expressivos ocorreram na fronteira da Mata Paraibana e do Agreste ao avaliar as secas de curto, médio e longo prazo, mas é necessário destacar que também houve aumento gradual no percentual de ocorrência desses eventos no oeste do Sertão com aumento da escala de tempo.

Ao utilizar as estimativas do satélite TRMM, nota-se que as regiões da Mata Paraibana e do Agreste continuam a ser as que apresentam os maiores percentuais dentre as outras regiões ao avaliar as secas de curto e médio prazo. Além disso, pontua-se a superestimativa desses valores por parte do TRMM no litoral, assim como também é possível perceber a subestimativa dos percentuais de maneira mais significativa no Sertão da Paraíba. Ao avaliar as secas de longo prazo, a distribuição espacial dos valores se altera, de modo que a Borborema passa a apresentar os valores mais altos no caso do SPI-24 e o mesmo acontece para o Sertão no caso do SPI-48. Para esses dois índices, as incoerências entre os dados de pluviômetros e estimativas do TRMM foram significativas em diversas regiões do estado.

Para os eventos severamente secos, os resultados apontam que tanto os desvios quanto a magnitude dos valores percentuais caíram, variando entre 0 a 15%. No geral, a variação da escala temporal passa a influenciar a magnitude do percentual de ocorrência dos eventos e nesse sentido, diferentemente do que ocorreu ao avaliar os eventos suavemente secos, os valores mais expressivos ocorrem de modo predominante para as secas de longo prazo. Independentemente da base de dados utilizada, é válido destacar que a região da Borborema

apresenta os maiores percentuais de ocorrência no caso das secas de médio prazo, mas esses não chegam a ultrapassar 10%. De todo modo, como esses eventos são raros, esse percentual de ocorrência é alto tendo em vista que a probabilidade cumulativa global de sua ocorrência é de menos de 5% (Santos *et al.*, 2019b).

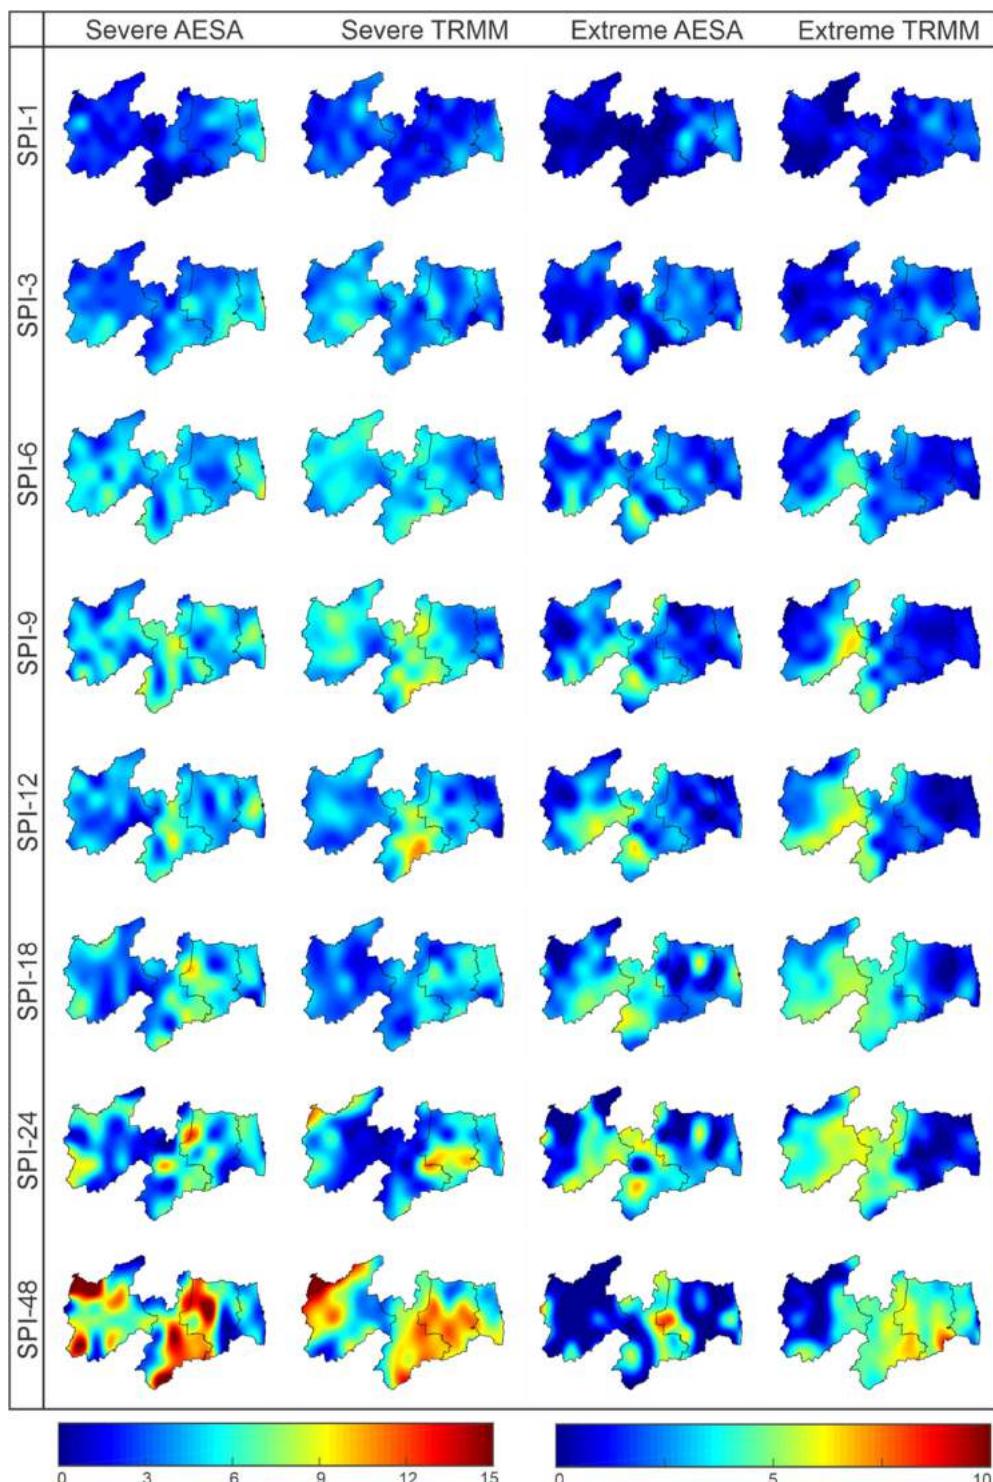


Figura 19 – Distribuição espacial do percentual de ocorrência de eventos severamente e extremamente secos sobre o estado da Paraíba (1998–2017).

Dentre os índices SPI, o que teve o comportamento mais notável foi o SPI-48. Para tal escala temporal, os valores foram os mais altos mesmo ao considerar ambas bases de dados. Os resultados do TRMM corroboraram com os dos pluviômetros no Sertão, mas foram mais incoerentes na Borborema e no sul do Agreste. Ao avaliar os eventos secos extremos, nota-se que existem os menores desvios e percentuais, se comparados aos outros tipos de eventos. Com valores que variam entre 0 a 10%, destaca-se que esse padrão espacial difere muito do encontrado para os outros tipos de eventos secos, bem como ressalta-se a semelhança entre os resultados das bases de dados, que é mais evidente ao avaliar as secas de curto e médio prazo.

Para as secas de longo prazo, há discordância entre os resultados obtidos com base em postos pluviométricos e nas estimativas do TRMM. Com base nos dados de postos, o sudeste e leste do Sertão e maior parte da Borborema são as mesorregiões que apresentam os maiores percentuais de eventos extremos para SPI-18 e SPI-24. Para o SPI-48, a faixa limítrofe entre a Borborema e o Agreste apresenta os resultados mais expressivo, destacando-se também o padrão singular do nordeste do Agreste. A partir dos dados estimados, nota-se superestimativa dos valores no Sertão e na Borborema como um todo ao avaliar os índices SPI-18 e SPI-24. Ao avaliar o SPI-48, as inconsistências são ainda maiores, com superestimativa relevante no leste do Sertão, no Agreste e na Mata.

Nessas regiões mais próximas ao litoral, é possível perceber que enquanto os valores estimados pela base de dados de postos pluviométricos foram quase nulos, esses chegaram a quase 10% com base nas estimativas do TRMM. Essa mudança pode não parecer tão elevada, mas ao utilizar a probabilidade cumulativa de ocorrência desses eventos como referência, i.e., 2.21%, destaca-se que essa distorção é extramente relevante. Nesse sentido, destaca-se que as estimativas do TRMM não são adequadas para monitorar esse tipo de eventos nessas regiões. Em seguida, depois de realizar a distribuição espacial do percentual de ocorrência dos quatro eventos secos, desenvolveu-se uma análise considerando o comportamento das mesorregiões. Nesse sentido, a Figura 20 mostra a análise de frequência desses quatro tipos de eventos secos para as mesorregiões da Paraíba em várias escalas de tempo.

Como esperado, há grande variabilidade do percentual de frequência dos tipos eventos secos entre as mesorregiões e a similaridade entre os resultados provenientes das duas bases de dados varia dentre as escalas temporais. De modo geral, percebe-se que há uma tendência de que o percentual de eventos secos em geral diminua com o aumento da escala temporal, mas esses eventos secos passam a ser mais relevantes, i.e., a apresentar uma magnitude mais expressiva, sendo esse cenário mais evidente ao utilizar os dados do TRMM. Entretanto, esse

comportamento geral não se aplica aos resultados encontrados na Mata Paraibana, tal que foi possível manter homogeneidade dos percentuais mesmo com a alteração da escala temporal. Para essa mesorregião, metade dos eventos foram secos, independentemente da base de dados ou da escala temporal utilizada.

Todavia, é válido notar que existem incoerências entre os valores obtidos a partir dos dados de pluviômetros e das estimativas do TRMM. Para as secas de curto prazo, o percentual de eventos suavemente secos foi superestimado pelo TRMM, mas os de eventos severamente e extremamente secos foi subestimado. Para as secas de médio prazo o padrão se manteve, mas também passou a existir uma tendência de superestimativa dos eventos moderadamente secos por parte do TRMM. Já para secas de longo prazo os resultados foram menos precisos, especialmente ao tratar do SPI-48, tal que os percentuais de eventos secos moderados foram significativamente subestimados, enquanto que os severamente e extremamente secos foram superestimados pelo satélite.

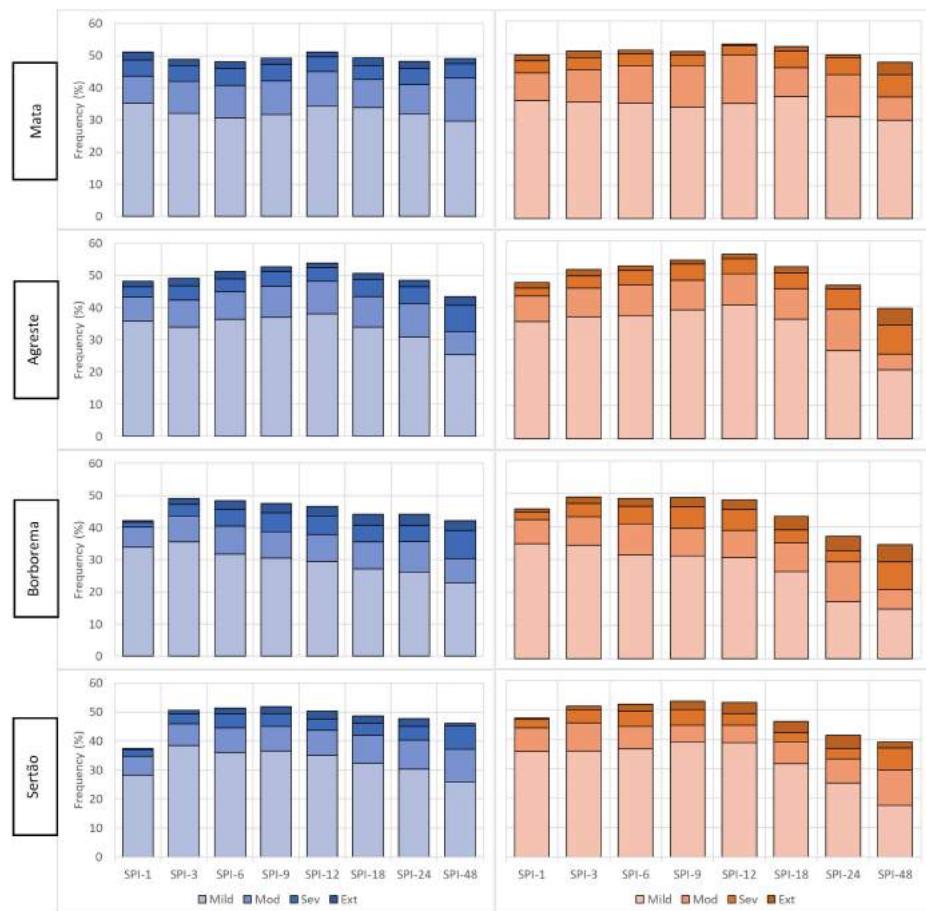


Figura 20 – Análise de frequência dos tipos de eventos secos para as mesorregiões do estado da Paraíba em múltiplas escalas temporais utilizando dados de pluviômetros (à esquerda) e TRMM (à direita) (1998–2017).

Para o Agreste, há elevada similaridade entre os resultados obtidos a partir dos dados de pluviômetros e das estimativas do TRMM, tal que para as secas de curto e médio prazo o satélite foi captou com precisão o percentual de ocorrência dos tipos de eventos secos, sem subestimar ou superestimar os valores oriundos dos pluviômetros de forma expressiva. Já para as secas de longo prazo, as incoerências são mais notáveis, especialmente em se tratando dos índices SPI-24 e SPI-48. Para o SPI-24, o TRMM superestimou os eventos moderadamente e severamente secos, mas subestimou o percentual de eventos suaves e extremos. Para o SPI-48, o percentual dos eventos mais suaves foi subestimado, mas a superestimativa dos eventos extremos por parte do satélite foi uma das mais expressivas dentre as mesorregiões.

Para a Borborema, o SPI-1 apresentou baixo percentual de eventos secos e esse foi um comportamento singular se comparado ao padrão predominante das secas de curto prazo. Ao comparar os resultados entre as bases de dados, percebe-se que para as secas de curto e médio prazo os resultados são similares entre si, assim como encontrado no Agreste. Para as secas de longo prazo, por sua vez, o percentual de eventos secos ao todo tende a ser subestimado pelo satélite, e isso é fruto da subestimativa do percentual de eventos suavemente, moderadamente e severamente secos, salvo à exceção do resultado encontrado ao avaliar o SPI-18 e SPI-24 no caso dos moderadamente secos. Mesmo assim, há notória superestimativa dos percentuais de eventos extremamente secos, especialmente em se tratando do índice SPI-48.

Os resultados encontrados no Sertão se assemelham aos da Borborema, mas é possível notar maior variabilidade entre os resultados das bases de dados entre as categorias de eventos secos. Já ao avaliar as secas de curto prazo, destaca-se que há superestimativa do percentual de todos os tipos de eventos secos no caso do SPI-1, e isso resultou uma diferença de mais de 10% no percentual total. Para as secas de médio prazo, os resultados foram subestimados para o eventos moderadamente secos, mas para as demais categorias, especialmente em se tratando dos eventos mais extremos, houve superestimativa do percentual a partir do satélite TRMM. No caso das secas de longo prazo, à exceção dos eventos mais raros, em todos as situações os percentuais foram subestimados pelo satélite, comportamento oposto ao encontrado ao avaliar as secas de curto prazo.

Por fim, diante do elevado potencial extensivo das secas, foi desenvolvida uma análise para avaliar o percentual de área atingida pelos diferentes tipos de eventos secos ao longo dos 20 anos, considerando as duas bases de dados e as múltiplas escalas temporais (Figura 21). A partir dessa figura, percebe-se que cada uma das cores expressa uma das quatro categorias de eventos secos e é interessante destacar que a soma percentual de todos esses tipos resultam no

percentual total de área afetada por eventos secos. Optou-se por detalhar quais foram os tipos de eventos secos e qual percentual de área atingida por cada tipo de evento a fim de realizar uma caracterização mais robusta a respeito do fenômeno da seca ao longo do tempo. Além do mais, é interessante destacar que os resultados provenientes do uso de dados de pluviômetros foram organizados em sentido normal, enquanto que os oriundos do TRMM estão invertidos.

No caso, a concepção foi adotada no intuito de facilitar a comparação visual e avaliar a similaridade entre as bases de dados, tal que quanto mais similares forem os resultados para cada índice, mais espelhadas serão as figuras. Diante do exposto, é possível perceber que os percentuais de área atingida pelos diferentes tipos de eventos são muito parecidos ao decorrer dos anos e nas múltiplas escalas temporais, mas ainda é possível perceber algumas diferenças pontuais que fazem com que as figuras não estejam perfeitamente espelhadas. Ao avaliar o SPI-48, por exemplo, todo o estado foi atingido por eventos secos no final de 2015 e grande parte foi afetada por eventos extremamente secos, sendo 86,6% com base nas estimativas do TRMM e 21,5% utilizando os dados de pluviômetros.

Para as outras categorias, i.e., os suavemente, moderadamente e severamente secos, os percentuais foram de 4,1%, 14,0% e 60,4% ao utilizar os dados de postos pluviométricos e de 0,0%, 0,0% e 13,4% utilizando as estimativas do satélite TRMM. Nesse caso, apesar de 100% da área ter sido atingida por eventos secos, nota-se uma superestimativa no percentual de área atingida por eventos extremamente secos por parte dos dados do satélite. Por isso, destaca-se a importância dessa figura diante da possibilidade de detalhar não só quais foram os períodos mais secos, mas de identificar quais foram os tipos de eventos secos predominantes, dado esse que tem alta relevância quanto à análise das secas (Jesús *et al.*, 2016; Caloiero, 2017; Caloiero *et al.*, 2018).

Comparando os resultados dos diferentes índices SPI, percebe-se que há ocorrência de eventos secos sobre o estado da Paraíba com mais frequência para as secas de curto que para as secas de longo prazo. Para o SPI-1, os eventos suavemente atingem parte do estado ao longo de todo o período, enquanto que para as secas de médio e longo prazo, existem fases em que não houve ocorrência de algum tipo de evento seco, e.g., entre 2009 e 2010 para o SPI-24 e entre 2011 e 2012 ao avaliar o SPI-48. Em contrapartida, os eventos secos mais severos passam a atingir grande parte da região de modo contínua ao considerar o comportamento das secas de longo prazo, e.g., entre 2012 e 2014 para o índice SPI-12. Esse resultado é parecido ao obtido na Figura 9, tal que para as secas de maior escala temporal, é possível identificar com precisão qual o início e fim dos episódios mais secos da região.

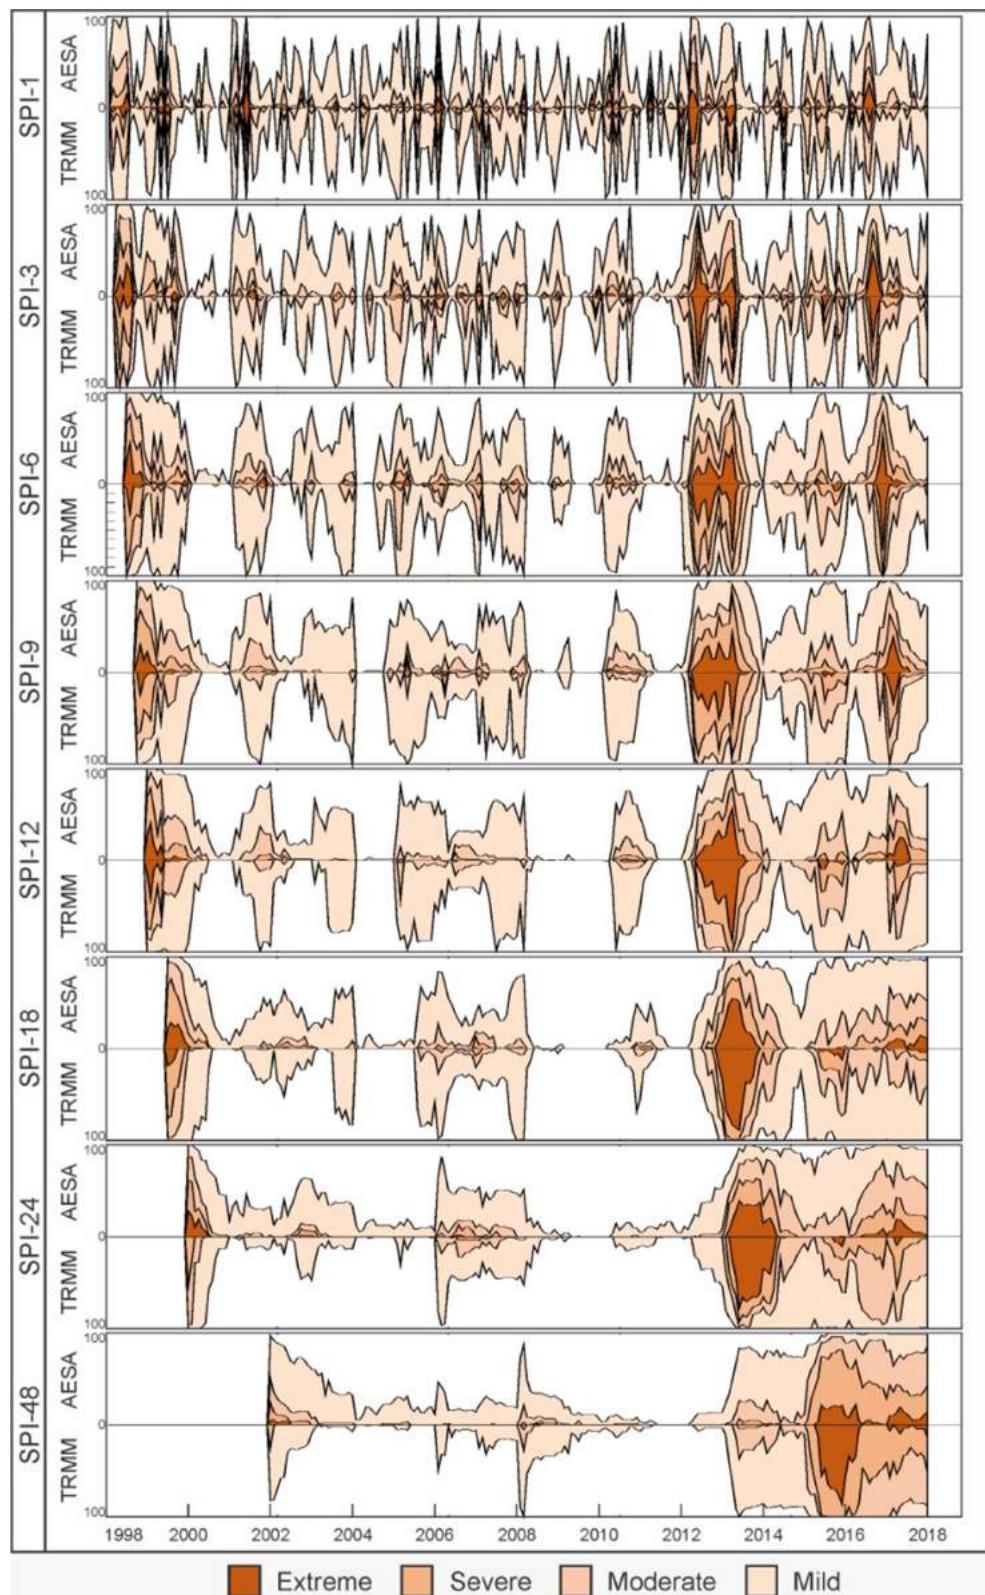


Figura 21 – Variação do percentual de área atingida pelos tipos de eventos secos sobre o estado da Paraíba utilizando dados de pluviômetros e as estimativas do TRMM (1998–2017).

Analizando os períodos em que a região foi atingida pelos eventos secos mais severos, destacam-se para as secas de curto prazo, os períodos entre 1998 e 1999, o ano de 2012 e o

final de 2016. Para as secas de médio prazo, realça-se mais uma vez o comportamento notável obtido no período entre 1998 e 1999, e especialmente entre 2012 e 2013. Neste último evento, o percentual de área atingida por eventos extremamente secos chegou a ser de 87,9% e 56,6% utilizando as estimativas do satélite TRMM e os dados de pluviômetros, respectivamente, o que demonstra a ocorrência de um dos eventos de seca mais extensivos do estado. Para as secas de longo prazo, há aumento no percentual de área atingida pelos eventos extremamente secos ao decorrer do tempo, tal que foram encontrados os maiores valores dentre os demais índices SPI. Para essas escalas temporais, o período mais crítico, quanto ao percentual de área atingida por eventos secos foi notoriamente o que se iniciou em 2012 e perdurou até o final de 2017.

Em comparação com os resultados de outros estudos, nota-se que o TRMM foi capaz de captar com precisão os eventos secos mais severos ao longo desses 20 anos analisados. De modo geral, Brasil Neto *et al.* (2016) identificaram que 2015 foi o ano que apresentou a maior quantidade de dias consecutivo secos sobre o estado da Paraíba e isso certamente influenciou as condições de umidade da região e favoreceu a configuração expressiva desse eventos. Em seguida, os resultados encontrados por Brasil Neto *et al.* (2017) mostram que nesse mesmo período foi encontrado um elevado percentual de eventos extremamente secos sobre toda a região e esse eventos foram em maioria extremamente secos. Brito *et al.* (2018) afirmaram que, com base no SPI-12, os eventos de secas mais expressivos sobre a região ocorreram de 1996–2001 e de 2011–2016, corroborando com os resultados apresentados na Figura 21.

Segundo Marengo *et al.* (2018), alguns eventos de seca merecem destaque desde o século XVI no nordeste do Brasil e dentre eles, ressaltam-se os períodos de 1998, 2001–2002, 2005, 2010 e 2012–2016, e esses foram predominantemente identificados pelo TRMM. Brasil Neto *et al.* (2019), sob outro ponto de vista, mostraram a ocorrência desses fenômenos ao avaliar a sua influência na saúde das culturas e da coberta vegetal em quatro regiões distintas da Paraíba, concluindo que as secas puderam ser não só captadas pelo TRMM como passaram a influenciar negativamente o desenvolvimento agrícola na região. Todavia, apesar da notória capacidade do satélite TRMM ao captar o percentual de área atingida pelos diferentes tipos de eventos secos, foi realizada uma análise estatística para validar a precisão do satélite.

Nesse sentido, a Tabela 2 mostra a variação do coeficiente de correlação Pearson (R) e da raiz do erro médio quadrático normalizada ($NRMSE$) entre as séries de percentual de área atingida oriundas das duas bases de dados, considerando quatro categorias de eventos secos e as múltiplas escalas temporais. No caso, a normalização do valor do $RMSE$ foi feita a partir da

razão entre esse valor e a média percentual de área atingida a partir dos dados de postos, no intuito de viabilizar a comparação entre os resultados das categorias. Logo, os dois primeiros valores, i.e., 0,65 e 3,75, indicam que o R e $NRMSE$ calculados entre as séries de percentual de área atingida por eventos extremamente secos com base nos dados de pluviômetros e de satélite foram de 0,65 e de 3,75 no caso do SPI-1, respectivamente e esse resultado mostra que a associação linear entre essas séries não é elevada, mas a raiz do erro quadrático normalizado sim.

Esse exemplo se aplica às demais categorias de eventos secos e escalas temporais e de posse dessas informações é possível verificar estatisticamente quais os erros e os acertos mais notáveis do TRMM ao captar o percentual de área atingida sobre a região. Cabe notar que os resultados apresentam alta variabilidade e isso é perceptível ao avaliar os diferentes índices SPI e as diferentes classes de severidade. Para os eventos extremamente secos, os melhores resultados foram os das secas de médio prazo, tanto ao avaliar o R quanto o $NRMSE$. Para o índice SPI-9, por exemplo, o valor R foi de quase 0,90, o que aponta que há uma associação linear entre as séries muito expressiva. Os valores $NRMSE$, por sua vez, revelam que também houve precisão por parte do TRMM ao captar a magnitude do percentual de área atingido por eventos desse tipo ao decorrer do tempo, mas essa variação ainda assim foi considerada alta.

Tabela 2 – Variação do coeficiente de correlação de Pearson (R) e da raiz do erro médio quadrático normalizado ($NRMSE$) entre as séries dos pluviômetros e TRMM considerando as múltiplas categorias de eventos e escalas temporais.

	Extreme $SPI < -2,0$ $R (NRMSE)$	Severe $-2,0 \leq SPI < -1,5$ $R (NRMSE)$	Moderate $-1,5 \leq SPI < -1,0$ $R (NRMSE)$	Mild $-1,0 \leq SPI \leq 0,0$ $R (NRMSE)$	Total $SPI \leq 0,0$ $R (NRMSE)$
SPI-1	0,65 (3,75)	0,80 (1,57)	0,75 (1,28)	0,66 (0,63)	0,85 (0,45)
SPI-3	0,82 (2,45)	0,78 (1,61)	0,78 (0,99)	0,82 (0,45)	0,91 (0,32)
SPI-6	0,85 (2,01)	0,86 (1,33)	0,76 (1,02)	0,81 (0,52)	0,92 (0,30)
SPI-9	0,89 (1,65)	0,89 (1,31)	0,79 (0,84)	0,82 (0,53)	0,94 (0,28)
SPI-12	0,92 (1,87)	0,86 (1,30)	0,81 (0,87)	0,86 (0,52)	0,95 (0,26)
SPI-18	0,91 (2,46)	0,78 (1,34)	0,87 (0,74)	0,89 (0,48)	0,97 (0,24)
SPI-24	0,87 (2,69)	0,78 (1,25)	0,87 (0,98)	0,82 (0,53)	0,96 (0,28)
SPI-48	0,82 (5,45)	0,90 (0,97)	0,91 (0,74)	0,83 (0,60)	0,93 (0,37)

No caso das secas de curto prazo, os resultados foram piores ao avaliar o coeficiente de correlação e um pouco melhores ao avaliar o *NRMSE*, mas o padrão se alterou ao avaliar as secas de longo prazo, tal que os valores de *R* foram bem maiores, bem como os de *NRMSE*. De fato, é interessante destacar que esse padrão está ligado ao comportamento dessas séries ao decorrer do tempo. Ao avaliar o comportamento do SPI-1, percebe-se que o estado da Paraíba foi atingido por eventos extremamente secos em fases muito pontuais, o que torna a captação da variação dessa série ao decorrer do tempo uma tarefa árdua (Figura 21). Assim, era de se esperar que os valores do coeficiente *R* fossem mais baixos para as secas de curto prazo, já que diante da rara ocorrência desse tipo de evento, torna-se difícil manter uma boa associação linear entre as séries.

Por esse mesmo motivo, já era de se esperar que os valores *NRMSE* fossem mais altos: se a frequência desses eventos é rara, isso implica que no predomínio de valores nulos em ambas as séries ao decorrer do tempo e por isso, qualquer erro do satélite TRMM ao captar a magnitude desses valores de percentual de área atingida implica em um aumento no valor de *NRMSE*. No caso das secas de longo prazo, esses altos valores de *NRMSE* não estão ligados à raridade dos eventos, mas ao erro que de fato ocorreu por parte do TRMM ao estimar o valor percentual de área atingida pelos eventos secos. Conforme já discutido, houve tendência por parte do TRMM em superestimar o percentual de área atingida por eventos desse tipo, bem como já mostrado na Figura 21, e essa superestimativa, que caracteriza um erro do TRMM, ocasionou o aumento significativo nos valores de *NRMSE*, especialmente no caso do SPI-48.

Ao avaliar os eventos severamente secos, percebe-se uma queda nos valores de *R* e de *NRMSE* em algumas situações, se comparados aos resultados dos eventos extremamente secos. Todavia, destaca-se que os resultados foram satisfatórios (i.e., $R \approx 0,80$) mas ainda assim expõem a imprecisão do satélite TRMM ao captar a magnitude dos percentuais de área atingida ($NRMSE > 1,00$). Os valores mais satisfatórios foram obtidos ao avaliar as secas de médio prazo e de longo prazo, especialmente em se tratando do índice SPI-48, enquanto que os piores foram obtidos no caso das secas de curto prazo. Além disso, é válido ressaltar que o diminuição do *NRMSE* em comparação aos resultados dos eventos extremamente secos pode estar relacionado à frequência de ocorrência desse tipo de evento ao longo da série temporal.

Essa categoria ocorre de modo mais frequente se comparada aos eventos extremos e por tal motivo, a diminuição nos valores do *NRMSE* já era, de certo modo, esperada. Para os eventos moderadamente secos, nota-se que os resultados mais satisfatórios foram encontrados ao avaliar as secas de longo prazo que tiveram, em geral, os maiores valores de *R* e menores

NRMSE, resultado que difere do obtido para os eventos extremos e os severos. É importante destacar que apesar dos valores do coeficiente R terem sido pouco menos satisfatórios que os resultados dos eventos secos mais raros, os valores de *NRMSE* apresentaram uma queda significativa e indicam que o desempenho do satélite TRMM, de modo geral, ainda pode ser considerado satisfatório em termos estatísticos.

Para os eventos suavemente secos, nota-se uma considerável diminuição nos valores de *NRMSE* se comparados aos outros eventos. Os valores do coeficiente de correlação R , por outro lado, variaram de acordo com a alteração na escala temporal, tal que os resultados obtidos para as secas de médio e longo prazo são mais notáveis do que os das secas de curto prazo. Em mais uma vez, é notório que o comportamento do SPI-1 foi o pior dentre as demais escalas de tempo e isso está relacionado à variabilidade dessa série ao longo do tempo, o que faz com que a captação precisa dessa variação seja difícil, especialmente ao tratar de eventos muito raros, como é o caso dos extremamente secos, ou muito frequentes, como no caso dos eventos suavemente secos.

Por fim, ao avaliar o comportamento dos eventos secos de modo geral, é possível notar um aumento considerável na precisão do TRMM em todas as escalas temporais. Os valores de R são da ordem de 0,90, o que indica associação linear quase perfeita entre as séries obtidas por ambas as bases de dados. Os valores do *NRMSE* também são os mais baixos dentre todos os outros tipos de eventos secos e variam de 0,25, nos melhores casos, até 0,45, nas piores situações. Dentre os índices SPI, destaca-se o comportamento do SPI-1 como o pior e o SPI-18 como o melhor dentre as oito escalas temporais. No geral, fica comprovado que a depender dos tipos de eventos secos analisados, há variação na acurácia do satélite TRMM ao captar o percentual de área atingida, mas ao avaliar os eventos secos de modo geral, as estimativas do TRMM captam o percentual de área atingida ao decorrer do tempo.

5.4.QUANTO À ANÁLISE DE TENDÊNCIA

Feita a avaliação dos eventos de seca em múltiplas escalas temporais, foram feitas as análises de tendências das séries de comportamento, duração e severidade das secas de curto, médio e longo prazo com base nos dados dos pluviômetros e dos *grids* TRMM sobre o estado da Paraíba. Inicialmente, a Figura 22 mostra a distribuição espacial da declividade de Sen das séries de comportamento das secas e o percentual de área com tendência significante com base em diferentes níveis de confiança sobre o estado da Paraíba em várias escalas de tempo.

A partir dessa figura, nota-se que considerável variabilidade entre os resultados ao considerar os diferentes dados de chuva e índices SPI, e é notório que os resultados são ora concordantes ora discordantes entre si em algumas situações específicas.

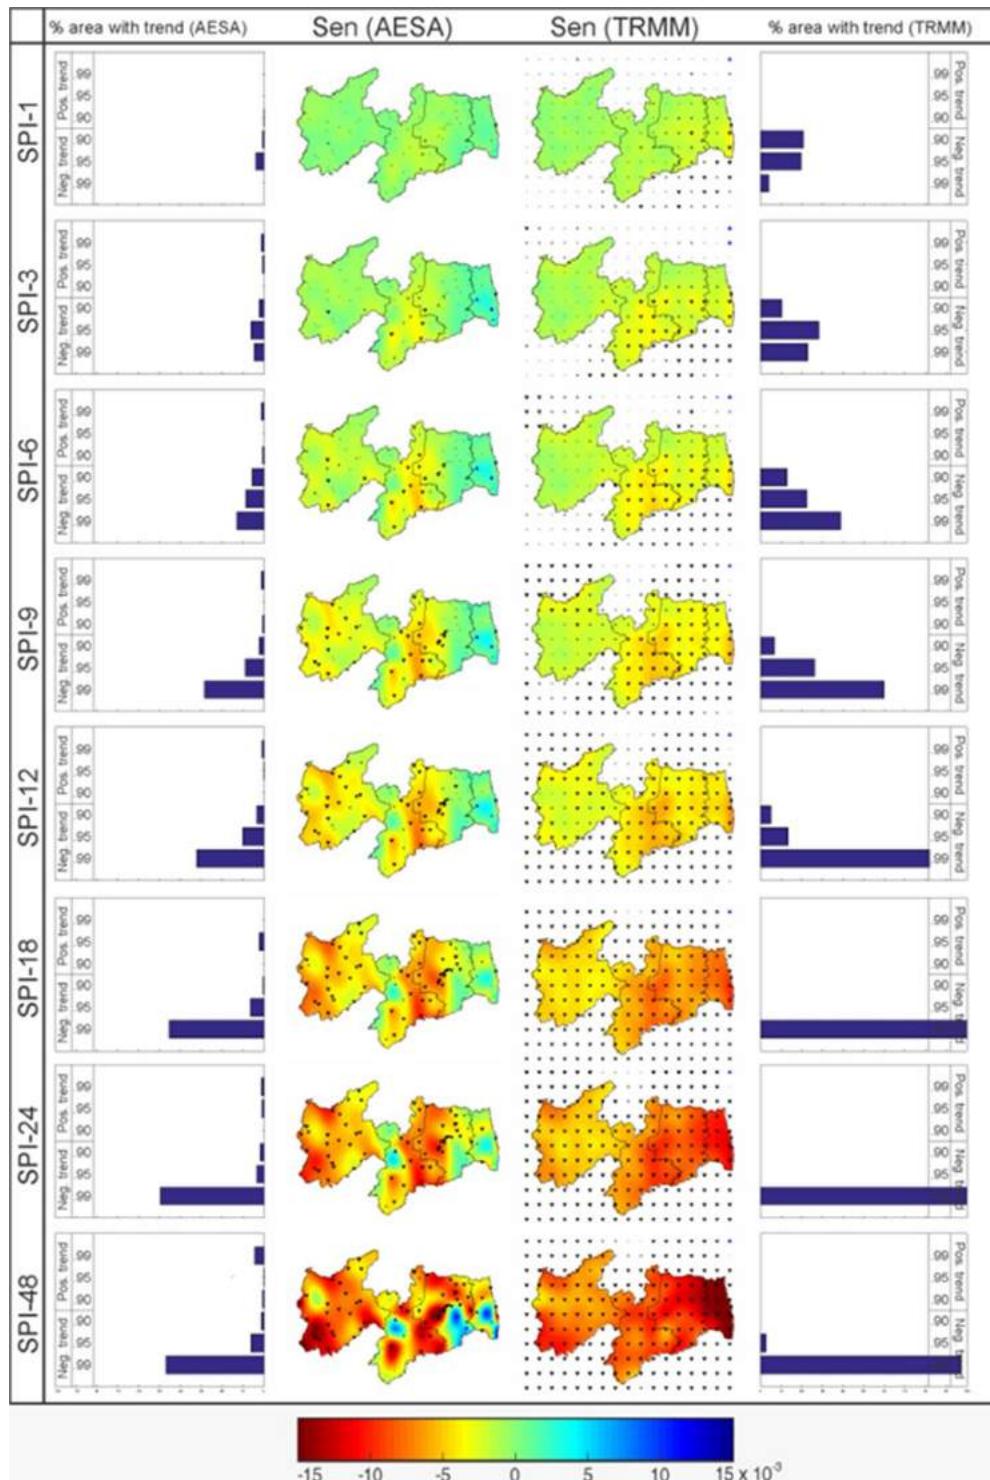


Figura 22 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de comportamento de secas sobre o estado da Paraíba (1998–2017).

Ao comparar os resultados entre os diferentes índices SPI, percebe-se de modo geral que os valores de declividades de Sen aumentam à medida que a escala temporal das secas aumenta, e o mesmo acontece ao avaliar o percentual de área com tendência estatisticamente significante, tal que esse percentual é maior para as secas de longo prazo em comparação com os resultados das secas de curto e médio prazo. Em outras palavras, os resultados indicam que ao avaliar as secas de longo prazo, as séries de comportamento tendem a ter uma declividade de Sen mais acentuada, seja essa positiva ou negativa, e as tendências se tornam significantes com um nível de confiança maior independentemente da base de dados empregada. No geral, cabe destacar que esse é um resultado padrão no tocante à análise de tendências das séries de comportamento das secas, e já pode ser encontrado em outros estudos desenvolvidos na Ásia (Guhathakurta *et al.*, 2017) e na Oceania (Caloiero, 2017), por exemplo.

Ao comparar os resultados obtidos a partir dos dados de postos e das estimativas do TRMM, destaca-se a variabilidade espacial relacionada tanto à declividade de Sen quanto ao nível de significância. Existem regiões em que os resultados ligados ao teste de Mann-Kendall e ao teste de Sen são coerentes entre ambas as bases de dados, e.g., no Sertão e na Borborema ao avaliar o SPI-1, onde as séries dos pluviômetros e dos *grids* TRMM tiveram declividades de Sen suavemente negativas e não apresentaram tendências significantes. Em outras regiões, por sua vez, os resultados foram totalmente opostos, como na faixa litorânea do estado da Paraíba ao avaliar o índice SPI-48, onde as declividades de Sem positivas e negativas mais acentuadas foram encontradas com base nos dados de postos pluviométricos e nas estimativas do TRMM.

Ao realizar uma análise mais detalhada do comportamento das secas de curto prazo, destaca-se a variabilidade espacial da declividade de Sen sobre o estado da Paraíba. Com base nos dados de postos, percebe-se que da região limítrofe entre a Mata Paraibana e o Agreste Paraibano até o litoral, as séries de comportamento apresentaram tendências positivas e significância estatística considerável, especialmente em se tratando do índice SPI-6. Por outro lado, no oeste do Agreste Paraibano e principalmente na Borborema é possível perceber que as séries de comportamento tiveram tendências negativas, i.e., os valores de SPI tenderão a ser mais negativos. Em comparação com os resultados obtidos a partir das estimativas do TRMM, é possível destacar algumas incoerências.

Para o SPI-1, grande parte dos *grids* TRMM apresentou tendência com significância considerável, especialmente nas mesorregiões do Agreste Paraibano e Mata Paraibana. Além disso, ao contrário dos resultados encontrados com base nos dados de postos, as tendências

foram predominantemente negativas em todas as mesorregiões, destacando-se a incoerência entre esses resultados principalmente nas regiões próximas ao litoral. É válido destacar que essa incoerência foi tanto em relação à declividade de Sen quanto à significância estatística obtida a partir do teste de Mann-Kendall. A única mesorregião em que houve concordância por parte de ambas as bases de dados foi a Borborema, onde o satélite indicou declividade negativa nas séries de comportamento das secas.

Para as secas de médio prazo, por sua vez, os valores das declividades de Sen são maiores em módulo se comparadas às secas de curto prazo, e há maior número de séries com tendência significante, independentemente da base de dados utilizada. Com base nos dados de pluviômetros, há aumento significativo no percentual de área com tendência significante, tal que os valores foram de 40% no caso do SPI-9 e de 50% no caso do SPI-12, valores esses que são superiores aos encontrados para o índice SPI-1, que foi de 5%. Com base nas estimativas do TRMM, esses valores percentuais foram de mais de 90% em se tratando do SPI-9, e de 100%, ao avaliar o SPI-12, o que revela elevada superestimativa no percentual de área com tendência significante por parte do satélite.

Todavia, nota-se que o padrão espacial da declividade de Sen é o mesmo das secas de curto prazo, mas os valores são mais expressivos. Com base nos dados de pluviômetros, a região limítrofe entre o Agreste Paraibano e a Borborema delimita de maneira mais expressiva a mudança no comportamento das declividades de Sen sobre o estado, tal que a porção a leste dessa faixa apresenta tendência positiva, enquanto a zona oeste tem tendência negativa. Apesar de não existir uma mudança tão significativa na declividade de Sen na zona costeira, é válido pontuar que as tendências no interior do estado foram mais expressivas e em sua maioria negativas se comparados ao comportamento das secas de curto prazo. Por outro lado, ao utilizar as estimativas TRMM é possível perceber que todo o estado apresentou tendências negativas, com destaque para a zona entre o Agreste Paraibano e a Borborema, e para a região próxima ao litoral da Paraíba.

Mais uma vez, pontua-se o erro do satélite TRMM ao identificar a declividade de Sen das séries de comportamento na Mata Paraibana e no leste do Agreste Paraibano. Por fim, para as secas de longo prazo, são encontrados os resultados mais extremos em se tratando do percentual de área com tendência significante e das declividades de Sen. Com base nos dados de postos pluviométricos, mais do que 45% da área obteve tendência negativa a um nível $\alpha \leq 0,01$, valor superior ao de qualquer outro índice SPI. Além do mais, os valores de declividade

de Sen foram muito superiores aos das outras escalas temporais, superando em três vezes os percentuais obtidos para as secas de curto prazo ao avaliar o SPI-48, por exemplo.

No geral, as zonas com tendências positivas ficaram concentradas na Mata Paraibana, no leste do Agreste Paraibano e no oeste da Borborema, enquanto que os valores negativos estão no sudoeste do Sertão Paraibano, na fronteira entre o Agreste e a Borborema e na porção central do Agreste. Com base nos dados de chuva estimados pelo satélite TRMM, por sua vez, todo o estado apresentou tendência significativamente negativa e nas mesorregiões do Agreste Paraibano e da Mata Paraibana essas tendências atingiram os seus valores mais baixos dentre todas as escalas de tempo. Conforme discutido, destaca-se que esses resultados se relacionam com alguns outros que já foram obtidos em outras pesquisas.

Primeiramente, pode-se perceber que a zona de maior incoerência entre os resultados obtidos a partir dos dados de pluviômetros e dos grids TRMM é a região próxima ao litoral e que isso se intensifica ao avaliar o comportamento das secas de longo prazo. Nesse sentido, ao fazer um paralelo com a Figura 10, nota-se que a região é a que apresenta os menores valores do coeficiente de correlação, o que indica que não existe uma associação linear satisfatória entre as séries SPI oriundas dos pluviômetros e das estimativas TRMM. No caso, a imprecisão foi tão notória que ocasionou uma declividade de tendência oposta, tal que a declividade computada com base nos dados *in loco* foi positiva e nas estimativas do satélite, negativa. Ressalta-se a importância de avaliar não só a precisão do TRMM com base em diferentes métricas estatísticas, mas de relacionar esses resultados com análises de múltiplas disciplinas, como é o caso da análise de tendências.

Sob um outro ponto de vista, Rao *et al.* (2016) avaliaram as tendências sazonais das chuvas sobre o Brasil ao longo de 30 anos e indicaram que a precipitação nos períodos mais chuvosos e secos sobre o estado da Paraíba aumentarão e com isso os eventos tenderão a ser mais úmidos. Medeiros *et al.* (2018), por sua vez, avaliaram as tendências da chuva no Sertão Paraibano (1912–2012) e concluíram que as chuvas têm tendências positivas, especialmente ao avaliar escalas de tempo anuais e semestrais. Notoriamente, esses não foram os resultados obtidos neste estudo e isso pode estar relacionado ao período de estudo empregado utilizado. De fato, é importante pontuar que o período dos dados influencia na avaliação de tendências e que o período de dados empregado nesta pesquisa difere bastante dos desses trabalhos.

Além disso, recentemente ocorreu um dos períodos de seca mais severos dos últimos tempos e isso pode ter influenciado a distribuição espacial das declividades de Sen. Marengo

et al. (2017) apontaram que dos 21 eventos de secas mais severas que atingiram o Nordeste desde 1900, seis estão inseridos no período de análise do nosso estudo, com destaque especial para os anos de 1997–1998 e 2012–2015. Este último evento mais recente que atingiu a região Nordeste, fez com que quase 1000 cidades decretassem estado de emergência e impulsionou conflitos sociais e econômicos. Nesse sentido, um dos motivos que pode ter influenciado as declividades negativas tão expressivas foi o aparecimento desse evento de seca nos últimos anos. Além disso, conforme discutido por Pascoa *et al.* (2017) e Guo *et al.* (2018a), nota-se que quanto menor o período dos dados, mais expressivas tendem a ser as declividades de tendências das séries.

Em comparação ao demais estudos desenvolvidos, pode-se notar que a série temporal avaliada no nosso estudo tem 20 anos de dados (1998–2017), limitado exclusivamente pela disponibilidade do TRMM, enquanto que os demais trabalhos utilizam, na maioria dos casos, períodos maiores. Todavia, leva-se em consideração que a intenção deste trabalho é avaliar as tendências das secas ao longo desses recentes 20 anos e a viabilidade de utilizar os dados do TRMM para monitorar essas tendências sobre o estado da Paraíba. Conclui-se, portanto, que os resultados apresentados não devem ser descartados, mas de fato sugere-se que, ao decorrer do tempo, mais anos sejam incorporados a essa análise a fim de que os resultados sejam cada vez mais representativos.

De modo análogo ao que foi desenvolvido para as séries de comportamento das secas, a Figura 23 mostra a distribuição espacial da declividade de Sen das séries de duração das secas e o percentual de área com tendência significante sobre o estado da Paraíba em várias escalas temporais. No geral, nota-se que assim como para as séries de comportamento, há considerável variabilidade entre os resultados seja para os diferentes escalas temporais ou para as duas bases de dados utilizadas. Em relação ao padrão dos resultados dentre as escalas temporais, percebe-se que os resultados mais expressivos das declividades de Sen foram obtidos para as secas de maior escala temporal, resultado que corrobora com o que foi obtido para as séries de comportamento das secas.

Em contrapartida, no tocante ao percentual de área que apresentou tendência ao nível de significância mais expressivo, não foi encontrado o mesmo padrão de resultados das séries de comportamento das secas. No caso da duração dos eventos de seca, esse percentual de área foi muito baixo, mesmo para as secas de longo prazo, o que contraria os resultados obtidos na Figura 22. Esse resultado, por sua vez, está fortemente relacionado à quantidade de dados que existe em cada série submetida à análise de tendências. Conforme discutido por Santos *et al.*

(2018), nota-se que é necessário uma quantidade mínima de dados em cada série para que essa série tenha significância relevante. A quantidade de dados requeridos para que uma série tenha significância $\alpha = 0,010$ é de quatro, mas para que a significância seja $\alpha = 0,10$ o número mínimo de dados é sete, a exemplo.

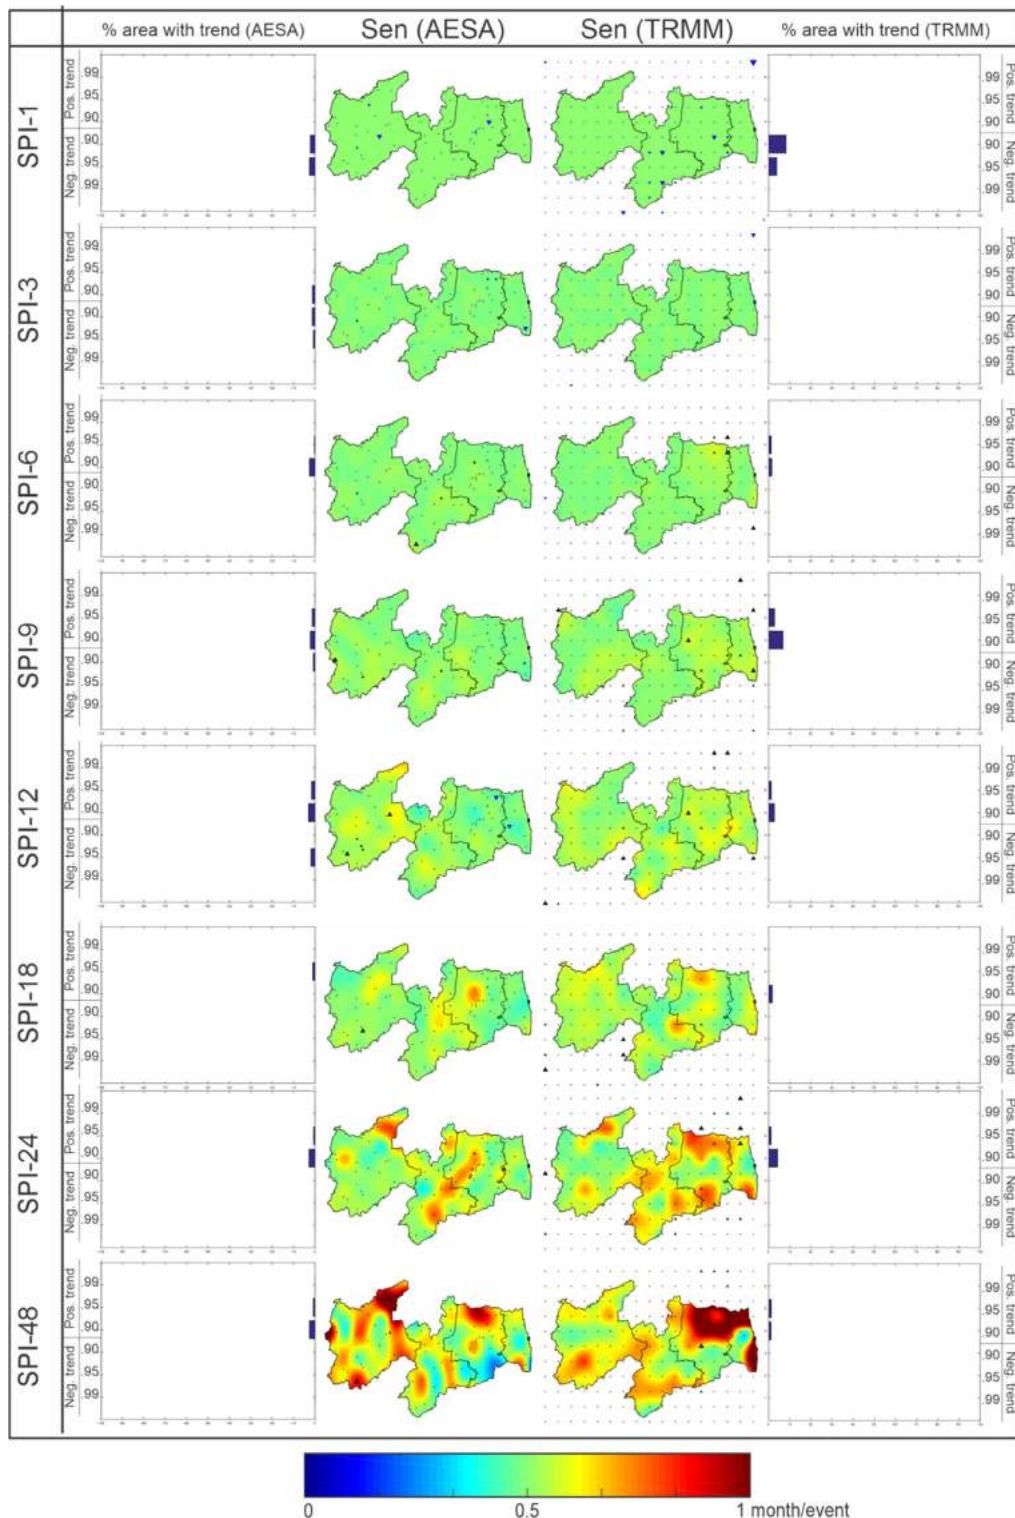


Figura 23 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de duração das secas sobre o estado da Paraíba (1998–2017).

Nesse sentido, tal como mostrado na Figura 15, nota-se que a quantidade de eventos de seca diminui consideravelmente ao avaliar as secas de longo prazo, ainda que esses eventos sejam mais duradouros e severos. Por tal motivo, em função da queda na quantidade de dados disponíveis das séries de duração, essas séries podem não ter obtido significância relevante, ainda que as declividades das tendências de Sen tenham se tornado mais expressivas. Ao comparar os resultados entre as bases de dados, os resultados são mais semelhantes entre si em comparação aos resultados obtidos na análise das séries de comportamento. Todavia, vale destacar que apesar de não ser obrigatório, a distribuição espacial da declividade de Sen para as séries de duração das secas se assemelha ao padrão espacial da declividade de Sen das séries de comportamento.

É válido discutir que não é porque a tendência da série de comportamento das secas é positiva, i.e., os eventos tendem a ser mais úmidos, que a série de duração ou de severidade das secas tenderá a diminuir necessariamente, indicando que os eventos de seca sejam menos duradouros e severos. Apesar das séries de duração das secas serem derivadas das séries de comportamento, é possível que estas séries apresentem declividade negativa, mas as séries de duração, não. De todo modo, ao comparar os resultados dessas figuras, nota-se que na maioria dos casos houve concordância entre essas séries. Para o SPI-48, por exemplo, as tendências de comportamento das secas foram negativas e as tendências de duração foram positivas na região nordeste do Agreste Paraibano, com base nos dados de pluviômetros.

Na realidade, esses resultados se complementam, pois indicam que os eventos tendem a ser mais secos ao decorrer do tempo e a duração dos eventos de secas tendem a ser maiores, quando esses eventos ocorrem. Ao avaliar o comportamento das secas de curto prazo, nota-se que os valores das declividades de Sen não foram tão expressivos e que apenas algumas séries tiveram tendência estatisticamente significante e essas estão localizadas, em sua maioria, no Agreste Paraibano e o sudoeste do Sertão Paraibano no caso do SPI-1, no sul da Mata e no nordeste do Agreste no caso do SPI-3, e no sul da Borborema no caso do SPI-6, com base nos dados de postos. Além disso, ao avaliar o SPI-6 é possível identificar o mesmo padrão das declividades de Sen na fronteira entre o Agreste Paraibano e a Borborema e há indícios de que os eventos de secas tenderão a ser mais duradouros nessa região.

Com base nas estimativas do TRMM, as declividades de Sen foram menores para o SPI-1, mas mais expressivas para o SPI-6 e foram muito similares aos resultados encontrados com base nos dados de pluviômetros. Quanto à significância estatística, há aumento do percentual de área com tendência estatisticamente significante em comparação aos resultados

dos pluviômetros, especialmente no sul da Borborema no caso do SPI-1, e no nordeste do Agreste Paraibano para o SPI-6. Todavia, diante dos valores de declividade de Sen e da baixa quantidade de séries com tendência estatisticamente significante, pode-se dizer que no caso das secas de curto prazo as diferenças os resultados obtidos a partir das estimativas do satélite e dos dados de pluviômetros são menores ao avaliar as séries de duração das secas em relação ao padrão das séries de comportamento das secas.

No caso das secas de médio prazo, percebe-se que tal como para a análise das séries de comportamento, as declividades são mais expressivas e maior variabilidade espacial quando comparadas aos resultados que envolvem as análises das secas de curto prazo. Entretanto, não há uma mudança tão relevante quanto ao percentual de área com tendência estatisticamente significante em relação às séries de duração de curto prazo, assim como aconteceu no caso das séries de comportamento. Com base nos dados de estações pluviométricas, há maior percentual de área com tendência significante ao avaliar o SPI-12 e menor para o SPI-9, e a maior parte da Mata e do Agreste Paraibano apresentam tendências negativas, enquanto que o Sertão Paraibano e a Borborema tem tendências positivas, o que indica que nessas regiões do interior os eventos de seca tendem a ser mais duradouros.

Ao utilizar as estimativas do satélite, basicamente todas as mesorregiões apresentaram tendências positivas e indicam que os resultados encontrados para as secas de médio prazo foram parecidos aos das secas de curto prazo. Nas regiões da Mata Paraibana e na fronteira entre o Agreste Paraibano e a Mata, houve incoerência entre os produtos oriundos do uso das duas bases de dados, mas esses resultados foram menos discrepantes que se comparados aos obtidos na análise das séries de comportamento. Quanto às tendências de duração dos eventos de seca, nota-se que os resultados obtidos nesta pesquisa corroboram com os de Awange *et al.* (2016), que também mostraram que os eventos tendem a ser mais duradouros sobre o estado da Paraíba, ainda que no norte do Nordeste a tendência seja de que os eventos de seca passem a ser menos duradouros.

Por fim, para as secas de longo prazo são encontrados os valores de declividade de Sen mais expressivos dentre as escalas temporais, apesar de que a área com tendência significante é reduzida em comparação com os resultados obtidos na Figura 22. Os resultados obtidos com base nos dados dos postos indicam que as mesorregiões do Agreste Paraibano e da Borborema apresentam tendências positivas ao avaliar os índices SPI-18 e SPI-24. Para o SPI-48, por sua vez, essas declividades tendem a ser ainda mais acentuadas, especialmente no nordeste do Agreste Paraibano e no norte do Sertão Paraibano. Nessas regiões, os valores de declividade

chegam a indicar incremento de 1 mês por evento de seca. Em outras palavras, isto indica que os eventos de seca futuros tendem a ter duração acrescida de um mês, o que mostra elevado aumento. No sudeste do Agreste Paraibano e no litoral, por outro lado, as declividades de Sen são negativas e acentuadas, indicando que os eventos de seca durarão menos.

Em comparação com as estimativas do TRMM, nota-se que há concordância entre os resultados especialmente para o SPI-18. No caso do SPI-24, as declividades de Sen no nordeste e sudeste do Agreste Paraibano e na região central da Borborema foram superestimadas. Para o SPI-48, os valores de tendência foram mais expressivos no norte do Agreste Paraibano e no sudeste do litoral da Paraíba. Por outro lado, é interessante ressaltar que na porção central da Mata Paraibana houve coerência por parte do satélite ao detectar as tendências negativas das durações dos eventos de secas, corroborando com os resultados encontrados com base nos dados de pluviômetros. Todavia, no norte da Mata Paraibana, sudeste do Agreste Paraibano e em grande parte da Borborema, o satélite TRMM não foi capaz de identificar com precisão o padrão das tendências de duração das secas.

De modo semelhante aos resultados da Figura 22 e Figura 23, a Figura 24 mostra a distribuição espacial da declividade de Sen das séries de severidade das secas e o percentual de área com tendência significante sobre o estado da Paraíba em múltiplas escalas de tempo. No geral, há considerável similaridade entre os resultados das séries de duração e severidade das secas, quanto aos níveis de significância, às declividades de Sen e quanto aos resultados entre as diferentes bases de dados. Para as secas de curto prazo, as declividades são menos expressiva, assim como para a análise das séries de duração e comportamento das secas. Além disso, é interessante ressaltar que em alguns casos, a exemplo da região localizada no sul da Borborema e no nordeste do Agreste Paraibano, no caso do índice SPI-3 e SPI-6, a tendência é significativamente positiva tanto ao avaliar a severidade quanto para as durações.

Essa informação é relevante porque dá indícios a respeito da tendência da intensidade dos eventos de seca. No geral, caso as declividades das séries de duração e de severidade das secas sejam iguais, isso provavelmente implica que a intensidade dos eventos de seca tende a se manter constante ao decorrer do tempo. Por outro lado, caso a duração tenha uma tendência negativa, i.e., os eventos tendem a ser menos duradouros, e a severidade apresente tendência positiva, i.e., os eventos tendem a ser mais severos, é possível afirmar que a intensidade dos eventos de seca tenderá a aumentar. Nesse sentido, esse resultado realça a importância de realizar a avaliação conjunta da análise de tendências desses três tipos de séries, pois pode-se entender o padrão das tendências das secas não só quanto ao seu comportamento (Figura 22)

como quanto em relação à sua duração (Figura 23) e severidade (Figura 24), e indiretamente quanto à intensidade desses fenômenos.

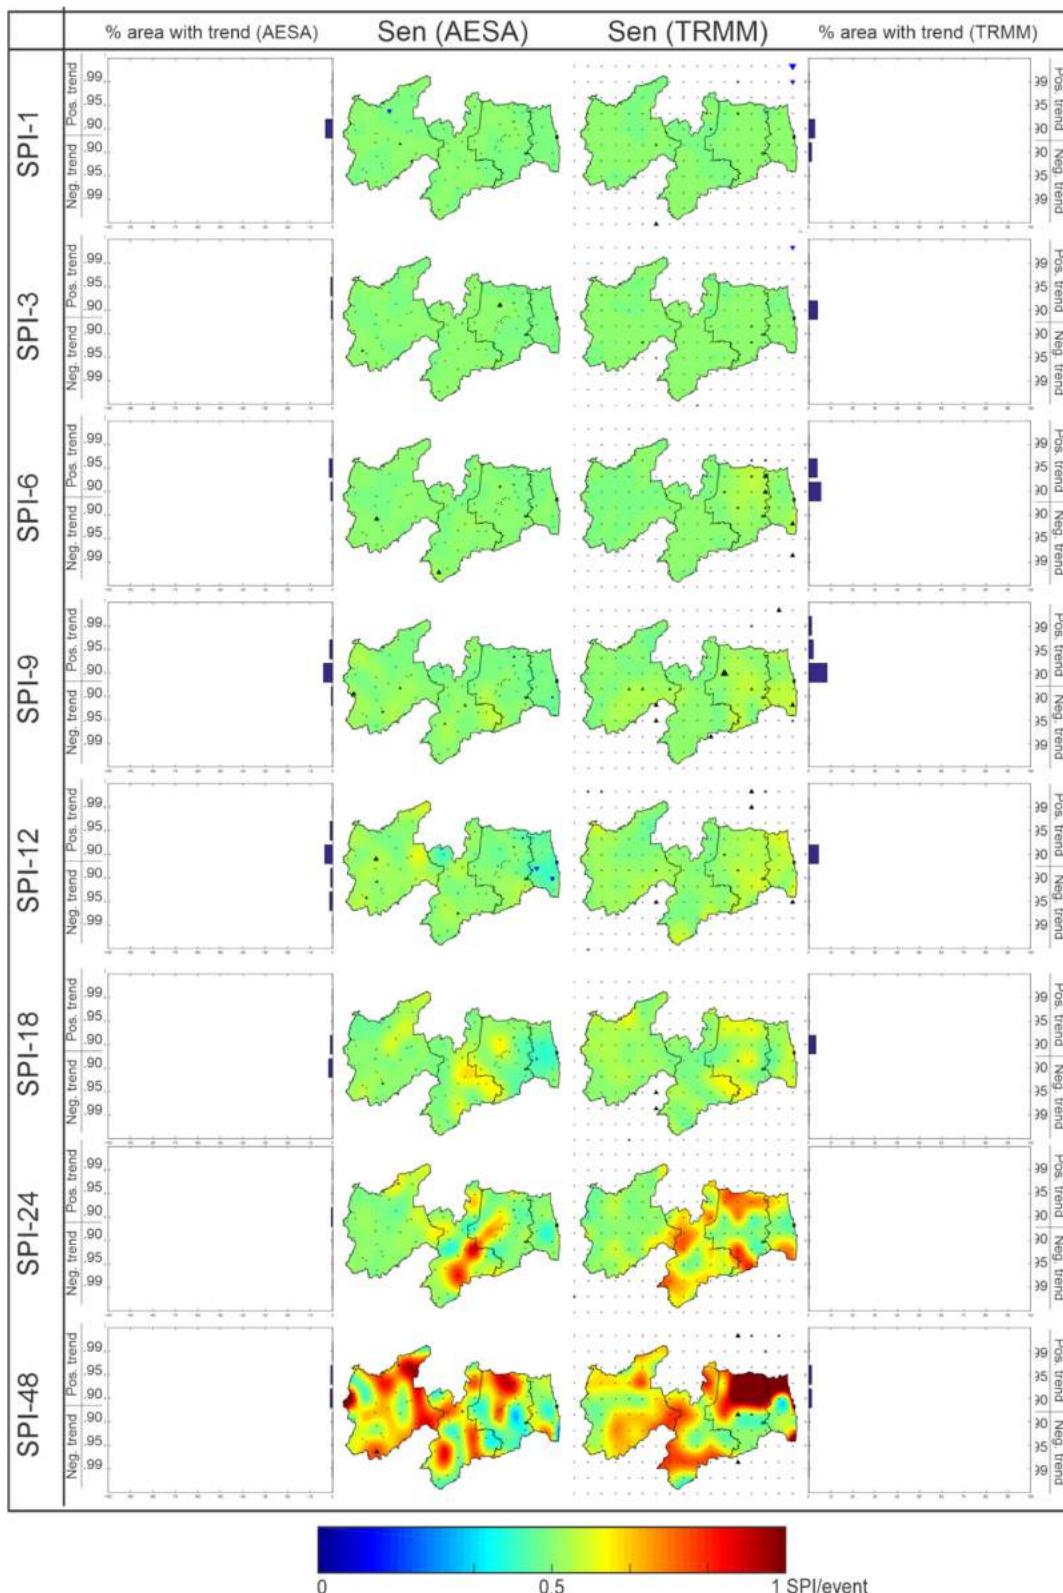


Figura 24 – Percentual de área com tendência significante e distribuição espacial da declividade de Sen das séries de seca sobre o estado da Paraíba (1998–2017).

Ao utilizar as estimativas do TRMM, o percentual de área com tendência significante é superior ao encontrado com base nos dados de pluviômetros. Para o SPI-6, por exemplo, o percentual ao utilizar as estimativas do satélite foi quatro vezes maior do que o obtido a partir dos dados de pluviômetros e se concentraram principalmente no Agreste Paraibano e na Mata. Além disso, as tendências foram predominantemente positivas ao considerar as duas bases de dados e assim como no caso das séries de duração, pode-se dizer que as discordâncias entre os resultados oriundos dos dados de postos e das estimativas do TRMM foram menores se comparadas com as séries de comportamento das secas.

Para as secas de médio prazo, os valores de declividade aumentaram em módulo e um maior percentual de área passou a ter tendência com significância estatística relevante, tal como no caso da duração das secas. Com base nos dados de postos pluviométricos, nota-se novamente que no sul da Borborema e no Sertão Paraibano as séries apresentaram tendências positivas, o que revela aumento na severidade dos eventos de seca. Em contrapartida, próximo ao litoral as declividades foram negativas principalmente para o SPI-12, o que revela que os eventos de seca tenderão a ser menos severos. Já com base nas estimativas do TRMM, nota-se que houve considerável aumento no percentual de área com tendência significante em relação aos resultados obtidos para as secas de curto prazo.

À exceção de algumas áreas isoladas no Sertão Paraibano e na Borborema, a maioria dos grids TRMM sobre o estado da Paraíba apresentaram tendência positiva, corroborando com os resultados encontrados para as séries de duração. Mais uma vez, as mesorregiões do Agreste Paraibano e da Mata Paraibana foram as que tiveram as declividades positivas mais acentuadas, situação que expõe a discordância entre os resultados obtidos com base nos dados de pluviômetros. Além disso, em comparação com os resultados das séries de duração, nota-se que essas séries de severidade apresentaram declividades menos expressivas ao avaliar o SPI-12 e isso indica que, por mais que as séries de duração e severidade tenham tendências positivas, as de duração tiveram declividades mais notáveis do que as de severidade.

Desse modo, como a duração dos eventos de seca tende a crescer em um ritmo mais acelerado do que a severidade, estima-se que os eventos tenderão a ser menos intensos, apesar de serem mais duradouros e severos de qualquer maneira. Por fim, para a análise de tendência da severidade dos eventos de seca de longo prazo, obtiveram-se as declividades de Sen mais expressivas dentre as outras escalas temporais, resultado parecido ao encontrado nas Figuras 22 e 23, e a outros trabalhos desenvolvidos na Ásia (Dashptagerdi *et al.*, 2015) e na África (Botai *et al.*, 2017), onde foram avaliadas as tendências das severidades. É válido notar que os

resultados das tendências de duração e severidade são muito similares entre si, mas existem algumas ressalvas a serem discutidas. Para o SPI-18, há queda na magnitude da declividade da severidade em comparação aos resultados da duração, tal que o mesmo acontece no norte e oeste do Sertão Paraibano no caso do SPI-24, e no leste da Mata Paraibana no caso do SPI-48.

Em todas essas situações, assim como para o SPI-12, estima-se que os eventos de seca tenderão a ser menos intensos, tendo em vista que a duração tem um incremento superior ao da severidade dos eventos de seca. Por outro lado, no nordeste e sudeste Agreste Paraibano, a situação se inverte e a severidade dos eventos apresenta declividade mais acentuada do que a duração no caso do índice SPI-48, por exemplo. Os resultados obtidos com base nos dados de pluviômetros apontam que a severidade dos eventos de seca na Mata Paraibana e no Agreste Paraibano tende a cair, mas na região do Sertão Paraibano e da Borborema as tendências são positivas. Ao utilizar o TRMM, quase todo o estado da Paraíba passa a apresentar tendências positivas, cujos os maiores valores são encontrados no norte e nordeste do Agreste Paraibano e na Mata Paraibana, assim como para as séries de duração das secas.

Nessas regiões, os valores de declividade ultrapassam a taxa de 1 unidade SPI/evento. Em outras palavras, isso implica que, com base nos eventos de seca que aconteceram ao longo dos 20 anos avaliados, os próximos eventos tendem a ter valores de severidade acrescidos de uma unidade, o que revela um aumento considerável se comparado aos resultados das secas de curto prazo. Quanto à precisão do TRMM em captar as declividades de Sen e o percentual de área com tendência significante, destaca-se a similaridade com os resultados obtidos na análise de tendências de duração das secas. Por fim, no intuito de realizar uma análise integrada para cada uma das mesorregiões do estado, a Figura 25 mostra a análise do percentual de área com tendência significante para as séries de comportamento, duração e severidade das secas para as mesorregiões do estado da Paraíba.

Os resultados indicam que o percentual de área com tendência significante que teve a maior variabilidade foi obtida ao avaliar as séries de comportamento das secas, enquanto que no caso das séries de duração e severidade das secas essa variação não foi tão expressiva. No mais, foi possível perceber que a escala temporal das secas influenciou consideravelmente a variação do percentual de área com tendência significante, tal os valores foram expressivos ao avaliar as secas de longo prazo, independentemente da mesorregião ou base de dados. Quanto à Mata Paraibana, destaca-se forte incoerência entre os resultados obtidos a partir dos dados de pluviômetros e os estimados pelo TRMM principalmente para as séries de comportamento das secas.

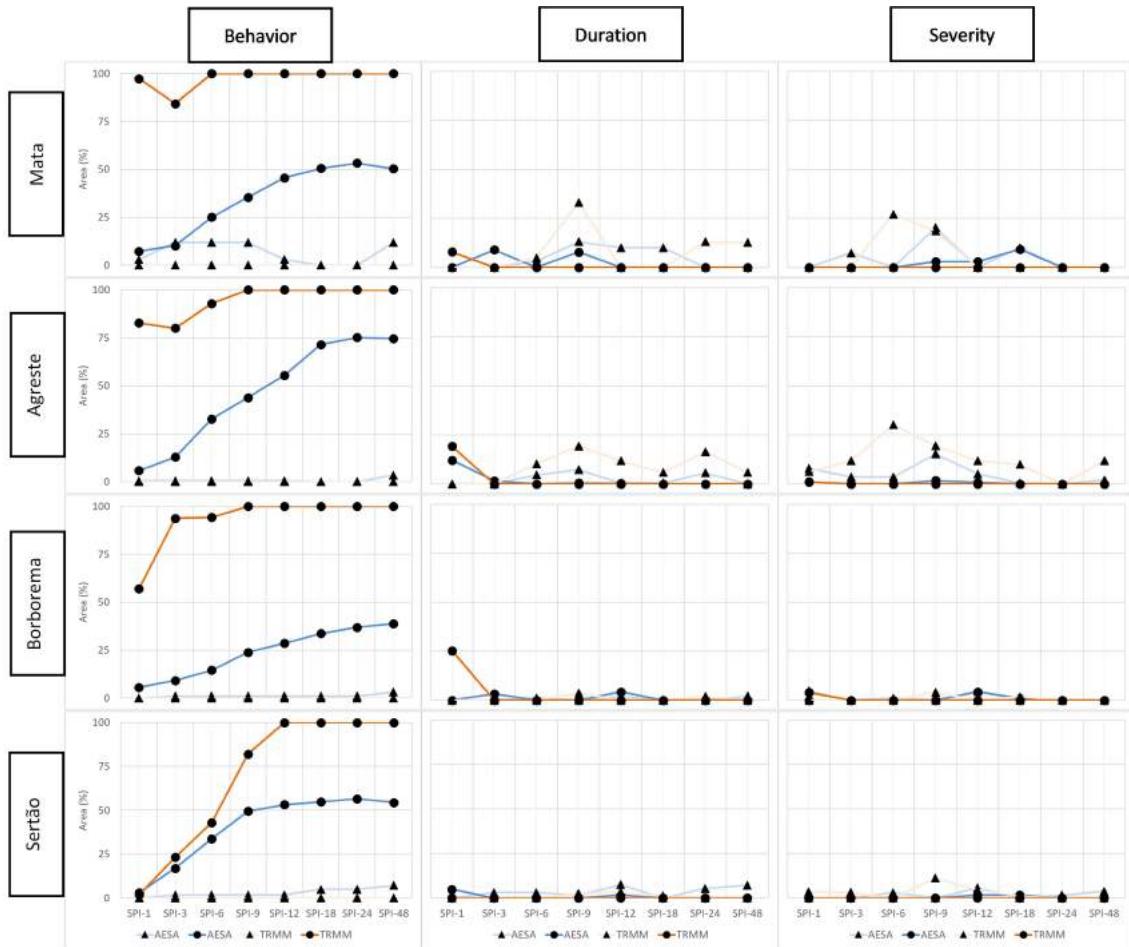


Figura 25 – Análise do percentual de área com tendência significante com base nas séries de comportamento, duração e severidade das secas para as mesorregiões da Paraíba (1998–2017).

Nessa situação, apesar de ambas as bases de dados terem identificado que a Mata Paraibana apresenta tendência predominantemente negativa, os valores percentuais foram notoriamente superestimados pelo TRMM, apesar dessa diferença ter sido menor ao tratar das secas de longo prazo (e.g., SPI-18, SPI-24, SPI-48). Quanto às séries de duração e severidade, a superestimativa do TRMM foi relacionada ao percentual de área com tendências positivas, mas as discrepâncias foram menores em comparação aos resultados que obtidos ao avaliar as séries de comportamento. Os resultados mais expressivos para a duração e severidade das secas foram obtidos ao avaliar os índices SPI-9 e SPI-12, e nesse caso houve coerência entre resultados obtidos com base nos dados dos postos e nas estimativas TRMM.

No Agreste Paraibano, pode-se perceber similaridade mais evidente entre os resultados obtidos a partir das bases de dados se comparados aos resultados da Mata Paraibana. Quanto ao comportamento, apesar de haver superestimativa dos valores percentuais de área com

tendência negativa por parte do satélite, destaca-se que tal fato ocorreu em menor magnitude em comparação ao padrão da Mata Paraibana. No geral, para as secas de curto e médio prazo, os resultados foram menos precisos, enquanto que para as secas de longo prazo os valores percentuais de área com tendência negativa foram superiores a 75%. Para as séries de duração e severidade, o percentual de área com tendência significante é menor do que 25% e atingem seus valores máximos no caso do SPI-9 para as séries de duração, e SPI-6 para as séries de severidade.

Na região da Borborema, nota-se que apesar dos resultados obtidos entre as duas bases de dados terem sido extremamente similares no caso das séries de duração e severidade, no caso das séries de comportamento, há incoerência notória entre os valores percentuais obtidos a partir dos pluviômetros e das estimativas do TRMM. O satélite identificou que o padrão de tendências foi predominantemente negativo, mas a superestimativa da área foi superior a 50% na maioria dos casos. No Sertão, existe similaridade entre os resultados das duas bases de dados e isso ocorreu também ao avaliar o comportamento das secas. O percentual de área com tendência significante obtido a partir das duas bases de dados foi muito similar ao avaliar as séries de comportamento das secas de curto e médio prazo, mas para as séries de longo prazo houve superstimação do TRMM.

5.5.QUANTO À ANÁLISE DE AGRUPAMENTO

Ao definir a distância de correlação como métrica de dissimilaridade para desenvolver as análises de agrupamento, estimou-se o melhor método de ligação entre os *clusters* a fim de evitar escolhas aleatórias. Assim, calculou-se o coeficiente de correlação cofenética das séries de comportamento, duração e severidade das secas em oito escalas temporais considerando três métodos de ligação para as duas bases de dados (Figura 26). Diante da variabilidade dos resultados, é válido realizar uma breve explanação sobre como interpretá-los: o coeficiente de correlação cofenética calculado a partir das séries de comportamento das secas oriundas dos 187 *grids* TRMM foi de 0,80 ao utilizar a distância média como método de ligação e de cerca de 0,76 ao utilizar as distâncias simples e completa, no caso do SPI-1.

A partir dos dados de pluviômetros esses valores passam a ser de 0,84, 0,83 e 0,60 ao utilizar os métodos de distância média, completa e simples, respectivamente. Assim, destaca-se que os resultados apresentam elevada variabilidade ao considerar os três tipos de séries de secas, os três métodos de ligação, as oito escalas temporais, e as duas bases de dados distintas.

Quanto à variação entre os tipos de séries de secas, os resultados tendem a variar em função da escala temporal. Para as secas de curto e de médio prazo, os coeficientes de correlação c são mais expressivos para as séries de comportamento, mas para as secas de longo prazo, são as séries de duração e de severidade que apresentam os melhores resultados mesmo ao levar em consideração os diferentes métodos e base de dados.

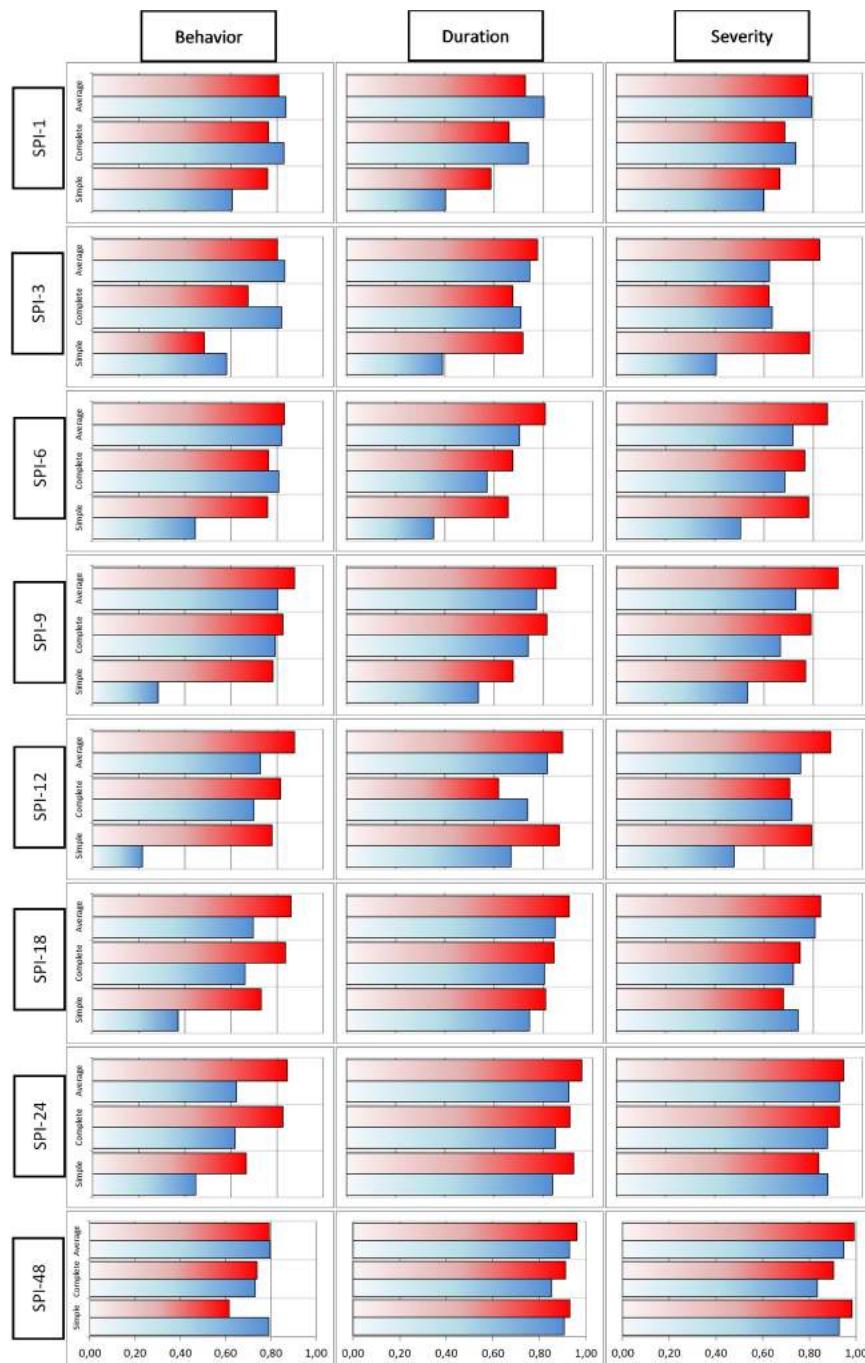


Figura 26 – Variação do coeficiente de correlação cofenética (c) para as séries de comportamento, duração e severidade em múltiplas escalas temporais sobre o estado da Paraíba (1998–2017). Os resultados de pluviômetros estão em azul e os TRMM em vermelho.

Em relação à variação dos valores dos coeficientes entre as escalas temporais, destaca-se que para as séries de comportamento, os melhores resultados foram encontrados para as secas de médio prazo, mas não há diferença expressiva entre esses resultados e os encontrados no caso das secas de curto e longo prazo. Em contrapartida, ao avaliar as séries de duração e de severidade, fica mais evidente a sensibilidade dos parâmetros em função da alteração da escala temporal, tal que os resultados tendem a ser mais significativos em com o aumento da escala de tempo. Para as secas de longo prazo, os valores são mais notáveis e indicam maior consistência da análise de *clusters*, enquanto que os resultados obtidos ao analisar as secas de médio e de curto prazo são um pouco piores.

Ao avaliar o comportamento do coeficiente de correlação confenética c entre as duas bases de dados, pode-se perceber que ao efetuar uma comparação direta, i.e., com escala de tempo, tipo de série de seca e tipo de ligação iguais, os valores obtidos a partir das estimativas do sátilite são predominantemente superiores aos valores calculados com base nos dados dos postos. Isso indica que as análises de agrupamento desenvolvidas com base nas estimativas do TRMM são em maioria mais consistentes que as análises desenvolvidas com base nos dados de pluviômetros. Por fim, quanto à variação do coeficiente c em função do método de ligação entre os *clusters*, nota-se que em todas as análises, o método de ligação média (*average*) foi o que apresentou o melhor desempenho.

Isto significa que ao avaliar o padrão dentre os oito índices SPI, os três tipos de séries de secas e as duas bases de dados, os resultados mais expressivos foram obtidos ao utilizar a ligação média como método de ligação. Em geral, os resultados obtidos com base no método de ligação completa foram medianos, enquanto os piores ocorreram ao utilizar o método de ligação simples. De todo modo, é válido destacar que há variação significativa entre valores desses dois últimos métodos a depender combinação da série de seca, escala temporal ou base de dados utilizada, enquanto os resultados com base na distância de ligação média não foram tão sensíveis à variedade de combinações.

Ao utilizar o método de ligação simples, os valores do coeficiente c calculados com base nos dados das estações são de 0,285, 0,535 e 0,535 para as séries de comportamento, de duração e de severidade do SPI-9. Todavia, ao avaliar esse resultado para o SPI-48, todos os valores ultrapassam a ordem de 0,800, o que mostra uma variabilidade considerável. O que se quer mostrar com essa discussão é que ao contrário do que ocorreu ao usar a ligação simples e completa, há consistência dos valores do coeficiente de correlação dentre as escalas temporais

e tipos de séries de secas e maior representatividade dos valores quando a distância de ligação média é o método escolhido de ligação entre *clusters*.

Em comparação a outros estudos, ressalta-se que os resultados obtidos nesta pesquisa corroboram com alguns desenvolvidos. Segundo Unal *et al.* (2003), a ligação média preenche lacunas de outros métodos hierárquicos existentes, como o de ligação simples e completa, além de minimizar a variância entre as séries de um mesmo *cluster* e maximizar a variância entre os diferentes *clusters*. Além disso, diversos estudos já foram realizados com base nesse método de ligação e os resultados foram adequados aos diferentes propósitos do agrupamento, e.g., McGree *et al.* (2016), Shiau e Lin (2016) e Yang *et al.* (2017) para agrupar zonas com base no padrão das secas e Santos *et al.* (2019a) para realizar as análises de agrupamento com base no comportamento da precipitação.

Em seguida, buscou-se definir o número ótimo de *clusters* no intuito de desenvolver uma análise de agrupamento eficiente e zonear o estado da Paraíba em diferentes regiões. Ao todo, vale destacar que foram realizadas 48 análises de *clusters*, pois estão sendo trabalhadas com duas bases de dados, três séries de seca e oito índices SPI, o que torna a definição desse número ótimo de *clusters* que atenda a todas as possibilidades uma tarefa complexa. Todavia, para preencher tal lacuna, a Figura 27 mostra a relação entre o número de *clusters* e os valores dos parâmetros de silhuetas, de Calinski-Harabasz e da distância entre *clusters* para as séries de comportamento, duração e severidade das secas sobre o estado da Paraíba em múltiplas escalas de tempo.

Em relação ao comportamento dos resultados dos postos e das estimativas TRMM, os resultados oriundos do satélite tiveram menores distâncias de correlação de Pearson entre si se, o que indica que há maior similaridade entre as séries de secas dos *grids* TRMM. Em outras palavras, a curva de variação das distâncias entre os *clusters* pelo número de *clusters* do TRMM está, na maioria dos casos, abaixo da curva obtida a partir dos dados de estações. Logo, ao admitir que para uma mesma quantidade de *clusters* a distância entre tais *clusters* é menor, conclui-se que as séries TRMM são mais similares entre si do que as séries oriundas dos postos. Entretanto, essa diferença entre as bases de dados é menor para as secas de curto prazo, mas tende a aumentar ao avaliar as secas de médio e longo prazo e as séries de duração e severidade.

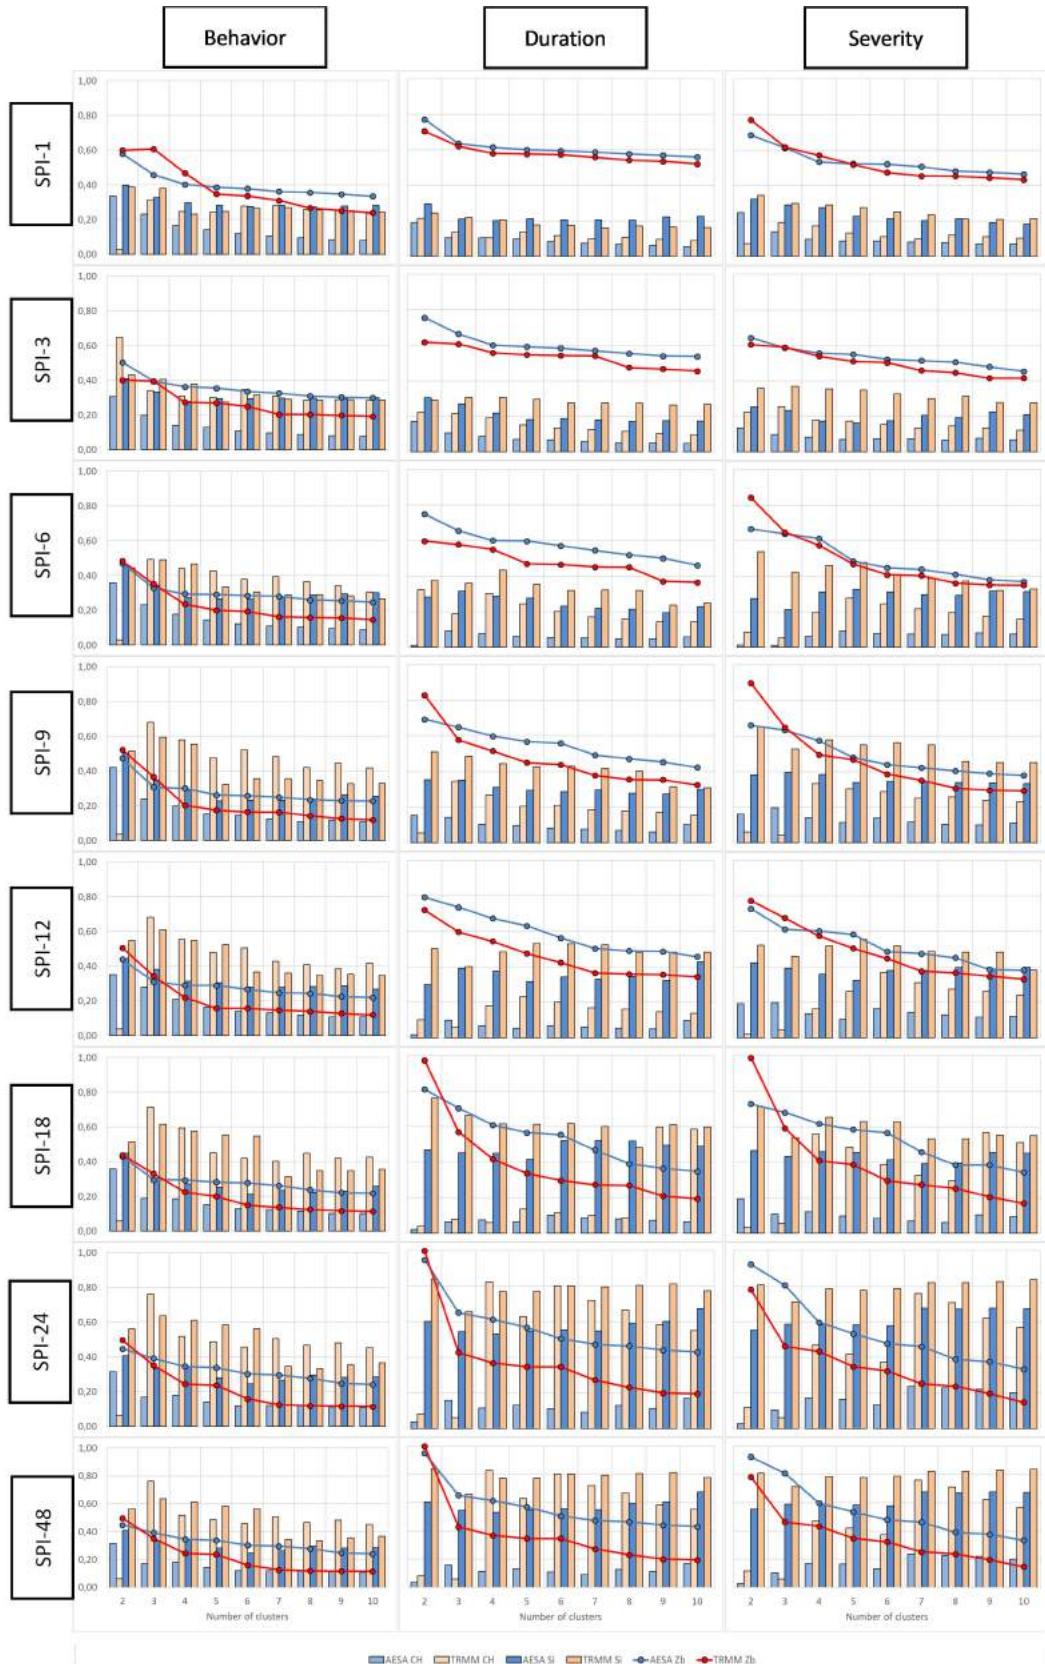


Figura 27 – Relação entre a distância de correlação entre *clusters*, critério de silhuetas e critério de Calinski-Harabasz com a quantidade de *clusters* para as séries de comportamento, duração e severidade das secas sobre o estado da Paraíba (1998–2017).

Os resultados indicam que os valores de Calinski-Harabasz tendem a ser maiores ao utilizar os dados do TRMM, independentemente do tipo de série de seca, escala temporal ou quantidade de *clusters*, e esse cenário só altera em alguns casos, e.g., no caso do SPI-9 para as séries de comportamento, duração e severidade. No geral, esse resultado corrobora com o que foi encontrado ao avaliar a relação distância/número de *clusters*, pois como as distâncias entre os *clusters* foram menores com base nos dados do TRMM, era de se esperar que os valores de *CH* fossem maiores. Além disso, há similaridade entre os valores das silhuetas com resultados do critério de Calinski-Harabasz e os valores foram predominantemente maiores ao utilizar dados TRMM, especialmente para as secas de médio e longo prazo. Por fim, destaca-se que os melhores resultados de *CH* e S_i foram obtidos para quantidade de *clusters* menor que cinco.

Ao comparar os resultados entre as diferentes séries de seca, pode-se perceber que as distâncias entre os *clusters* são menores para as séries de comportamento e maiores para as séries de duração e severidade. Para o SPI-1, por exemplo, ao serem avaliados quatro *clusters*, a distância entre os grupos é de cerca de 0,45 para as séries de comportamento, mas para as séries de duração e de severidade a distância é de 0,55. Para o SPI-12, esse padrão ficou ainda mais evidente tal que ao agrupar as séries de comportamento em quatro *clusters*, a distância entre os grupos foi de 0,25 para as séries de comportamento das secas e de 0,60 para as séries de duração e severidade. Conclui-se que, independentemente da escala temporal ou da base de dados utilizada, as séries de comportamento são mais homogêneas entre si do que as séries de duração e severidade.

Em relação aos valores do *CH*, os resultados indicam que para as secas de curto prazo e médio prazo, os valores tenderam a ser maiores para as séries de comportamento das secas. Além disso, destaca-se que os valores do parâmetro de Calinski-Harabasz obtidos com base nas séries TRMM apresentaram maior variabilidade entre os tipos de séries se comparados aos resultados dos dados de pluviômetros, onde os valores dificilmente ultrapassaram 0,20 em várias combinações. Em relação ao parâmetro das silhuetas, os resultados mostram que não há variação significativa entre os resultados para uma mesma escala de tempo, à exceção do que foi obtido ao avaliar as secas de longo prazo. No caso, os valores para as séries de duração e de severidade foram mais altos do que os encontrados ao avaliar as séries de comportamento, assim como encontrado para o parâmetro de Calinski-Harabasz.

Quanto à variação dos resultados ao avaliar as múltiplas escalas temporais, nota-se que para um mesmo tipo de série, há considerável variação entre os resultados encontrados. Para as séries de comportamento, há uma espécie de estabilidade nos valores de distâncias entre os

clusters já para uma pequena quantidade de grupos, principalmente para as secas de curto e médio prazo. Isso significa que as curvas distância/quantidade ficam menos íngremes a partir de quatro *clusters*, o que indica que é desnecessário dividir as séries TRMM ou os postos em mais grupos, já que a distância de correlação entre as séries se alterará pouco. Para as séries de comportamento das secas do SPI-3, por exemplo, as distâncias entre quatro *clusters* é de cerca de 0,25 com base nos dados do TRMM e de 0,35 com base nos dados dos postos.

Ao utilizar dez *clusters*, a distância passa a ser de 0,30 no caso dos dados TRMM e de 0,20 no caso dos pluviômetros. Portanto, como a distância entre os *clusters* foi alterada de modo sutil, é irrelevante dividir as séries em mais grupos. Em contrapartida, nota-se que ao desenvolver a mesma análise para o SPI-48, as distâncias entre os *clusters* utilizando quatro e dez grupos, varia de 0,40 (TRMM) a 0,20 (AES), o que demonstra um salto maior na curva se comparado aos resultados apresentados para as secas de curto e médio prazo. Para as séries de duração e severidade esse padrão se manteve e para as secas de curto prazo e médio prazo os valores de distância de correlação se estabilizaram com uma menor quantidade de grupos. Para as secas de longo prazo, houve maior distinção entre as séries e a estabilidade da curva só chegou com uma quantidade superior de *clusters*.

Ao avaliar os parâmetros de Calinski-Harabasz e das silhuetas, os resultados mais expressivos foram obtidos ao avaliar as secas de longo prazo, mas ficou nítido que a variação da escala temporal influencia de modo mais considerável o valor das silhuetas. Para o SPI-1, por exemplo, a ordem dos valores de silhuetas para os três tipos de séries de secas é inferior a 0,40, mas ao avaliar o SPI-48 os valores são predominantemente superiores a 0,70, resultado que demonstra elevada variabilidade em comparação aos do parâmetro de Calinski-Harabasz. Além do mais, é válido observar que no tocante ao número de *clusters*, houve alteração mais significativa nos valores das silhuetas em múltiplas escalas temporais com base nos dados de pluviômetros, mas a quantidade de *clusters* inferior a cinco grupos se comporta como uma das escolhas mais apropriadas na maior parte dos casos.

A partir do emprego desses três métodos para definir a quantidade ótima de *clusters*, conclui-se que utilizar poucos *clusters* é a alternativa mais adequada na maioria dos casos. Diante do fato de que a divisão territorial da Paraíba é feita em quatro mesorregiões, adotou-se quatro como sendo o número de *clusters* utilizados. Para essa quantidade, os valores das silhuetas e do critério de Calinski-Harabasz são expressivos, bem como as curvas de variação tendem a ser menos íngremes, o que torna a escolha eficaz sob a ótica dos diferentes métodos. Apesar de existirem casos em que essa quantidade não seja tão apropriada, é válido destacar

que a escolha foi baseada nos resultados das 48 análises de agrupamento e a partir dela, pode-se verificar se os resultados das análises de *clusters* são condizentes com a divisão territorial adotada neste estudo.

Desse modo, de posse da métrica de dissimilaridade (i.e., distância de correlação), do método de ligação (i.e., ligação média) e do número ótimo de *clusters* (i.e., quatro), realizou-se o processo de distribuição espacial dos *clusters* com base nas séries de comportamento, duração e severidade das secas sobre a região. Inicialmente, a Figura 28 mostra os resultados da análise de *cluster* hierárquica desenvolvida para as séries de comportamento das secas com base nos dados de postos pluviométricos e nas estimativas do TRMM para diferentes escalas temporais. A partir dessa figura, percebe-se considerável variação entre os resultados obtidos tanto ao considerar os diferentes índices SPI quanto os tipos de dados de chuva.

Ao avaliar o comportamento das secas de curto prazo, nota-se correspondência entre a distribuição espacial dos diferentes *clusters* e as mesorregiões do estado da Paraíba. Com base nos dados de pluviômetros, os resultados indicam que à distância de 0,50 entre os *clusters*, há um grande grupo que abrange as mesorregiões do Sertão e da Borborema (♦■●), enquanto que o Agreste Paraibano e a Mata Paraibana são cobertos por outro *cluster* (▲), resultados válidos para os índices SPI-1, SPI-3 e SPI-6. Além disso, percebe-se que há maior variabilidade entre os *clusters* nas áreas que recobrem o Sertão Paraibano e a Borborema, e.g., para o SPI-1 o Sertão é composto por um grupo (●), enquanto a Borborema é dividida em duas regiões, tal que uma delas está ao norte (■) e outra ao sul (♦).

No caso do SPI-3, o Sertão foi dividido ao meio por uma zona a oeste (●) e a leste (■), tal que esta última se estende em direção ao litoral paraibano e cobre toda a Borborema até o oeste do Agreste. O comportamento do SPI-6 se assemelha ao do SPI-3 com leve ressalva de que fica mais nítida a diferença no comportamento dos *clusters* na fronteira da Borborema com o Agreste (♦). Ao avaliar o padrão dos dendrogramas das secas de curto prazo, é possível perceber que o comportamento no Sertão e Borborema é mais heterogêneo entre si do que nas regiões do Agreste e da Mata Paraibana. No caso dos SPI-3 e SPI-6, as séries localizadas no Agreste e na Mata Paraibana só passam a se diferenciar a uma distância inferior a 0,25, enquanto que a distância de 0,30 já existem dois *clusters* no interior do estado.

Ao utilizar as estimativas do TRMM, nota-se que as séries de comportamento tendem a ser mais homogêneas entre si se comparadas aos resultados obtidos a partir dos postos. A distância entre *clusters* de 0,50, praticamente todas as séries do TRMM estão inseridas em um

único *cluster* que cobre todo o estado, com ressalva apenas no comportamento de um *grid* localizado no nordeste da área de estudo. Todavia, foi possível manter boa correspondência entre a distribuição espacial dos *clusters* e as mesorregiões do estado da Paraíba e apesar de algumas diferenças entre os resultados oriundos das duas bases de dados, foi viável identificar a similaridade entre o comportamento do Sertão e Borborema, e do Agreste e Mata Paraibana.

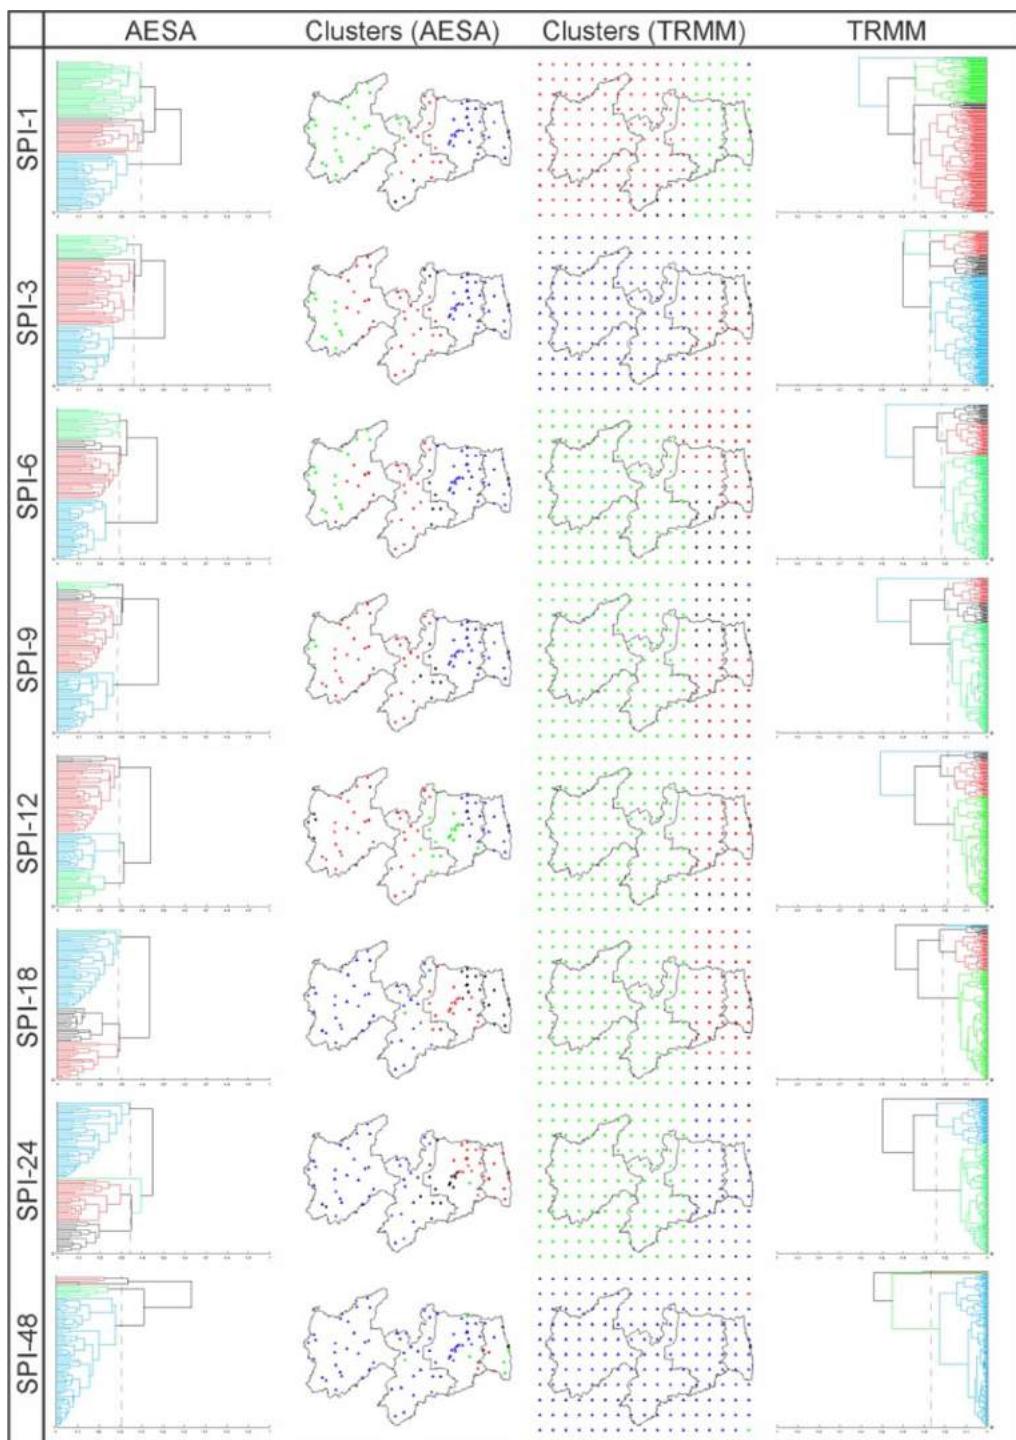


Figura 28 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de comportamento das secas sobre o estado da Paraíba (1998–2017).

Ainda com base nos dados TRMM, destaca-se que à exceção dos resultados do SPI-1, onde houve distinção entre o comportamento das secas nas regiões do Sertão (■) e do sul da Borborema (♦), as duas mesorregiões localizadas no interior foram sempre agrupadas em um único *cluster*, diferentemente dos resultados encontrados para os dados dos postos. Desse modo, os resultados indicam que há maior variabilidade entre o comportamento das secas nas mesorregiões do Agreste e da Mata Paraibana. Para o SPI-1, as regiões do Agreste e da Mata Paraibana foram cobertas por um único cluster (●), tal qual aconteceu no caso dos resultados com base nos dados de pluviômetros. Para o SPI-3 e o SPI-6, o norte do Agreste Paraibano e da Mata Paraibana foram cobertos por um cluster e a porção sul por outro.

Assim, conclui-se que apesar do satélite TRMM ter apresentado acurácia em separar as regiões do Sertão e da Borborema das mesorregiões do Agreste e da Mata Paraibana, houve certa imprecisão ao estimar quais dessas duas regiões eram mais homogêneas entre si. Para as secas de médio prazo, as distâncias entre quatro *clusters* foram as menores dentre os tipos de secas, o que indica que ao comparar essas séries de comportamento com as séries de curto e de longo prazo, para as secas de médio prazo houve maior similaridade. Com base nos dados das estações pluviométricas, a divisão do estado da Paraíba entre as mesorregiões do Sertão e da Borborema, e a região do Agreste e da Mata ficou cada vez mais evidente, e os resultados obtidos para os índices SPI-9 e SPI-12 são muito parecidos.

Tanto para o SPI-9 quanto para o SPI-12, há um *cluster* formado no extremo oeste do Sertão e que a outra parte dessa mesorregião é coberta por um *cluster* (■) que se estende até o Agreste. Na Mata Paraibana, o comportamento é o mesmo para essas duas escalas, e pontua-se a existência de apenas de um único *cluster* sobre toda a área (▲). A maior diferença entre os resultados é no Agreste, pois para o SPI-9 toda a mesorregião tende a se comportar de modo mais similar à região da Mata Paraibana (▲), enquanto que para o SPI-12, há distinção entre o padrão a oeste (●) que se assemelha mais à zona que faz fronteira com a Borborema, e o padrão a leste (▲) que se assemelha mais ao comportamento da Mata. De qualquer modo, as mesorregiões mais próximas ao litoral apresentaram maior similaridade entre si, enquanto que as regiões do interior apresentaram menor similaridade.

Com base nas estimativas do satélite TRMM, as distâncias de correlação encontradas entre os quatro *clusters* são menores que as encontradas a partir dos dados de postos. A uma distância de correlação de 0,40, as séries TRMM estão agrupadas em um grande grupo que cobre todo o estado, mas ao utilizar os dados de pluviômetros, as séries são divididas em dois grupos principais, assim como no caso das secas de curto prazo. Apesar dessas diferenças, os

resultados obtidos a partir dos dados TRMM demarcam a divisão da Paraíba em duas grandes regiões, estando uma localizada no interior do estado e formada pelo Sertão e Borborema (●), e outra no ao litoral da Paraíba, destancando-se que a região mais próxima ao litoral ainda foi dividida em duas regiões: uma localizada no norte e a outra ao sul.

No caso do SPI-12, as regiões do Agreste e da Mata são compostas em sua maioria por um único cluster (■), enquanto que ao avaliar o SPI-9 essa região é composta por dois grupos distintos. Destaca-se que o satélite não identificou as particularidades do oeste do Sertão e do Agreste e na Mata Paraibana, mas assim como para as secas de curto prazo, identificou que os *clusters* localizados no interior do estado são mais homogêneos do que os próximos ao litoral. Ao avaliar o comportamento das secas de longo prazo, ressalta-se alta variação em relação aos resultados das secas de curto e médio prazo, especialmente em se tratando do SPI-48. A partir dos dados de pluviômetros, a distribuição espacial dos *clusters* para os índices SPI-18 e SPI-24 são muito similares, mas os resultados do SPI-48 têm um padrão mais particular.

Apesar das distâncias entre os quatro *clusters* serem menores para o SPI-18 do que para o SPI-24, a regionalização do estado foi basicamente a mesma para esses dois índices, divergindo apenas em poucas situações. Além da semelhança com os resultados do SPI-12, destaca-se que as regiões da Borborema e do Sertão apresentaram menor similaridade entre si apesar de terem sido cobertas em sua maioria por um único *cluster* (▲). Da fronteira entre a Borborema e Agreste até a porção central desta mesorregião há outro *cluster*, enquanto que da região central do Agreste até o litoral, há outro grupo. Para o SPI-48, o comportamento é mais intrigante e o motivo é que há predomínio notório de um grupo (▲) em todas as mesorregiões do estado, cobrindo desde o Sertão até o litoral. Na Mata Paraibana puderam ser encontrados quatro diferentes *clusters*, o que realça a variabilidade do padrão das secas nessa região.

Com base nas estimativas do TRMM, destaca-se diferença no comportamento do SPI-18, SPI-24 e SPI-48. No caso dos dois primeiros, a divisão do estado em duas regiões fica mais nítida, sendo uma formada pelo Sertão e Borborema (●) e outra pelo Agreste e pela Mata Paraibana (◆■▲). A partir dos dendrogramas, nota-se que os *clusters* são mais similares entre si ao tratar do Sertão e da Borborema e que esses só passarão a se diferenciar a partir de uma distância de correlação de 0,15. Ao avaliar o padrão do índice SPI-48 quase todos os *grids* TRMM estão agrupados em um *cluster* (▲), assim como nos resultados obtidos a partir dos pluviômetros. Isso indica que para as séries de comportamento das secas de longo prazo, há um padrão de similaridade elevado entre as séries sobre o estado, sem haver a distinção do padrão das secas do Sertão Paraibano até a Mata Paraibana.

Uma das possíveis explicações para que as distâncias entre os *clusters* ao avaliar as secas de curto prazo sejam tão elevadas é de que como o comportamento dessas séries SPI são muito variáveis, é de se esperar que as séries tenham menos similaridade entre si. Em outras palavras, qualquer perturbação na série de precipitação pode estimular o aparecimento de um valor SPI extremo seco ou úmido, e isso pode ocasionar diferenças quanto à semelhança entre as séries SPI. Por outro lado, ao avaliar as secas de médio e longo prazo, à exceção de raros valores pontuais, as séries tendem a se comportar do mesmo modo em função da amortização da precipitação ao decorrer do tempo, o que faz com que no final das contas, as séries tenham alta similaridade.

No tocante à similaridade mais acentuada das séries de comportamento das secas dos *grids* TRMM, isso pode estar ligado ao algoritmo empregado pelo satélite, que pode tender a realizar uma compensação dos valores de precipitação entre as regiões. Nesse caso, como as séries de comportamento são agrupadas de acordo com à similaridade de variação do SPI ao decorrer do tempo, essa compensação pode ter feito com que as séries fossem mais similares entre si. Ao utilizar dados de pluviômetros, por outro lado, as variações pontuais são captadas de modo mais particular e isso aumenta da dissimilaridade entre as séries de comportamento dos postos. Em seguida, a Figura 29 mostra o resultado da análise de *cluster* hierárquica para as séries de duração das secas com base nos dados de postos pluviométricos e do TRMM para as diferentes escalas temporais.

Conforme discutido na Figura 27, as distâncias de correlação entre os quatro *clusters* para quaisquer escalas temporais são maiores do que as encontradas com base na análise das séries de comportamento. Ao definir uma distância dendrogramica de 0,50, nota-se que na maioria dos casos ao mínimo, quatro *clusters* são distribuídos pela região diferentemente dos resultados da Figura 28. Além dessa diferença, também é válido destacar que a distribuição espacial dos *clusters* com base nas séries de duração das secas difere em algumas situações da configuração ao avaliar as séries de comportamento. Esse resultado é relevante porque mostra que um determinado posto pluviométrico (ou *grid* TRMM) pode apresentar alta similaridade a outro em relação ao comportamento das secas, mas pode diferir de maneira significativa ao avaliar o padrão das séries de duração.

Realça-se a importância de avaliar a distribuição espacial dos *clusters* considerando as diferentes séries de secas em múltiplas escalas temporais, pois a discussão integrada permite o aumento da compreensão do padrão das secas e de suas características. Para as secas de curto prazo, os resultados obtidos a partir da avaliação da duração e do comportamento das secas se

alteraram e isso ocorreu de modo evidente ao utilizar a base de dados dos pluviômetros. Ao utilizar esses dados, nota-se mudança na distribuição espacial dos *clusters*, tal que para o SPI-1, o Sertão e a Borborema passam a ser cobertos em sua maioria por apenas um cluster (\blacktriangle), enquanto a Mata Paraibana e o Agreste são formados por duas zonas distintas, sendo uma a oeste (\blacklozenge) e outra a leste (\blacktriangle).

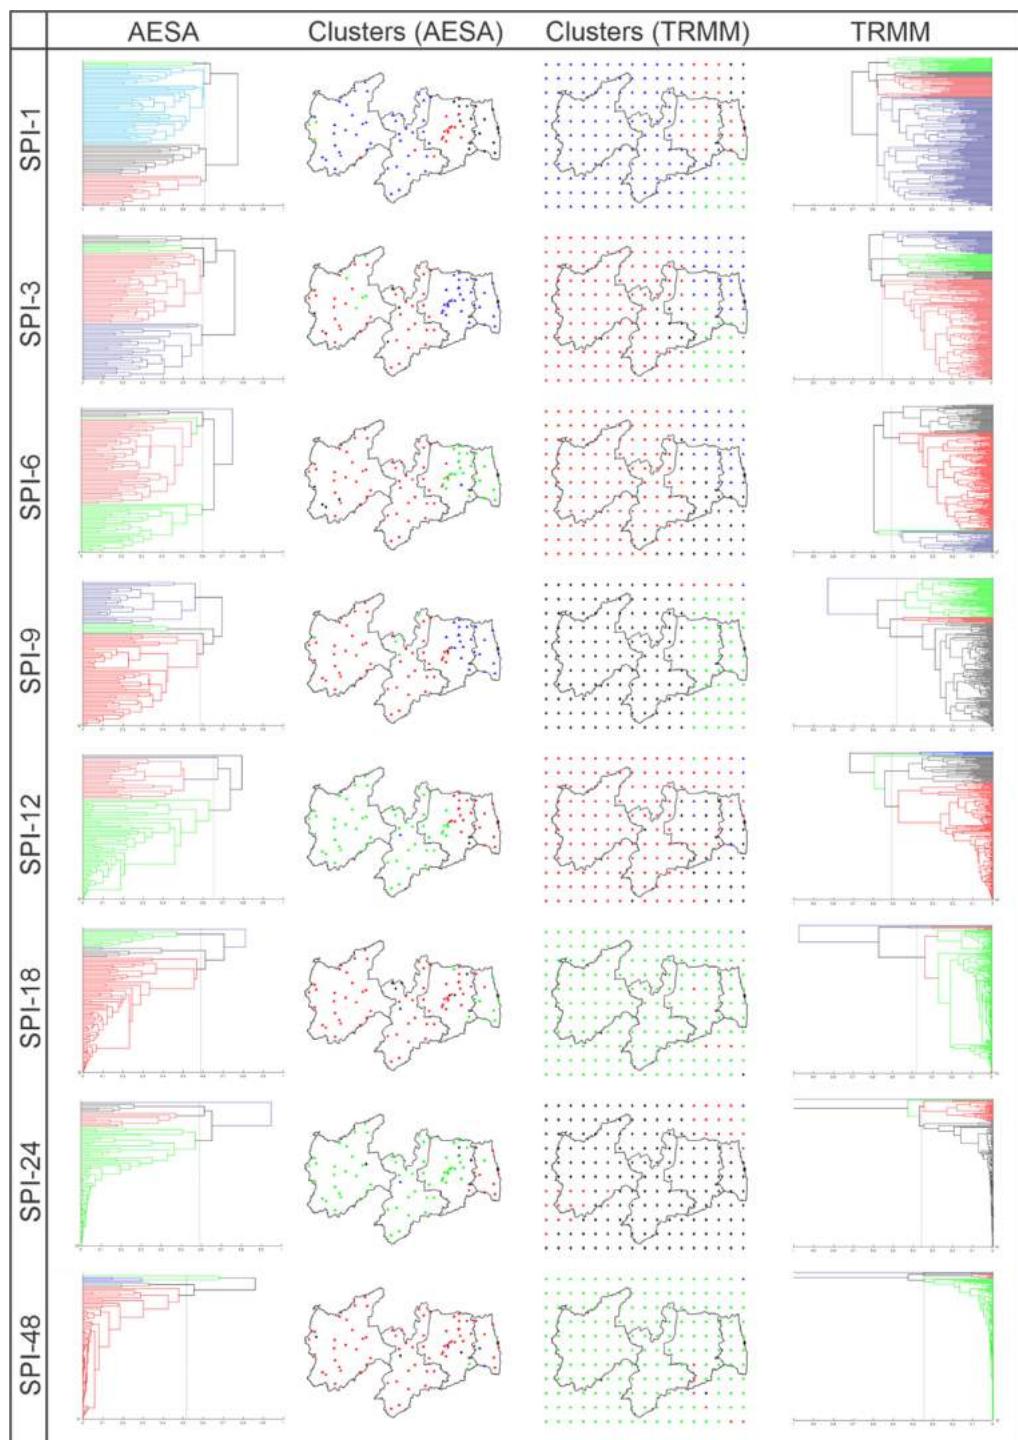


Figura 29 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de duração das secas sobre o estado da Paraíba (1998–2017).

Em comparação aos resultados da Figura 28, percebe-se que o Sertão e a Borborema eram divididos em três *clusters*, enquanto que a Mata Paraibana e o Agreste eram cobertas por apenas um *cluster*. Para o SPI-6, o Sertão e a Borborema foram agrupados em um *cluster* (■), enquanto que o Agreste e a Mata Paraibana foi formada em sua maioria por uma outra zona (●). Já para o SPI-3, a distribuição dos *clusters* é mais irregular se comparado ao padrão do SPI-1 e do SPI-6: o Sertão é dividido em três regiões, estando uma no sudoeste (◆), outra no centro (■) e outra no nordeste (●), enquanto que o Agreste e a Mata são compostos por um único *cluster* (▲). Esse resultado difere do encontrado na Figura 28, pois o agrupamento das regiões foi mais condizente com os limites das mesorregiões, especificamente em se tratando das mesorregiões do Sertão e da Borborema.

Todavia, é interessante destacar que para o SPI-1, SPI-3 e SPI-6, há indícios de que as regiões da Mata e do Agreste continuam a ter comportamento mais homogêneo entre si, e as mesorregiões do Sertão e da Borborema tem padrão de dissimilaridade mais elevado, apesar de que foi mantido o padrão de dividir a área de estudo em duas grandes regiões. De qualquer modo, é importante ressaltar que não há distinção significativa em relação à semelhança entre essas regiões se comparados aos resultados obtidos na Figura 28. Isto significa que as regiões da Mata Paraibana e do Agreste Paraibano não apresentam homogeneidade interna mais tão expressiva se comparadas à semelhança existente entre o Sertão Paraibano e a Borborema, o que difere do padrão que foi obtido ao avaliar o comportamento das secas.

A partir dos dados TRMM, é interessante destacar que assim como para os resultados da Figura 28, as distâncias entre os *clusters* perante as séries de duração são menores do que as distâncias obtidas com base na utilização de postos pluviométricos. Entretanto, assim como no caso das séries de comportamento, notaram-se algumas mudanças quanto à distribuição espacial dos *clusters* sobre o estado da Paraíba. No geral, o que se percebe é que as regiões do Sertão e da Borborema tendem a ter grande parte do seu território compostos por um *cluster*. Além disso, em comparação à análise de agrupamento das séries de comportamento, percebe-se que de certo modo a distribuição espacial foi mantida, especificamente para os resultados do SPI-6.

No caso do SPI-1, houve variação significativa na distribuição dos *clusters* no Agreste e na Mata Paraibana que passaram a ser divididas em três *clusters* (◆■●); já no caso do SPI-3, um novo *cluster* apareceu entre o Agreste Paraibano e a Borborema (◆). Para o SPI-6, apesar da distribuição espacial dos *clusters* considerando as séries de duração das secas terem sido similares aos resultados para séries de comportamento, é válido destacar um comportamento

intrigante. Ao analisar os dendrogramas, nota-se que apesar de existirem três grandes *clusters* sobre o estado, há maior similaridade entre os *clusters* que cobrem as mesorregiões do Sertão, da Borborema e do Agreste (♦■). O outro *cluster* cobre o norte do Agreste e grande parte da Mata Paraibana (▲) e tem comportamento mais singular em relação aos demais.

Esse resultado mostra que diferentemente do que ocorreu ao avaliar o comportamento das secas de curto prazo, já para a análise das séries de duração dos índices SPI-3 e do SPI-6, houve tendência em zonear grande parte do estado em um único *cluster*, resultado só obtido ao avaliar as séries de comportamento das secas de longo prazo. Desse modo, ao comparar os resultados entre as bases de dados, percebe-se que para as séries de duração, o satélite TRMM é preciso ao identificar os dois grandes grupos sobre o estado da Paraíba, mas erra por não ser capaz de captar as singularidades entre as regiões e ao indicar que as séries de duração tendem a ter o mesmo comportamento por todo o estado sob a avaliação das secas de curto prazo, o que difere dos resultados obtidos a partir dos dados de pluviômetros.

Para as secas de médio prazo, nota-se que as distâncias de correlação ao utilizar quatro *clusters* não são mais as menores dentre as escalas temporais, pois isso só ocorre ao avaliar as secas de longo prazo. Com base nos dados de chuva obtidos por pluviômetros, há similaridade quanto à distribuição espacial dos *clusters* sobre o estado da Paraíba em comparação aos dados obtidos a partir das séries de comportamento, mas algumas diferenças precisam ser pontuadas. Para o SPI-9, a região do Sertão Paraibano e da Borborema passou a ser composta por um único *cluster* (■) e esse ultrapassa a faixa limítrofe entre mesorregiões e se estende até o centro do Agreste Paraibano. Dessa região até o litoral, há formação de um outro *cluster* (▲) que cobre o Agreste e a Mata Paraibana.

Para o SPI-12, a alteração na distribuição espacial dos *clusters* se intensifica tal que do Sertão até a porção central do Agreste há existência de um *cluster* mais representativo (●), e do Agreste até o litoral há existência de outra *cluster* (■), assim como no caso do SPI-9. Desse modo, diferentemente dos resultados mostrados na Figura 28, o estado da Paraíba passou a ser dividido em menos *clusters* mais representativos. Entretanto, partir dos dendrogramas, nota-se que as mesorregiões do interior apresentaram maior dissimilaridade entre si se comparados ao padrão das mesorregiões mais próximas ao litoral, assim como encontrado para as séries de comportamento das secas. Com base nas estimativas TRMM, a divisão do estado da Paraíba em duas grandes regiões fica ainda mais evidente, especialmente ao avaliar o SPI-9.

Para o SPI-9, o Sertão e a Borborema são compostos em sua maioria por um *cluster* (♦), e as regiões do Agreste e da Mata Paraibana são cobertos por outro (●). De certo modo, é possível concluir que esses resultados corroboram com os encontrados para os pluviômetros, tendo em vista que a formação de dois *clusters* principais sobre a região foi identificada. Os resultados indicam que o Sertão e a Borborema são mais homogêneas entre si que as regiões do Agreste e da Mata Paraibana e esse resultado corrobora com o obtido na análise das séries de comportamento. Por fim, nota-se que as distâncias dendrogramicas entre os *clusters* sobre a Paraíba tem alta varabilidade ao avaliar as secas de longo prazo, mas essas são as menores ao serem avaliados apenas quatro *clusters*.

Isso implica que ao considerar uma distância dendrogramica entre os *clusters* de 0,80, por exemplo, as séries de duração das secas de curto e médio prazo seriam agrupadas em um único *cluster*, enquanto que ao avaliar o SPI-18, SPI-24 e SPI-48, as séries de duração obtidas a partir dos dados de pluviômetros e das estimativas do satélite passam a ser subdivididas em no mínimo dois diferentes *clusters*, o que realça a heterogeneidade das séries de longo prazo. Por outro lado, ao nível de quatro *clusters* essas distâncias não são tão significativas, e isso mostra que existem séries de duração das secas sobre a Paraíba que tem um comportamento bastante singular, o que faz com que exista distinção entre *clusters* com alta dissimilaridade. De modo mais minucioso, a distância mínima entre quatro *clusters* é de 0,50, no caso dos dados de pluviômetros e de 0,35, no caso das estimativas do TRMM, valores que são bem inferiores a ordem de 0,80 encontrada para distinguir ao mínimo dois *clusters* um do outro.

Em comparação a Figura 28, as séries de duração ainda são menos similares entre si. Com base nos dados de pluviômetros, os resultados obtidos para os SPI-18 e SPI-24 são mais parecidos, enquanto que os do SPI-48 têm particularidades. Em geral, o que se percebe é que para o SPI-18, o Sertão, a Borborema e o Agreste são cobertos por um *cluster* (■), enquanto que a Mata Paraibana é composta por outro (●), resultados similares aos obtidos para o índice SPI-24. No tocante ao SPI-48, um *cluster* cobriu grande parte do estado (■) e os demais se concentraram na porção centro-sul do Agreste, assim como no caso da Figura 28. Com base nas estimativas do TRMM, por outro lado, todo o estado da Paraíba é coberto por um mesmo *cluster* e isso se aplica ao padrão dos índices SPI-18, SPI-24 e SPI-48.

De modo detalhado, à exceção de um grid no centro do Agreste (■) para o SPI-18, da região sudoeste do Sertão e norte da Mata Paraibana (■) para o SPI-24 e do sul do Agreste (■) para o SPI-48, todo as regiões apresentaram o mesmo padrão de variação quanto às séries de duração das secas ao decorrer do tempo. Ao comparar os resultados entre as bases de dados,

percebe-se que apesar de algumas diferenças, o TRMM foi capaz de identificar que existe praticamente um único *cluster* sobre o estado, mas ainda cometeu erro ao não identificar a particularidade do padrão da mesorregião da Mata Paraibana. Por fim, a Figura 30 mostra o resultado da análise de *cluster* hierárquica para as séries de severidade das secas com base nos dados de pluviômetros e nas estimativas do TRMM para as diferentes escalas temporais.

No geral, há grande similaridade entre os resultados da análise de *clusters* das séries de severidade e séries de duração (Figura 29) ao considerar os resultados de ambas as bases de dados. Além disso, as distâncias entre os *clusters* são mais expressivas e ao considerar uma distância dendrogrâmica de 0,50, sempre há formação de no mínimo dois *clusters* distintos independentemente da base de dados ou escala temporal. É válido destacar que para as séries de severidade das secas de curto, médio e longo prazo as distâncias de correlação entre os dois primeiros *clusters* a partir dos dados TRMM são maiores do que as obtidas a partir dos dados de postos. Esse resultado ocorreu de maneira expressiva ao serem avaliados os SPI-1, SPI-6, SPI-9, SPI-18 e SPI-48, mas no geral, as distâncias entre os *clusters* dos pluviômetros tendem a ser maiores do que as obtidas com base nos dados TRMM.

Ao utilizar os dados de postos pluviométricos, nota-se que há bastante similaridade entre os resultados da Figura 29 e Figura 30. Para o SPI-1, à exceção do oeste do Sertão (■), o estado da Paraíba foi dividido em dois *clusters*, tal que um cobriu grande parte do Sertão e da Borborema (●) e o outro cobriu a Mata e o Agreste (▲). O padrão espacial do SPI-3 foi semelhante ao SPI-1 e é notória a divisão do estado em duas regiões principais. Mesmo assim, destaca-se que a porção central da Borborema (▲) passou a ter um comportamento um pouco mais distinto do interior do estado. Já para o SPI-6, o centro-oeste do Agreste também passou a se comportar de modo mais similar ao Sertão e a Borborema (■) e mais dissimilar as regiões próximas do litoral.

Para os índices SPI-1 e SPI-3, não há tanta distinção entre à similaridade das zonas do interior e as regiões próximas ao litoral, assim como no caso das séries de duração. Ao avaliar o SPI-6, por outro lado, a zona no litoral tende a ter comportamento mais similar entre si se comparado às mesorregiões do interior, que apresentam maior variabilidade. Com base nas estimativas do satélite, os resultados das Figuras 29 e 30 se diferenciam um pouco mais ao se compararem com os resultados dos postos. Apesar dessas diferenças, em todos os casos as regiões do Sertão e da Borborema foram, em maioria, cobertas por um único *cluster*, i.e., SPI-1 (●), SPI-3 (●), SPI-6 (■), enquanto que as regiões do Agreste e da Mata Paraibana tenderam a apresentar maior variabilidade se comparadas aos resultados das séries de duração.

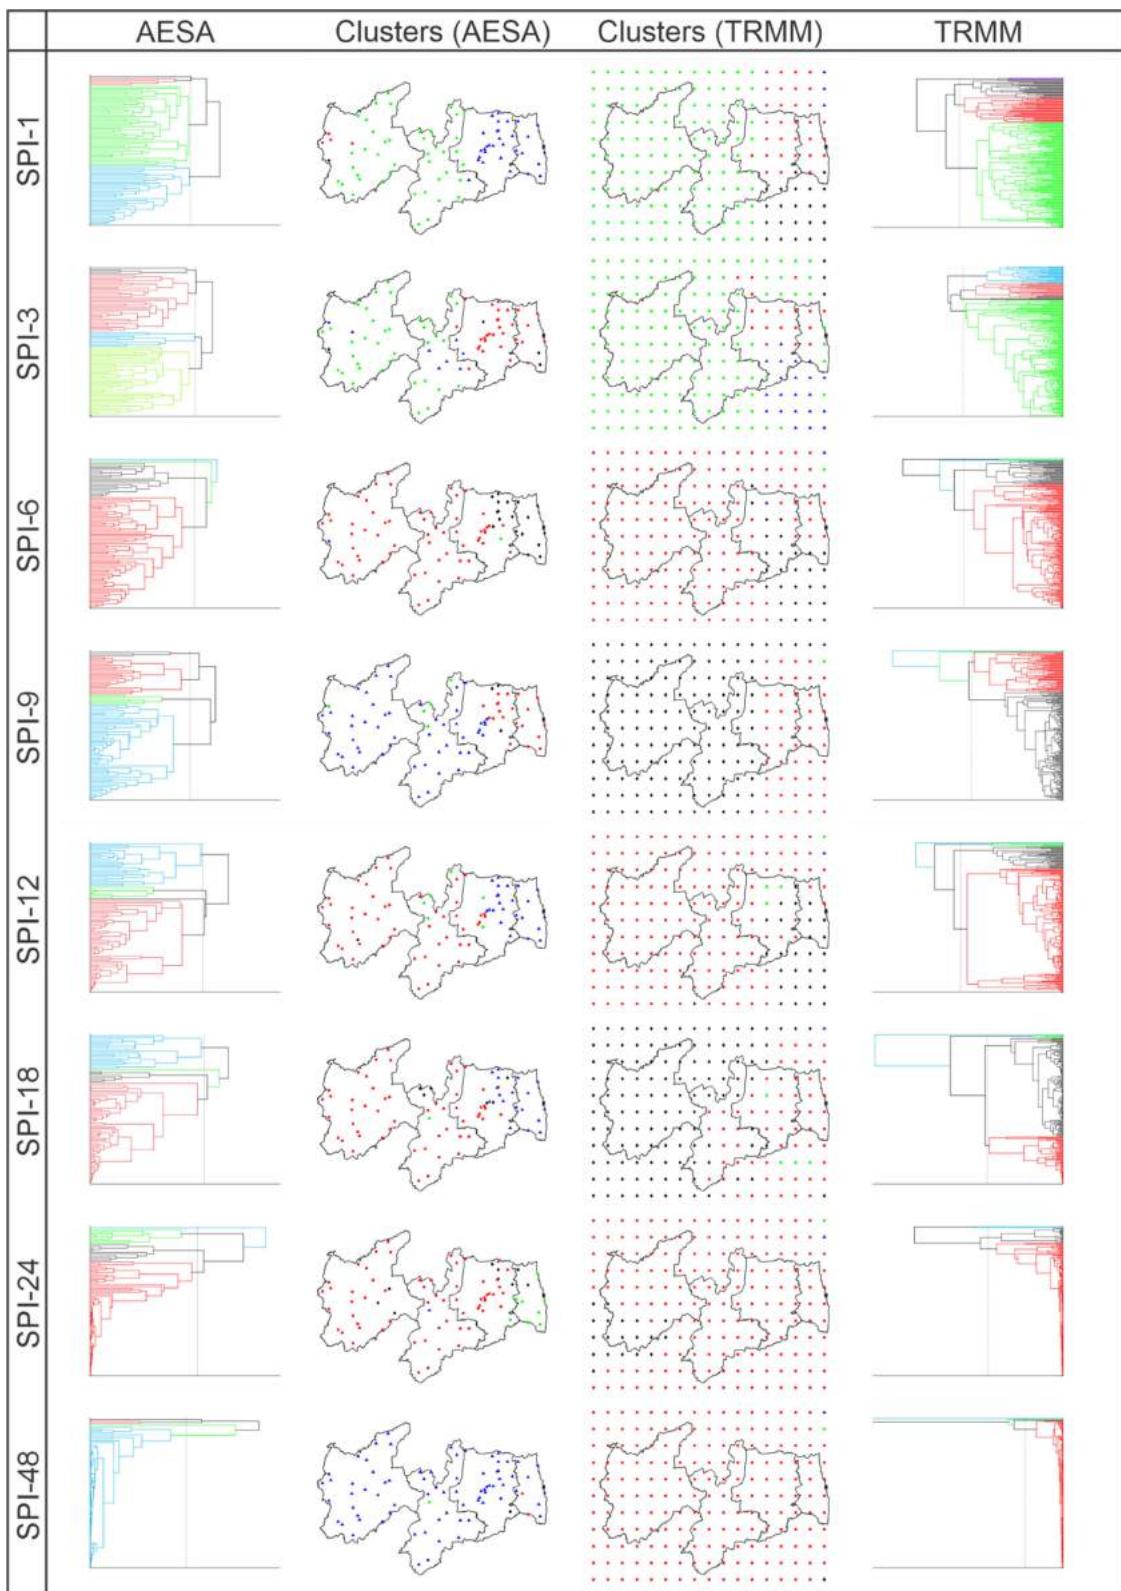


Figura 30 – Análise de cluster hierárquica e seus dendrogramas utilizando quatro clusters com base na série de severidade das secas sobre o estado da Paraíba (1998–2017).

Para o SPI-1, houve divisão da Mata e do Agreste em duas áreas: uma está localizada predominantemente ao norte (■) e outra ao sul (◆). Para o SPI-3, o TRMM não identificou o

comportamento singular na região central da Borborema (\blacktriangle) além de ter subdividido a zona da Mata e do Agreste em três áreas principais, sendo uma mais ao norte (\blacksquare), uma ao sul (\blacktriangle) e outra no litoral (\bullet). Para o SPI-6, a discordância entre os resultados das bases de dados foi menor e a similaridade entre as regiões do Sertão e da Borborema foram identificadas, apesar de que a região da Mata Paraibana apresentou o mesmo comportamento do interior do estado. Por outro lado, no centro do Agreste houve a identificação de um *cluster* com comportamento distinto (\blacklozenge), assim como ao utilizar os dados de postos pluviométricos.

No geral, para o SPI-1 as regiões do Sertão e da Borborema tendem a se comportar de maneira mais semelhante entre si, enquanto que para o SPI-3 e SPI-6, a região do Agreste e da Mata são as que apresentam maior similaridade interna. No caso das secas de médio prazo, as distâncias entre os diferentes *clusters* apresentam a mesma ordem de grandeza das séries de duração. Com base nos dados de chuva obtidos por medições pluviométricas, nota-se mais uma vez alta similaridade entre os resultados obtidos nas Figuras 29 e 30. Para o SPI-9, há uma pequena alteração na porção norte e central do Agreste, mas salvo essa exceção, houve a mesma regionalização ao avaliar as séries de duração e severidade das secas.

Para o SPI-12, destaca-se a existência de dois grandes *clusters* sobre o estado, sendo um deles localizado do Sertão ao Agreste (\blacksquare) e outro do Agreste ao litoral (\blacktriangle). Ao avaliar a configuração dos dendrogramas, nota-se que para o SPI-9 e SPI-12 as regiões do Sertão, da Borborema e grande parte do Agreste tem maior similaridade entre si, resultado que difere do encontrado para as séries de comportamento e duração. Em se tratando dos resultados obtidos a partir dos dados TRMM, nota-se que tanto para o SPI-9 quanto para o SPI-12, houve divisão do estado da Paraíba em duas grandes regiões. A região mais próxima ao litoral tem maior variabilidade do que a do interior, especialmente no caso do SPI-9. Ao comparar os resultados entre as bases de dados, houve alta concordância por parte do satélite ao subdividir o estado da Paraíba em zonas homogêneas.

Para o SPI-9, no entanto, a discordância mais significativa entre os resultados das duas bases de dados foi ao norte da Borborema, pois a partir dos dados de estações há distinção entre essa região (\bullet) e as demais (\blacktriangle), enquanto a partir das estimativas TRMM essa zona foi incorporada ao *cluster* que cobre o interior do estado (\blacklozenge). Para o SPI-12, pode-se perceber que o TRMM foi capaz de captar as particularidades de cada região, especialmente ao identificar a existência de três *clusters* distintos no Agreste. Assim como no caso da avaliação da duração das secas, é notório que as distâncias entre os *clusters* são altas ao avaliar a severidade desses

eventos em apenas dois grupos, mas ao avaliar os quatro *clusters* essas distâncias diminuem consideravelmente.

Com base nos dados de pluviômetros, destaca-se a semelhança entre os resultados obtidos ao avaliar as séries de comportamento, duração e severidade das secas. Para o SPI-18, a Paraíba é coberta por dois *clusters*, sendo um que vai desde o Sertão até o centro do Agreste (■) e o outro que vai do leste do Agreste ao litoral da Paraíba (▲). Para o SPI-24, esse padrão se mantém, mas há formação de dois *clusters* distintos nas proximidades da Mata Paraibana, tal que um está ao norte (♦) e o outro ao sul (●). Para o SPI-48, assim como para os resultados das séries de comportamento e duração das secas, um *cluster* passa a cobrir todo o estado da Paraíba (▲). No geral, conclui-se que o aumento da escala temporal dos índices SPI faz com que todo o estado passe a se comportar do mesmo modo no tocante à severidade das secas.

Com base nas estimativas do TRMM, nota-se que assim como no caso dos resultados obtidos a partir dos dados de postos pluviométricos, o estado da Paraíba tende a ser agrupado em um único *cluster*. Para o SPI-18, esse comportamento não é tão evidente, e ainda pode-se perceber a existência de um *cluster* que cobre o Sertão, o norte e o sudoeste da Borborema (♦) e outro que vai desde a porção central da Borborema até o litoral da Paraíba (■). Para o SPI-24, à exceção do sudoeste do Sertão (♦), todas as regiões são integrantes de um mesmo *cluster* (■) e isso se repete de modo mais evidente ao avaliar o SPI-48. No geral, o comportamento do SPI-18, quanto à severidade das secas foi singular e difere dos resultados obtidos das séries de duração das secas, enquanto que os resultados dos índices SPI-24 e SPI-48 foram similares.

Por fim, é válido pontuar que alguns trabalhos desenvolvidos na literatura já zonearam o estado da Paraíba em diferentes regiões homogêneas com base no padrão da precipitação, e os resultados encontrados foram intrigantes. Keller Filho *et al.* (2005) delimitaram cerca de 25 zonas pluviometricamente homogêneas sobre o Brasil, das quais dez estão na região Nordeste e quatro estão sobre o estado da Paraíba. Os resultados indicam que uma das zonas está situada no litoral paraibano, outra abrange grande parte do Agreste e as demais recobrem as áreas da Borborema e do Sertão. Pouco depois, Reboita *et al.* (2010) apontaram que a Paraíba está inserida em duas regiões principais: uma próxima à costa e a outra no Sertão Nordestino.

A região costeira, que apresenta como principal sistema climático atuante a Zona de Convergência Intertropical, tem precipitação anual média superior a 1500 mm, enquanto a zona do Sertão Nordestino tem precipitação menor que 500 mm, o que corrobora com nosso estudo. No NEB, Araújo e Souza (2012) identificaram quatro zonas com o comportamento

homogêneo quanto ao padrão da precipitação, estando duas dessas distribuídas sobre o estado da Paraíba. Nesse estudo, percebeu-se que a área litorânea tem o padrão distinto se comparado ao interior do estado, resultado que corrobora com outras pesquisas. A ressalva, entretanto, é que a zona costeira é constituída por uma área muita menos significativa do que a outra região que recobre o estado, o que indica que a Paraíba tende a se portar de forma muito homogênea.

Na Paraíba, Macedo *et al.* (2010) delimitaram três zonas diferentes de modo que uma cobre basicamente a Mata Paraibana e a metade leste do Agreste, outra está situada da metade oeste do Agreste até a Borborema, e a terceira se encontra no Sertão da Paraíba. Apesar dessa divisão pouco convencional em relação à separação do Sertão da Borborema, os estudiosos ressaltam que essas regiões são as mais similares entre si e que o comportamento encontrado no litoral tem características mais singulares. Utilizando as estimativas do TRMM, Santos *et al.* (2019a) mostraram uma evidente diferenciação da precipitação das regiões do Agreste e da Mata Paraibana do comportamento das regiões da Borborema e do Sertão, e que esse padrão de agrupamento pode ser encontrado mesmo ao avaliar diferentes escalas temporais.

As conclusões desses estudos reafirmam os resultados que foram encontrados nesta pesquisa e no geral, há um padrão de zoneamento do estado da Paraíba em duas regiões, sendo uma composta pelo Sertão e Borborema, e a outra pelo Agreste e Mata Paraibana. No geral, esse comportamento foi identificado pelo TRMM em múltiplas escalas e para diferentes tipos de séries de secas. Os resultados podem estar relacionados a vários fatores como a influência da altitude e do Planalto da Borborema, por exemplo. Essa formação bloqueia os efeitos dos sistemas atmosféricos e influencia o regime da precipitação e das secas na região. Além disso, fatores como a proximidade das regiões com o oceano ou a atuação de diferentes sistemas climáticos podem ter ocasionado esse padrão de agrupamento. De todo modo, fica comprovado que as estimativas TRMM foram capazes de identificar as zonas estatisticamente homogêneas quanto ao comportamento, duração e severidade das secas.

5.6.AVALIAÇÃO DO NIDS-TREND

Após avaliar a acurácia estatística e realizar a caracterização dos eventos de seca, de suas tendências e de seus padrões de agrupamento, o índice NIDS-Trend foi computado e foi feita a análise de risco das secas sobre o estado da Paraíba. A Figura 31 mostra a distribuição espacial do NIDS-Trend para os postos pluviométricos e para os *grids* TRMM, os pesos de cada parâmetro utilizado para compor esse índice e o valor do NIDS-Trend médio para cada

mesorregião. Nesse sentido, cabe informar que foram desenvolvidas 16 análises de risco, de modo que essas análises consideraram os dados provenientes de duas fontes distintas e de oito escalas temporais utilizadas para caracterizar o comportamento das secas de curto, médio e longo prazo.

A partir da Figura 31, nota-se que os resultados apresentam alta variabilidade e isso se refere tanto aos pesos dos parâmetros quanto à distribuição espacial e à magnitude do NIDS-Trend. É válido destacar que os resultados da Figura 31 são a composição de outros resultados já discutidos neste trabalho e por isso, espera-se relação entre os resultados discutidos e os que serão detalhados. Os dois primeiros parâmetros utilizados para compor o NIDS-Trend foram a quantidade e a intensidade média dos eventos de seca e ambos resultados já foram mostrados na Figura 15. O terceiro parâmetro (i.e., DS), por sua vez, é uma adequação dos resultados mostrados nas Figuras 18 e 19, de onde é possível ter noção de quais regiões foram mais ou menos atingidas pelos diferentes tipos de eventos secos.

Os parâmetros ligados às análises de tendências das séries de comportamento (Figura 22), duração (Figura 23) e severidade (Figura 24) das secas também dão indícios das regiões mais ou menos vulneráveis à ação das secas. Nesse sentido, essa breve discussão mostra que todos os parâmetros utilizados para compor o NIDS-Trend já foram discutidos e por isso, não há necessidade de expô-los novamente. Em relação à análise dos resultados da Figura 31, é preciso discutir primordialmente a variação dos valores dos pesos de cada um dos parâmetros utilizados para compor o índice de seca e ressaltar que esses pesos variam conforme o índice SPI (i.e., escala temporal) e quanto à base de dados utilizada.

De certo modo, não existe um padrão entre os pesos e por isso é necessário avaliar os resultados detalhadamente. Ao avaliar as secas de curto prazo, as maiores divergências entre os resultados dos dados de pluviômetros e das estimativas TRMM ocorreram ao avaliar os parâmetros ligados à quantidade de eventos de seca (*A*), tendências das séries de duração (*E*) e severidade das secas (*F*), enquanto que nos demais casos, os valores podem ser considerados condizentes. Para o SPI-1 e para o SPI-3, os pesos do parâmetro *A* foram maiores ao utilizar os dados de pluviômetros que com base nos dados de satélite, mas para o SPI-6 esse cenário se inverteu. Por outro lado, os pesos atribuídos aos parâmetros de análises de tendências foram superestimados pelo TRMM, à exceção do parâmetro *F* para o SPI-6.

É interessante destacar também que, no geral, os parâmetros relacionados às análises de tendência, i.e., *D*, *E* e *F*, apresentam pesos mais expressivos, independentemente da base

de dados ou da escala temporal, enquanto o parâmetro ligado ao percentual de ocorrência dos eventos secos (C) tem valores baixos. Na maioria dos casos, os três primeiros parâmetros que estão relacionados à situação já ocorrida das secas têm pesos menores a 0,167, valor que seria atribuído caso todas as variáveis tivessem pesos iguais. Realça-se que alguns dos resultados já eram esperados diante do que foi discutido: para o SPI-1, a variância entre as magnitudes de Sen das séries de severidade das secas (Figura 24) com base nas estimativas do TRMM foi baixa e por isso, era de se esperar que o peso dessa variável fosse alto.

Por outro lado, os valores de intensidade média (B) tiveram elevada variabilidade se comparado aos outros cinco parâmetros, e por tal motivo, seu peso foi mais baixo. Percebe-se que a definição dos pesos aos parâmetros está consideravelmente ligada à variância dentre e entre os parâmetros. No caso, pode ocorrer a situação de que por mais que exista alta variância dentre o comportamento de um parâmetro mas esse valor não foi tão alto frente à variância dos demais parâmetros, o peso atribuído será baixo. Para as secas de médio prazo, destaca-se que os parâmetros A e B foram maiores ao utilizar os dados oriundos dos pluviômetros e não há diferença tão significativa ao avaliar o parâmetro C , relacionado ao índice de severidade das secas e que foi proposto por Santos *et al.* (2019b).

Por outro lado, ao tratar do parâmetro D , é possível perceber que há alta tendência do TRMM em superestimar o peso da variável, que chega a alcançar o valor de 0,250. Esse valor é expressivo e indica que tanto para o SPI-9 quanto para o SPI-12, o parâmetro relacionado à magnitude de Sen das séries de comportamento das secas tem relevância na definição da situação de exposição a ação das secas. Além disso, nota-se que a magnitude desse parâmetro está intimamente ligada à variância dos valores de Sen mostrados na Figura 22. É possível perceber que no caso do SPI-9 e SPI-12, quase todo o estado da Paraíba apresenta tendências negativas e essas são uniformes por todas as mesorregiões. Portanto, como a variância entre o comportamento dos *grids* TRMM foi baixa, o peso desse parâmetro foi consideravelmente alto.

No caso dos resultados obtidos a partir dos dados de pluviômetros o cenário se inverte. Como já discutido, a região da Mata Paraibana apresentou tendências positivas, enquanto que a região do interior do estado da Paraíba apresentou tendências negativas. É possível concluir que essa variabilidade dentre as declividades gerou a diminuição do peso do parâmetro D , em se tratando dos resultados dos pluviômetros. Além disso, há diferença ao avaliar os resultados do parâmetro F no caso dos índices SPI-9 e SPI-12, pois no caso do SPI-9 há subestimativa

do TRMM assim como para o SPI-6, enquanto o valor foi superestimado ao avaliar o SPI-12 assim como nas análises do SPI-1 e SPI-3.

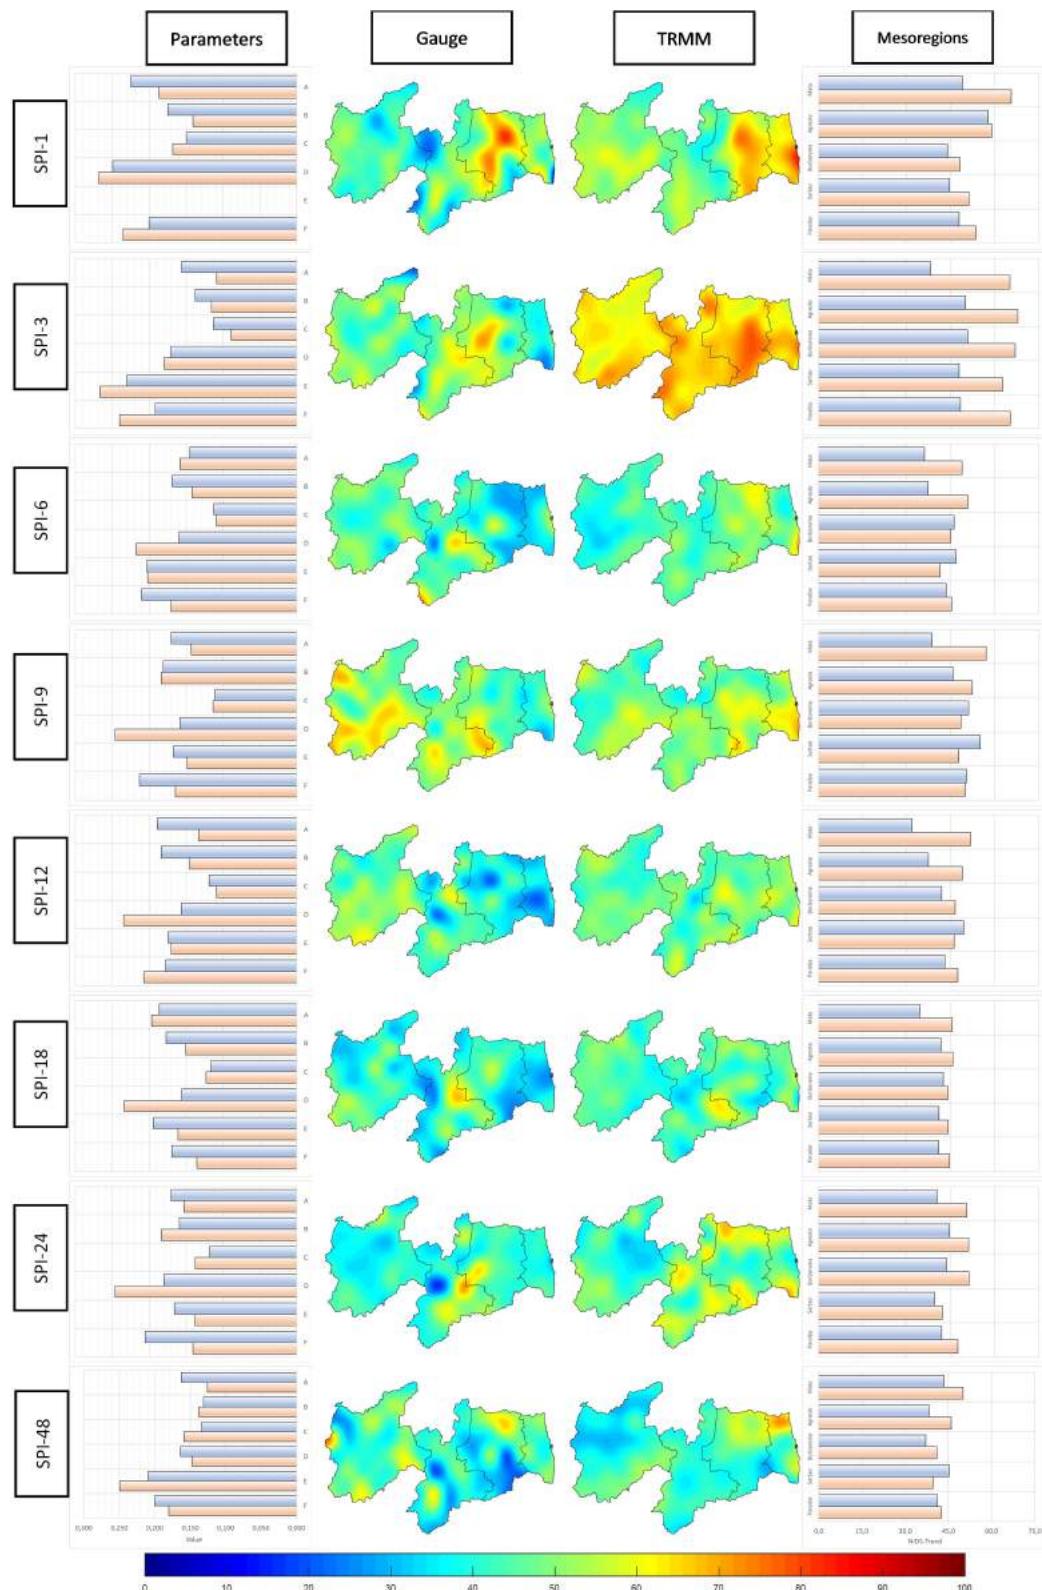


Figura 31– Análise de risco da seca e avaliação do índice NIDS-Trend sobre o estado da Paraíba em múltiplas escalas temporais (1998–2017).

No caso das secas de médio prazo, os pesos das variáveis foram distribuídos de modo mais regular se comparado aos resultados das secas de menor prazo. Para o SPI-9, o peso do parâmetro C foi mais baixo que o valor médio (i.e., $\omega = 0,167$), mas os parâmetros D (para o TRMM) e F (para os pluviômetros) tiveram resultados mais expressivos. Para o SPI-12, a distribuição dos pesos com base nos dados de pluviômetros foi mais regular e os parâmetros A e B tiveram maior relevância. Com base nas estimativas do TRMM, a divisão entre os pesos foi irregular, tendo os parâmetros D e F ultrapassado a ordem de 0,20. Por fim, para as secas de longo prazo, pode-se perceber que foram encontrados os resultados mais distintos dentre todas as escalas temporais.

Consideram-se esses resultados os mais distintos porque há tendência do TRMM em subestimar ou superestimar os pesos atribuídos aos parâmetros em comparação aos resultados dos postos pluviométricos. Para os índices SPI-18 e SPI-24, há grande divergência entre os resultados das duas bases de dados especialmente ao avaliar os parâmetros D , E e F . Para os dois últimos, houve subestimativa do peso por parte do TRMM, mas por outro lado houve notória a superestimativa do peso do parâmetro D . No caso do SPI-48, é possível perceber que houve subestimativa do parâmetro A , enquanto que os valores dos parâmetros C e E foram superestimados pelo satélite TRMM de modo mais expressivo. Após avaliação dos pesos dos parâmetros, cabe analisar a distribuição espacial dos valores do NIDS-Trend sobre o estado da Paraíba e o valor médio de cada mesorregião.

Para o SPI-1, além da variabilidade entre os valores do NIDS-Trend sobre o estado da Paraíba, é possível notar que existe similaridade entre os resultados oriundos das duas bases de dados, apesar de que algumas divergências podem ser percebidas. Com base nos dados de postos, a porção central do Agreste foi a zona que apresentou os maiores valores de NIDS-Trend, enquanto a fronteira entre o Sertão e a Borborema foi a que apresentou os valores mais baixos. Além disso, a variação desses valores foi expressiva, variando de 20 a 80 nas regiões menos e mais críticas, respectivamente. Nas demais mesorregiões, os valores de NIDS-Trend foram da ordem de 50 e o risco quanto à ação das secas é médio. Com base nas estimativas do TRMM, há tendência em superestimar os valores de NIDS-Trend em basicamente todas as mesorregiões.

É possível notar que o TRMM foi capaz de identificar o alto risco à ação da seca no centro do Agreste e o risco mais baixo na fronteira entre Agreste e Borborema. Por outro lado, os valores de NIDS-Trend foram mais altos no Sertão, na Borborema e especialmente no litoral da Paraíba, o que realça o erro por parte do TRMM em captar a distribuição espacial do

índice. Ao avaliar o padrão por mesorregiões, os valores de NIDS-Trend computados a partir dos dados de postos pluviométricos não são homogêneos e ultrapassam o valor de 50 em vários casos. Já os valores do satélite TRMM, por sua vez, são superestimados em todas as regiões e consequentemente na Paraíba como um todo. No mais, especialmente na Mata e no Agreste, os valores de NIDS-Trend são da ordem de 60, o que indica uma condição de risco mais acentuada.

A distribuição espacial do NIDS-Trend do SPI-3 é parecida com a do SPI-1, mas há alteração no tocante à magnitude dos valores. Com base nos dados de postos pluviométricos, a região central do Agreste teve maior risco à ação das secas, bem como a região limítrofe entre o Agreste e a Borborema, mas com magnitude inferior se comparada aos resultados do índice SPI-1. Além disso, a Mata Paraibana passou a ter um risco menos expressivo, enquanto que a fronteira entre as regiões do Sertão e da Borborema tiverem aumento do risco à ação das secas. Ao utilizar os dados TRMM, pode-se perceber um comportamento bastante singular em comparação ao produto obtido com base nos dados de pluviômetros.

Nesse caso, os valores do NIDS-Trend foram muito mais acentuados se comparados aos resultados para o SPI-1. Os valores mínimos de NIDS-Trend foram superiores a 55, o que revela que em se tratando do índice SPI-3 há elevado risco de ação das secas sobre o estado da Paraíba como um todo e essa foi a análise de risco mais crítica dentre as desenvolvidas. Um destaque especial merece ser dado ao comportamento em grande parte do Agreste e na porção leste da Borborema, regiões que apresentaram os maiores valores de NIDS-Trend. Em relação ao comportamento das mesorregiões, é válido destacar que houve aumento nos valores do NIDS-Trend em todas as mesorregiões, que passaram a ter valores superiores a 60.

De todo modo, assim como para o SPI-1, pontua-se a tendência de superestimativa por parte do TRMM e ressalta-se que esse comportamento ocorreu de modo mais expressivo e em toda a Paraíba. Dentre os índices SPI empregados para caracterizar as secas de curto prazo, os resultados obtidos entre as duas bases de dados para o SPI-6 podem ser considerados os mais similares entre si. Utilizando os dados dos pluviômetros, nota-se que diferentemente do que ocorreu ao avaliar o SPI-1 e SPI-3, o Agreste não teve risco tão alto se comparado às outras mesorregiões. No caso, os valores mais altos do NIDS-Trend foram encontrados no leste e sul da zona da Borborema, enquanto que os mais baixos se concentraram na faixa limítrofe do Agreste e a Mata. Nas demais zonas, os valores foram medianos e se mantiveram na ordem de 50.

Com base no satélite, as divergências mais significativas com os resultados oriundos de postos pluviométricos foram na região do Agreste, em especial na porção nordeste e no centro da Borborema. Nesse caso, os valores de NIDS-Trend estimados pelo TRMM foram superiores aos calculados a partir dos postos. Entretanto, nas outras regiões as inconsistências não foram tão notáveis, e pode-se dizer que o TRMM captou o padrão de vulnerabilidade quanto à ação das secas sobre o estado da Paraíba. Quanto aos resultados das mesorregiões, destaca-se que os valores do índice foram menos acentuados e variaram na ordem de 45. À exceção do comportamento encontrado no Sertão e na Borborema, os valores foram sempre superestimados pelo TRMM, especialmente na Mata Paraibana e no Agreste Paraibano.

Ao avaliar os resultados do SPI-9, ressalta-se mudança na distribuição espacial do NIDS-Trend em comparação aos resultados das secas de curto prazo. Com base nos dados dos postos pluviométricos, há aumento na variabilidade do índice sobre o estado e fica ainda mais evidente que diferentemente dos resultados das secas de curto prazo, as áreas centro-oeste do Sertão e sudeste da Borborema apresentam os valores mais altos do NIDS-Trend, enquanto o Agreste e a Mata Paraibana apresentam os menores risco a ação de secas e seus valores não ultrapassam a faixa de 40. Em relação ao uso dos dados de satélite, pode-se perceber que em algumas regiões, os resultados foram ora concordantes, ora discordantes em comparação aos dos postos.

O satélite TRMM identificou o elevado risco à ação das secas na porção sudeste da Borborema, estimando a magnitude e a extensão espacial de modo preciso. De certo modo, a precisão também foi identificada no norte do Sertão e em grande parte da Borborema, fato que realça o bom desempenho das estimativas. Entretanto, no sudoeste do Sertão, na Mata e no Agreste Paraibano as divergências entre as bases de dados foram mais expressivas. Logo, no interior do estado o TRMM subestimou os valores NIDS-Trend, e no Agreste e na Mata os valores foram superestimados, indicando maior vulnerabilidade à ação das secas. Ao avaliar o comportamento das mesorregiões, ressalta-se a superestimativa por parte do TRMM na Mata, cujo os valores médios foram próximos a 60.

Os resultados encontrados entre o SPI-12 e o SPI-9 são diferentes ao utilizar os dados de postos pluviométricos, mas muito similares ao usar as estimativas do satélite TRMM. Com base nos dados de postos pluviométricos, fica evidente que o Sertão e Borborema tiveram os maiores valores de NIDS-Trend, mas a magnitude desses valores caiu muito em comparação aos resultados do índice SPI-9. Além disso, é possível perceber que o mesmo aconteceu nas regiões próximas ao litoral, especialmente no sul da Mata Paraibana e no noroeste do Agreste.

Com base nas estimativas do TRMM, os dados expressivos do NIDS-Trend se concentraram no Agreste Paraibano e na Mata Paraibana assim como para o SPI-9, enquanto que na porção central da Borborema os valores indicam menor risco à ação das secas.

Ao comparar os resultados das duas bases de dados, pode-se perceber que o satélite apresentou comportamento mais homogêneo se comparado aos resultados obtidos a partir dos dados de pluviômetros. Destaca-se que no centro do Agreste e em praticamente toda Mata Paraibana, os valores do índice de seca foram notoriamente superestimados pelo TRMM, indicando que as regiões são mais vulneráveis à ação das secas. No geral, o valor médio do NIDS-Trend entre as diferentes mesorregiões foi da ordem de 45 com base nas estimativas do satélite e inferior ao utilizar os dados de pluviômetros. Os erros mais expressivos ocorreram para a Mata Paraibana e para o Agreste com uma superestimativa considerável dos valores de NIDS-Trend, enquanto que no Sertão o NIDS-Trend médio foi subestimado pelo TRMM.

Ao realizar a análise do SPI-18, percebe-se que a distribuição espacial do NIDS-Trend obtida a partir das bases de dados se assemelha. A partir dos dados dos postos pluviométricos, os resultados surpreendentemente se assemelham aos do SPI-3 e SPI-12, resultado que revela a existência de relação entre o comportamento das secas de curto, médio e longo prazo. No geral, o Sertão, a região limítrofe entre a Borborema e o Agreste, e o noroeste do Agreste são as áreas que apresentam maior risco à ação das secas, enquanto que a fronteira entre o Sertão e Borborema, o sudeste do Agreste, e grande parte da Mata tem risco menos acentuado. A partir das estimativas TRMM, é válido destacar considerável homogeneidade do NIDS-Trend sobre o estado da Paraíba.

Os valores do índice variaram entre 40 e 50 e a Borborema foi a mesorregião que teve maior variabilidade. De certo modo, destaca-se forte tendência do TRMM em superestimar os valores de NIDS-Trend em todas as mesorregiões, mas existe uma precisão ao captar o padrão na Borborema. Para o SPI-24, há similaridade com os resultados do SPI-18, mas pontua-se a alteração na magnitude dos valores. Ao utilizar os dados dos pluviômetros, houve aumento do NIDS-Trend sobre o estado e há homogeneidade desses valores dentre as mesorregiões, salvo a exceção do resultado na Borborema. A região limítrofe entre o Sertão e a Borborema tem o menor risco à ação das secas, enquanto a zona a leste dessa área teve os valores de NIDS-Trend mais altos.

Com base nas estimativas do TRMM, os valores de risco à ação das secas voltam a ser mais altos assim como no SPI-1 e SPI-9. No geral, as regiões ao norte e ao sul do Agreste que

fazem divisas com o estado do Rio Grande do Norte e com Pernambuco são as zonas que tem os riscos mais altos à ação das secas. Ao comparar os resultados obtidos entre as bases de dados, nota-se que assim como para o SPI-18, os valores obtidos a partir dos dados do satélite superestimaram os resultados dos postos pluviométricos, destacando-se dentre as incoerências mais notáveis a que foi encontrado na porção central da Borborema, seguida da zona oeste do Sertão e do norte e sul do Agreste. Ao avaliar o valor médio das mesorregiões, confirma-se a baixa variabilidade dos resultados para os dados de pluviômetros e a superestimativa notável do TRMM em todas as regiões.

A avaliar o comportamento do SPI-48, é possível perceber uma queda quanto ao risco à ação das secas em comparação aos resultados do SPI-24. Ao utilizar os dados dos postos, nota-se que grande parte da Borborema e o sul do Agreste apresentam os menores valores de NIDS-Trend, enquanto que o oeste do Sertão e nordeste do Agreste têm maior risco à ação das secas. Em comparação aos resultados do satélite, destaca-se forte tendência do TRMM em superestimar os valores do NIDS-Trend na Borborema, no Agreste e no nordeste de Mata Paraibana. Por outro lado, nas regiões com os valores de risco mais expressivos conforme os dados de pluviômetros os valores do NIDS-Trend foram mais baixos segundo as estimativas TRMM, e isso ocorreu de modo mais significativo no oeste do Sertão.

Segundo Gutierrez *et al.* (2014), uma larga porção do NEB enfrentou uma das secas mais devastadoras dos últimos tempos e diante desse episódio, os autores avaliaram a situação relativa às políticas de preparação e mitigação contra a ação das secas no Brasil. Desse modo, os autores afirmam que o gerenciamento de risco dos desastres é uma combinação de diversas etapas e a primeira delas a identificação do risco de modo propriamente dito. No caso, a etapa está intimamente ligada não só ao monitoramento dos riscos como também à modelagem probabilística relacionada à ocorrência das secas, tarefa similar ao processo desenvolvido no presente trabalho, e isto realça a utilidade do NIDS-Trend no âmbito regional e nacional.

Silva e Lúcio (2014) propuseram um indicador de vulnerabilidade agrícola sobre o Rio Grande do Norte aliando conceitos de exposição, sensibilidade e capacidade adaptativa. No tocante à exposição das secas, que se assemelha ao conceito de análise de risco desenvolvido neste trabalho, os autores levaram em consideração a quantidade e a severidade dos eventos úmidos e secos, mas não desenvolveram análises de tendências ou frequência para compor o índice de exposição, como feito no NIDS-Trend. Ademais, pode-se perceber que na fronteira do sul do Rio Grande do Norte e as mesorregiões do Sertão Paraibano e Borborema, o risco de exposição às secas foi alto conforme o estudo de Silva e Lúcio (2014) e que esse resultado

também pode ser encontrado no caso do SPI-3, índice comumente empregado para avaliar o padrão das secas agrícolas.

Pouco depois, Silva *et al.* (2017) estenderam a área de estudo e realizaram a avaliação da vulnerabilidade agrícola no NEB, utilizando a ideia de Silva e Lúcio (2014). Nesse estudo, grande parte do estado da Paraíba tem alta susceptibilidade à ação das secas, com exceção da região litorânea. Além disso, no Agreste os valores foram menos acentuados do que no Sertão e na Borborema. O problema de efetuar a comparação entre esses resultados com os nossos é que não sabe qual foi a escala temporal empregada pelos estudiosos. Ao estimar que a escala é a que se baseia em três meses (SPI-3), nota-se que os valores NIDS-Trend obtidos a partir dos dados de pluviômetros indicam que a Mata Paraibana é a região com menor risco e o Agreste e a Borborema o risco é mais expressivos. Por outro lado, não foi possível identificar o alto risco na região do Sertão à ação das secas com base no índice proposto.

6. CONCLUSÕES

A partir deste trabalho, foi possível avaliar as secas e suas características em múltiplas escalas temporais sobre o estado da Paraíba utilizando dados de pluviômetros e estimativas de precipitação oriundas de satélite de sensoriamento remoto. Quanto à acurácia do TRMM, há considerável variabilidade entre as mesorregiões do estado e a escala temporal influencia na precisão das estimativas TRMM. As mesorregiões da Mata Paraibana e do Agreste Paraibano são as áreas em que há maior imprecisão das estimativas do satélite, enquanto no Sertão e na Borborema os resultados foram satisfatórios. Além disso, os resultados obtidos para as secas de médio prazo foram os mais expressivos, mas o padrão das de curto e longo prazo também foram relevantes na maior parte do estado.

Quanto à capacidade do satélite em caracterizar os eventos de seca, conclui-se que as estimativas de precipitação são hábeis a captar as diferentes características dos eventos. Para as secas de curto prazo, a quantidade de eventos é maior e esses são menos duradouros e severos se comparados aos eventos das secas de longo prazo. Entretanto, a intensidade média dos eventos não variou tanto com a alteração da escala temporal nem dentre as mesorregiões. Pode-se perceber que os eventos são mais frequentes para as secas de curto prazo, mas esses diminuem em quantidade e aumentam em severidade no caso das secas de longo prazo. Além disso, o percentual de área atingida por eventos secos nos últimos anos foi alto e apesar dos erros, pode-se concluir que o TRMM captou os eventos mais severos dos últimos anos.

Em relação às análises de tendências, os resultados a partir do TRMM identificaram a existência de tendências sobre o estado da Paraíba e isso foi feito de modo mais preciso para a duração e severidade das secas. Além disso, quanto maior a escala temporal mais expressiva foram as declividades das linhas de tendência e a significância das séries. No caso da duração e severidade das secas, os eventos tenderam a ser mais duradouros e severos com o aumento da escala temporal, mas a significância dessas séries não foi tão sensível à variação da escala de tempo. Conclui-se que os eventos tendem a ser mais secos, duradouros e severos na maior parte do estado, e as maiores incoerências entre os resultados obtidos a partir de dados de pluviômetros e estimados pelo TRMM foram nas zonas mais proximidade ao litoral do estado.

Quanto ao zoneamento da Paraíba, o TRMM captou o padrão de regionalização obtido a partir dos dados de estações, mas existem incoerências. No geral, há tendência em dividir o estado em duas grandes regiões, sendo uma formada pela Mata Paraibana e Agreste e outra pelo Sertão e Borborema. Por outro lado, essa divisão é mais evidente ao avaliar as secas de curto prazo, pois com base nas secas de longo prazo há tendência em agrupar todo o estado da Paraíba em um único *cluster*. As séries TRMM são mais similares entre si e indicam que as regiões do Sertão e Borborema apresentam maior homogeneidade, enquanto os resultados de pluviômetros têm maior variabilidade entre si e indicam que a Mata Paraibana e o Agreste são as duas mesorregiões de maior similaridade entre si.

Em relação ao NIDS-Trend, há similaridade relevante entre os resultados encontrados a partir dos dados de pluviômetros e as estimativas do TRMM. No tocante às estimativas dos pesos dos parâmetros, é interessante pontuar que os parâmetros relacionados às análises de tendência tiveram pesos mais expressivos que os outros referentes à quantidade, intensidade e frequência dos eventos em múltiplas escalas temporais. Para as secas de curto prazo, o valor do NIDS-Trend tendeu ser maior, enquanto o risco à ação das secas caiu com o aumento da escala temporal. Por fim, pode-se perceber que há tendência do TRMM em superestimar os valores do NIDS-Trend e na maioria dos casos, as incoerências mais significativas ocorreram ao avaliar a Mata Paraibana e o Agreste Paraibano.

7. RECOMENDAÇÕES

Apesar da quantidade de resultados apresentados nesta pesquisa, é válido pontuar que algumas lacunas ainda precisam ser preenchidas no intuito de que o entendimento a respeito do padrão das secas e de suas consequências seja ainda mais completo. Desse modo, uma das

primeiras recomendações deste trabalho é avaliar não só outros índices de seca como também o desempenho de outras estimativas de satélite sobre a região. No tocante à escolha do índice de seca, é fato que o SPI é um dos índices mais utilizados no mundo e isso está ligado às suas facilidades e à sua eficiência em monitorar as secas em múltiplas escalas temporais. Por outro lado, utilizar índices que levam em considerações mais variáveis meteorológicas, como é o caso do SPEI, por exemplo, abrirá margem para outras análises e compreensão do fenômeno.

Quanto à avaliação do desempenho de outras estimativas, vale destacar que o TRMM foi alvo de muitos estudos diante da robustez e da escala espaço-temporal dos seus dados. No entanto, com o advento da tecnologia, outros produtos têm sido desenvolvidos com escalas espaço-temporais detalhadas e janelas temporais mais abrangentes. Nesse sentido, avaliar o desempenho de outros produtos para monitorar as secas é um exercício que pode abrir ainda mais o leque de ferramentas disponíveis para entender o padrão desses fenômenos. De modo específico e em relação à análise de acurácia das estimativas de precipitação, sugere-se o uso de outras métricas estatísticas e métodos de comparação espacial no intuito de validar quais são as metodologias mais adequadas para comparar séries de dados pontuais e em *grid*.

Em relação à análise de tendências, utilizar métodos como o teste de Mann-Kendall modificado pode garantir mais robustez ao processo de avaliação das tendências das secas e de suas magnitudes. Em relação às técnicas de agrupamento, desenvolver análises com base em métodos não hierárquicos como *k-means* ou SOM e comparar os resultados obtidos com os de técnicas hierárquicas pode viabilizar novas formas de agrupamento entre as regiões, realçando as potencialidades de cada um. Por fim, em relação ao desenvolvimento do NIDS-Trend, sugere-se o desenvolvimento de estudos que validem o uso do índice em regiões com comportamentos similares e diversos ao do estado da Paraíba. A partir desses testes, poderá ser possível concluir se o NIDS-Trend é capaz de identificar quais são as zonas mais e menos vulneráveis e expostas à ação das secas.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abramowitz M. e Stegun I. Handbook of mathematical functions with formulas, graphs, and mathematical table. New York: Dover, 1965.
- Adnan S., Ullah K., Shuanglin L., Gao S., Khan A.H. e Mahmood R. 2017. Comparison of various drought indices to monitor drought status in Pakistan. *Climate Dynamics*, **51**(5-6), 1885–1899. doi: 10.1007/s00382-017-3987-0
- Alexander L.V., Fowler H.J., Bador M., Behrang A., Donat M., Dunn R., Funk C., Goldie J., Lewis E., Rogé M., Seneviratne S.I. e Venugopal V. 2019. On the use of indices to study extreme precipitation on sub-daily and daily timescales. *Environmental Research Letters*, **14**(12), 125008. doi: 10.1088/1748-9326/ab51b6
- Almeida C.T., Delgado R.C., Oliveira-Júnior J.F., Gois G. e Cavalcanti A.S. 2015. Avaliação das Estimativas de Precipitação do Produto 3B43-TRMM do Estado do Amazonas. *Floresta e Ambiente*, **22**(3), 279–286. doi: 10.1590/2179-8087.112114
- Araújo W.S. e Souza F.A.S. 2012. Identificação de regiões pluviometricamente homogêneas no Nordeste do Brasil usando análise multivariada. *Revista Brasileira de Climatologia*, **10**(1), 136–152. doi: 10.5380/abclima.v10i1.30600
- Ashouri H., Hsu K.-L., Sorooshian S., Braithwaite D.K., Knapp K.R., Cecil L.D., Nelson B.R. e Prat O.P. 2015. PERSIANN-CDR: Daily Precipitation Climate Data Record from Multisatellite Observations for Hydrological and Climate Studies. *Bulletin of the American Meteorological Society*, **96**(1), 69–83. doi: 10.1175/BAMS-D-13-00068.1
- Awange J.L., Mpelasoka F. e Goncalves R.M. 2016. When every drop counts: Analysis of Droughts in Brazil for the 1901-2013 period. *Science of The Total Environment*, **566-567**, 1472–1488. doi: 10.1016/j.scitotenv.2016.06.031
- Barbosa L.R., Freitas E.S., Almeida C.N. e Melo D.C.D. 2015. Rainfall in an experimental watershed: A comparison between observed and TRMM 3B42V7 dataset. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, **40**(7W3), 1447–1452. doi: 10.5194/isprarchives-xl-7-w3-1447-2015
- Becker A., Finger P., Meyer-Christoffer A., Rudolf B., Schamm K., Schneider U. e Ziese M. 2013. A description of the global land-surface precipitation data products of the Global Precipitation Climatology Centre with sample applications including centennial (trend)

analysis from 1901–present. *Earth System Science Data*, **5**(1), 71–99. doi:10.5194/essd-5-71-2013

Botai C.M., Botai J.O., Wit J.P., Ncongwane K.P. e Adeola A.M. 2017. Drought characteristics over the Western Cape Province, South Africa. *Water*, **9**(11), 876–891. doi: 10.3390/w9110876

Brasil Neto R.M., Santos C.A.G. e Silva R.M. Avaliação da influência da evapotranspiração potencial na análise de seca no estado da Paraíba. In: XIV Simpósio de Recursos Hídricos do Nordeste, 2018, Maceió. Anais do XIV Simpósio de Recursos Hídricos do Nordeste. Porto Alegre: ABRH, 2018, p. 1–10.

Brasil Neto R.M., Nascimento T.V.M., Santos C.A.G. e Silva R. M. Avaliação do desempenho do satélite TRMM na identificação das secas sobre o estado da Paraíba. In: XXIII Simpósio Brasileiro de Recursos Hídricos, 2019a, Foz do Iguaçu. Anais do XXIII Simpósio Brasileiro de Recursos Hídricos. Porto Alegre: ABRHidro, 2019, p. 1–10.

Brasil Neto R.M., Santos C.A.G. e Meneses I.A. Análise da correlação entre precipitação e o NDVI sobre o estado da Paraíba utilizando dados TRMM e de pluviômetros. In: XXIII Simpósio Brasileiro de Recursos Hídricos, 2019b, Foz do Iguaçu. Anais do XXIII Simpósio Brasileiro de Recursos Hídricos. Porto Alegre: ABRHidro, 2019, p. 1–10.

Brasil Neto R.M., Santos C.A.G. e Silva R.M. Análise espacial da seca no estado da Paraíba em 2015 utilizando dados do satélite TRMM e SPI. In: XXII Simpósio Brasileiro de Recursos Hídricos, 2017, Florianópolis. Anais do XXII Simpósio Brasileiro de Recursos Hídricos. Porto Alegre: ABRH, 2017, p. 1–8.

Brasil Neto R.M., Santos C.A.G., Silva R.M. e Costa S.G.F. Análise espacial da quantidade de dias secos e úmidos no estado da Paraíba. In: XIII Simpósio de Recursos Hídricos do Nordeste, 2016, Aracaju. Anais do XIII Simpósio de Recursos Hídricos do Nordeste. Porto Alegre: ABRH, 2016, p. 1–10.

Brito S.S., Cunha A.P., Cunningham C.C., Alvalá R.C., Marengo J.A. e Carvalho M.A. 2018. Frequency, duration and severity of drought in the Semiarid Northeast Brazil region. *International Journal of Climatology*, **38**(2), 517–529. doi:10.1002/joc.5225

Brito T.T., Oliveira-Júnior J.F., Lyra G.B., Gois G. e Zeri M. 2017. Multivariate analysis applied to monthly rainfall over Rio de Janeiro state, Brazil. *Meteorology and Atmospheric Physics*, **129**(5), 469–478. doi: 10.1007/s00703-016-0481-x

- Byakatonda J., Parida B.P., Moalafhi D.B. e Kenabatho P.K. 2018. Analysis of long-term drought severity characteristics and trends across semiarid Botswana using two drought indices. *Atmospheric Research*, **213**, 492–508. doi: 10.1016/j.atmosres.2018.07.002
- Caliński T. e Harabasz J. 1974. A dendrite method for cluster analysis. *Communications in Statistics - Theory and Methods*, **3**(1), 1–27. doi: 10.1080/03610927408827101
- Caloiero T. 2017. Drought analysis in New Zealand using the Standardized Precipitation Index. *Environmental Earth Sciences*, **76**(16), 569–581. doi: 10.1007/s12665-017-6909-x
- Caloiero T., Veltri S., Caloiero P. e Frustaci F. 2018. Drought analysis in Europe and in the Mediterranean basin using the Standardized Precipitation Index. *Water*, **10**(8), 1043 –1055. doi: 10.3390/w10081043
- Cao Y., Zhang W. e Wang W. 2018. Evaluation of TRMM 3B43 data over the Yangtze River Delta of China. *Scientific Reports*, **8**(1), 5290–5301. doi: 10.1038/s41598-018-23603-z
- Cashion J., Lakshmi V., Bosch D. e Jackson T.J. 2005. Microwave remote sensing of soil moisture: Evaluation of the TRMM microwave imager (TMI) satellite for the Little River Watershed Tifton, Georgia. *Journal of Hydrology*, **307**(1-4), 242–253. doi: 10.1016/j.jhydrol.2004.10.019
- Chen C., Chen Q., Duan Z., Zhang J., Mo K., Li Z. e Tang G. 2018. Multiscale Comparative Evaluation of the GPM IMERG v5 and TRMM 3B42 v7 Precipitation Products from 2015 to 2017 over a Climate Transition Area of China. *Remote Sensing*, **10**(6), 944–961. doi: 10.3390/rs10060944
- Cohen J. 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, **20**(1), 37–46. doi:10.1177/001316446002000104
- Coughlan M.J. 1987. Monitoring drought in Australia. In: Planning for drought: toward a reduction of societal vulnerability. West View, Boulder, pp 131–144.
- Cruz M.A.S., Rocha L.T., Aragão R. e Almeida A.Q. 2018. Aplicabilidade da precipitação TRMM para modelagem hidrológica em uma bacia no agreste do Nordeste Brasileiro. *Revista Brasileira de Meteorologia*, **33**(1), 57–64. doi: 10.1590/0102-7786331013
- Cunha A.P.M.A., Tomasella J., Ribeiro-Neto G.G., Brown M., Garcia S.R., Brito S.B. e Carvalho M.A. 2018. Changes in the spatial-temporal patterns of droughts in the Brazilian Northeast. *Atmospheric Science Letters*, **19**(10), 855–862. doi: 10.1002/asl.855

- Curtarelli M.P., Renno C.D. e Alcantara E.H. 2014. Evaluation of the Tropical Rainfall Measuring Mission 3B43 product over an inland area in Brazil and the effects of satellite boost on rainfall estimates. *Journal of Applied Remote Sensing*, **8**(14), 1–14. doi: 10.1117/1.JRS.8.083589
- Dashtpagerdi M.M., Kousari M.R., Vaghfarfard H., Ghonchepour D., Hosseini M.E. e Ahani H. 2018. An investigation of drought magnitude trend during 1975–2005 in arid and semi-arid regions of Iran. *Environmental Earth Sciences*, **73**(3), 1231–1244. doi: 10.1007/s12665-014-3477-1
- Edwards D.C. e McKee T.B. 1997. Characteristics of 20th Century Drought in the United States at Multiple Time Scales. Climatology Report 97-2, Department of Atmospheric Science, Colorado State University, Fort Collins.
- Farhangi M., Kholghi M. e Chavoshian S.A. 2016. Rainfall Trend Analysis of Hydrological Subbasins in Western Iran. *Journal of Irrigation and Drainage Engineering*, **142**(10), 1–11. doi: 10.1061/(ASCE)IR.1943-4774.0001040
- Farias A.A., Souza J.T.A. e Sousa F.A.S. 2014. Identification and analysis of severe and extreme dry in the municipality of Taperoá-PB. *Revista Brasileira de Geografia Física*, **7**(5), 818–826.
- Fensterseifer C., Allasia D.G. e Paz A.R. 2016. Assessment of the TRMM 3B42 Precipitation Product in Southern Brazil. *Journal of the American Water Resources Association*, **52**(2), 367–375. doi: 10.1111/1752-1688.12398
- Franchito S.H., Rao V.B., Vasques A.C., Santo C.M.E. e Conforte J.C. 2009. Validation of TRMM precipitation radar monthly rainfall estimates over Brazil. *Journal of Geophysical Research: Atmospheres*, **114**(2), D02105. doi: 10.1029/2007JD009580
- Fu Q., Zhou Z., Li T., Liu D., Hou R., Cui S. e Yan P. 2018. Spatiotemporal characteristics of droughts and floods in northeastern China and their impacts on agriculture. *Stochastic Environmental Research and Risk Assessment*, **32**(10), 2913–2931. doi: 10.1007/s00477-018-1543-z
- Funk C., Peterson P., Landsfeld M., Pedreros D., Verdin J., Shukla S. e Michaelsen J. 2015. The climate hazards infrared precipitation with stations – A new environmental record for monitoring extremes. *Scientific Data*, **2**, 150066. doi: 10.1038/sdata.2015.66

- Gadelha A.N., Coelho V.H.R., Xavier A.C., Barbosa L.R., Melo D.C.D., Xuan Y., Huffman G.J., Petersen W.A. e Almeida C.D.N. 2019. Grid box-level evaluation of IMERG over Brazil at various space and time scales. *Atmospheric Research*, **218**, 231–244. doi: 10.1016/j.atmosres.2018.12.001
- Gao B. 1996. NDWI: A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, **58**(3), 257–266. doi: 10.1016/S0034-4257(96)00067-3
- Ghosh K.P. 2018. Spatial and temporal appraisal of drought jeopardy over the Gangetic West Bengal, eastern India. *Geoenvironmental Disasters*, **6**(1), 1–21. doi: 10.1186/s40677-018-0117-1
- Gilbert R.O. 1987. Statistical method for environmental pollution monitoring, Chapter 16.4 Mann–Kendall Test, pp 208–217, and Appendix A, Table A.18 Probabilities for Mann–Kendall nonparametric test for trend, p 272. Wiley, New York.
- Goyal M.K. e Gupta V. 2014. Identification of homogeneous rainfall regimes in northeast region of India using fuzzy cluster analysis. *Water Resources Management*, **28**(13), 4491–4511. doi: 10.1007/s11269-014-0699-7
- Guhathakurta P., Menon P., Inkane P.M., Krishnan U. e Sable S.T. 2017. Trends and variability of meteorological drought over the districts of India using standardized precipitation index. *Journal of Earth System Science*, **126**(8), 120–137. doi: 10.1007/s12040-017-0896-x
- Guo H., Bao A., Liu T., Chen S. e Ndayisaba F. 2016. Evaluation of PERSIANN-CDR for Meteorological Drought Monitoring over China. *Remote Sensing*, **8**(5), 379–393. doi: 10.3390/rs8050379
- Guo H., Bao A., Liu T., Jiapaer G., Ndayisaba F., Jiang L., Kurban A. e De Maeyer P. 2018a. Spatial and temporal characteristics of droughts in Central Asia during 1966–2015. *Science of the Total Environment*, **624**, 1523–1538. doi: 10.1016/j.scitotenv.2017.12.120
- Guo H., Bao A., Ndayisaba F., Liu T., Jiapaer G., El-Tantawi A.M. e De Maeyer P. 2018b. Space-time characterization of drought events and their impacts on vegetation in Central Asia. *Journal of Hydrology*, **564**, 1165–1178. doi: 10.1016/j.jhydrol.2018.07.081

Gutiérrez A.P.A., Engle N.L., De Nys E., Molejón C. e Martins E.S. 2014. Drought preparedness in Brazil. *Weather and Climate Extremes*, **3**, 95–106. doi: 10.1016/j.wace.2013.12.001

Haboudane D., Miller J.R., Pattey E., Zarco-Tejada P.J. e Strachan I.B. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, **90**(3), 337–352. doi: 10.1016/j.rse.2003.12.013

Haied N., Foufou A., Chaab S., Azlaoui M., Khadri S., Benzahia K. e Benzahia I. 2017. Drought assessment and monitoring using meteorological indices in a semi-arid region. *Energy Procedia*, **119**, 518–529. doi: 10.1016/j.egypro.2017.07.064

Hao Z. e AghaKouchak A. 2013. Multivariate Standardized Drought Index: a parametric multi-index model. *Advances in Water Resources*, **57**, 12–18. doi: 10.1016/j.advwatres.2013.03.009

Heim R.R. 2002. A review of twentieth-century drought indices used in the United States. *Bulletin of the American Meteorological Society*, **83**, 1149–1165. doi:10.1175/1520-0477(2002)083<1149:AROTDI>2.3.CO;2

Henry A.J. 1906. Climatology of the United States, Bulletin Q. U.S. Weather Bureau Bulletin. 361, Washington, DC, pp. 51–58.

Hou A.Y., Kakar R.K., Neeck S., Azarbarzin A.A., Kummerow C.D., Kojima M. e Iguchi T. 2014. The global precipitation measurement mission. *Bulletin of the American Meteorological Society*, **95**(5), 701–722. doi: 10.1175/bams-d-13-00164.1

Huffman G.J., Bolvin D.T. e Nelkin E.J. 2015. Integrated Multi-satellitE Retrievals for GPM (IMERG) technical documentation.

Huffman G.J., Bolvin D.T., Nelkin E.J., Wolff D.B., Adler R.F., Gu G. e Stocker E.F. 2007. The TRMM multisatellite precipitation analysis (TMPA): Quasi-global, multiyear, combined-sensor precipitation estimates at fine scales. *Journal of Hydrometeorology*, **8**(1), 38–55. doi: 10.1175/JHM560.1

IBGE, Instituto Brasileiro de Geografia e Estatística. 2016. Divisão regional do Brasil em mesorregiões e microrregiões geográficas territoriais brasileiras. Disponível em:

http://biblioteca.ibge.gov.br/visualizacao/livros/liv2269_1.pdf. Rio de Janeiro. Acesso em: nov. de 2019.

Ionita M., Scholz P. e Chelcea S. 2016. Assessment of droughts in Romania using the Standardized Precipitation Index. *Natural Hazards*, **81**(3), 1483–1498. doi: 10.1007/s11069-015-2141-8

Jesús A., Breña-Naranjo J.A., Pedrozo-Acuña A. e Yamanaka V.H.A. 2016. The Use of TRMM 3B42 Product for Drought Monitoring in Mexico. *Water*, **8**(8), 325–342. doi: 10.3390/w8080325

Jiang S., Ren L., Zhou M., Young B., Zhang Y. e Ma M. 2017. Drought monitoring and reliability evaluation of the latest TMPA precipitation data in the Weihe River Basin, Northwest China. *Journal of Arid Land*, **9**(2), 256–269. doi: 10.1007/s40333-017-0007-5

Joyce R.J., Janowiak J.E., Arkin P.A. e Xie P. 2004. CMORPH: A method that produces global precipitation estimates from passive microwave and infrared data at high spatial and temporal resolution. *Journal of Hydrometeorology*, **5**(3), 487–503. doi: 10.1175/1525-7541(2004)005<0487:CAMTPG>2.0.CO;2

Júnior W.S., Baldwin C., Camkin J., Fidelman P., Silva O., Neto S. e Smith T.F. 2016. Water: Drought, Crisis and Governance in Australia and Brazil. *Water*, **8**(11), 493–513. doi: 10.3390/w8110493

Kao S.C. e Govindaraju R.S. 2010. A copula-based joint deficit index for droughts. *Journal of Hydrology*, **380**(1-2), 121–134. doi: 10.1016/j.jhydrol.2009.10.029

Keller Filho T., Assad E.D. e Lima P.R.S.R. 2005. Regiões pluviometricamente homogêneas no Brasil. *Pesquisa Agropecuária Brasileira*, **40**(4), 311–322. doi: 10.1590/S0100-204X2005000400001

Kenabatho P.K., McIntyre N.R., Chandler R.E. e Wheater H.S. 2012. Stochastic simulation of rainfall in the semi-arid Limpopo basin, Botswana. *International Journal of Climatology*, **32**(7), 1113–1127. doi:10.1002/joc.2323

Kendall M.G. 1975. Rank Correlation Methods, Charles Griffin, London, 220 p.

Kendall M.G. e Smith B.B. 1939. The Problem of m Rankings. *The Annals of Mathematical Statistics*, **10**(3), 275–287. doi:10.1214/aoms/1177732186

- Kendall M.G. e Stuart A. 1977. The advanced theory of statistics. High Wycombe, London, 676 p.
- Khan M. I., Liu D., Fu Q. e Faiz M.A. 2018. Detecting the persistence of drying trends under changing climate conditions using four meteorological drought indices. *Meteorological Applications*, **25**, 184–194. doi:10.1002/met.1680
- Khanmohammadi N., Rezaie H. e Behmanesh J. 2018. The spatial-temporal variation of dry and wet periods in Iran based on comparing SPI and RDI indices. *Stochastic Environmental Research and Risk Assessment*, **32**(10), 2771–2785. doi: 10.1007/s00477-018-1594-1
- Kidd C. e Huffman G. 2011. Global precipitation measurement. *Meteorological Applications*, **18**(3), 334–353. doi: 10.1002/met.284
- Kidd C., Becker A., Huffman G.J., Muller C.L., Joe P., Skofronick-Jackson G. and Kirschbaum D.B. 2017. So, How Much of the Earth's Surface Is Covered by Rain Gauges? *Bulletin of the American Meteorological Society*, **98**(1), 69–78. doi: 10.1175/BAMS-D-14-00283.1
- Kiem A.S., Johnson F., Westra, S., Van Djik A., Evans J.P., O'Donnell A., Rouillard A., Barr C., Tyler J., Thyer M., Jakob D., Woldemeskel F., Sivakumar B. e Mehrotra R. 2016. Natural hazards in Australia: droughts. *Climatic Change*, **139**(1), 37–54. doi: 10.1007/s10584-016-1798-7
- Kogan F.N. 1995. Droughts of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bulletin of the American Meteorological Society*, **76**(5), 655–668. doi: 10.1175/1520-0477(1995)076<0655:DOTLIT>2.0.CO;2
- Kousky V.E. 1979. Frontal Influences on Northeast Brazil. *Monthly Weather Review*, **107**(9), 1140–1153. doi: 10.1175/1520-0493(1979)107<1140:FIONB>2.0.CO;2
- Kubota T., Shige S., Hashizume H., Aonashi K., Takahashi N., Seto S. e Kachi M. 2007. Global precipitation map using satellite-borne microwave radiometers by the GSMap project: Production and validation. *IEEE Transactions on Geoscience and Remote Sensing*, **45**(7), 2259–2275. doi: 10.1109/TGRS.2007.895337
- Kumar R., Musuza J.L., Van Loon A.F., Teuling A.J., Barthel R., Ten Broek J., Mai J., Samaniego L. e Attinger S. 2016. Multiscale evaluation of the Standardized Precipitation

Index as a groundwater drought indicator. *Hydrology and Earth System Sciences*, **20**(3), 1117–1131. doi: 10.5194/hess-20-1117-2016

Kummerow C., Barnes W., Kozu T., Shiue J. e Simpson J. 1998. The tropical rainfall measuring mission (TRMM) sensor package. *Journal of Atmospheric and Oceanic Technology*, **15**(3), 809–817. doi: 10.1175/1520-0426(1998)015<0809:TTRMMT>2.0.CO;2

Kummerow C., Simpson J., Thiele O., Barnes W., Chang A.T.C., Stocker E., Adler R.F., Hou A., Kakar R., Wentz F., Ashcroft P., Kozu T., Hong Y., Okamoto K., Iguchi T., Kuroiwa H., Im E., Haddad Z., Huffman G., Ferrier B., Olson W.S., Zipser E., Smith E.A., Wilheit T.T., North G., Krishnamurti T. e Nakamura K. 2000. The status of the Tropical Rainfall Measuring Mission (TRMM) after two years in orbit. *Journal of Applied Meteorology*, **39**(12), 1965–1982. doi: 10.1175/1520-0450(2001)040<1965:TSOTTR>2.0.CO;2

Lelis L.C.S., Bosquilia R.W.D. e Duarte S.N. 2018. Avaliação dos dados de precipitação gerados pelos satélites GPM e TRMM. *Revista Brasileira de Meteorologia*, **33**(1), 153–163. doi: 10.1590/0102-7786331004

Li F., Li H., Lu W., Zhang G. e Kim J.-C. 2019a. Meteorological drought monitoring in Northeastern China using multiple indices. *Water*, **11**(1), 72–88. doi: 10.3390/w11010072

Li N., Wang Z., Chen X. e Austin G. 2019b. Studies of general precipitation features with TRMM PR data: An extensive overview. *Remote Sensing*, **11**(1), 80–113. doi: 10.3390/rs11010080

Li X., Zhang Q. e Ye X. 2013. Dry/wet conditions monitoring based on TRMM rainfall data and its reliability validation over Poyang Lake basin, China. *Water*, **5**(4), 1848–1864. doi: 10.3390/w5041848

Li X., Zhou W. e Chen Y.D. 2015. Assessment of regional drought trend and risk over China: A drought climate division perspective. *Journal of Climate*, **28**(18), 7025–7037. doi: 10.1175/jcli-d-14-00403.1

Liu X., Zhu X., Pan Y., Li S., Liu Y. e Ma Yuqi. 2016. Agricultural drought monitoring: Progress, challenges, and prospects. *Journal of Geographical Sciences*, **26**(6), 750–767. doi: 10.1007/s11442-016-1297-9

- Lobl E.S., Aonashi K., Murakami M., Griffith B., Kummerow C., Liu G. e Wilheit T. 2007. Wakasa Bay: An AMSR precipitation validation campaign. *Bulletin of the American Meteorological Society*, **88**(4), 551–558. doi: 10.1175/BAMS-88-4-551
- Lyra G.B., Oliveira-Júnior J.F. e Zeri M. 2014. Cluster analysis applied to the spatial and temporal variability of monthly rainfall in Alagoas state, Northeast of Brazil. *International Journal of Climatology*, **34**(13), 3546–3558. doi: 10.1002/joc.3926
- Macedo M.J.H., Guedes R.V.S. e Sousa F.A.S. 2011. Monitoramento e intensidade das secas e chuvas na cidade de Campina Grande/PB. *Revista Brasileira de Climatologia*, **8**, 105–117. doi: 10.5380/abclima.v8i0.25797
- Macedo M.J.H., Guedes R.V.S., Souza F.A.S. e Dantas F.R.C. 2010. Analysis of the standardized precipitation index for the Paraíba state, Brazil. *Ambiente Água*, **5**(1), 204–214. doi: 10.4136/ambi-agua.130
- Mahmoudi P., Rigi A. e Kamak M.M. 2019. A comparative study of precipitation-based drought indices with the aim of selecting the best index for drought monitoring in Iran. *Theoretical and Applied Climatology*, **137**(3-4), 3123–3138. doi: 10.1007/s00704-019-02778-z
- Mann H.B. 1945. Nonparametric Tests Against Trend. *Econometrica*, **13**(3), 245–259. doi: 10.2307/1907187
- Marengo J.A., Alves L.M., Alvala R.C.S., Cunha A.P., Brito S. e Moraes O.L.L. 2018. Climatic characteristics of the 2010-2016 drought in the semiarid Northeast Brazil region. *Anais da Academia Brasileira de Ciências*, **90**(2), 1973–1985. doi: 10.1590/0001-3765201720170206
- Marengo J.A., Torres R.R. e Alves L.M. 2017. Drought in Northeast Brazil—past, present, and future. *Theoretical and Applied Climatology*, **129**(3-4), 1189–1200. doi: 10.1007/s00704-016-1840-8
- McGree S., Schreider S. e Kuleshov Y. 2016. Trends and Variability in Droughts in the Pacific Islands and Northeast Australia. *Journal of Climate*, **29**(23), 8377–8397. doi: 10.1175/JCLI-D-16-0332.1

- McKee T.B., Doesken N.J. e Kleist J. 1993. The Relationship of Drought Frequency and Duration to Time Scales. *Proceedings of the Eighth Conference on Applied Climatology*, American Meteorological Society, pp. 179-184.
- Medeiros S.E.L., Abrahão R., García-Garizábal I., Peixoto I.M.B.M. e Silva L.P. 2018. Assessment of Precipitation Trends in the Sertão Paraibano Mesoregion. *Revista Brasileira de Meteorologia*, **33**(2), 344–352. doi: 10.1590/0102-7786332016
- Melo D.C.D., Xavier A.C., Bianchi T., Oliveira P.T.S., Scanlon B.R., Lucas M.C. e Wendland E. 2015. Performance evaluation of rainfall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil. *Journal of Geophysical Research: Atmospheres*, **120**(18), 9426–9436. doi: 10.1002/2015JD023797
- Merino A., López L., Hermida L., Sánchez J.L., García-Ortega E., Gascón E. e Fernández-González S. 2015. Identification of drought phases in a 110-year record from Western Mediterranean basin: Trends, anomalies and periodicity analysis for Iberian Peninsula. *Global and Planetary Change*, **133**(1), 96–108. doi: 10.1016/j.gloplacha.2015.08.007
- Mhanna M. e Bauwens W. 2012. A stochastic space-time model for the generation of daily rainfall in the Gaza Strip. *International Journal of Climatology*, **32**(7), 1098–1112. doi: 10.1002/joc.2305
- Michot V., Vila D., Arvor D., Corpelli T., Ronchail J., Funatsu B.M. e Dubreuil V. 2018. Performance of TRMM TMPA 3B42 V7 in replicating daily rainfall and regional rainfall regimes in the Amazon basin (1998-2013). *Remote Sensing*, **10**(12), 1879–1898. doi: 10.3390/rs10121879
- Mishra A.K. e Singh V.P. 2010. A review of drought concepts. *Journal of Hydrology*, **391**(1-2), 202–216. doi: 10.1016/j.jhydrol.2010.07.012
- Mitchell J.M., Dzeerdzevskii B., Flohn H., Hofmeyr W.L., Lamb H.H., Rao K.N. e Wallén C.C. 1966. *Climate Change*. Technical Note No. 79, World Meteorological Organization, Geneva.
- Moraes E.C. 2004. Fundamentos de sensoriamento remoto. São José dos Campos: INPE. Disponível em: http://www.dsr.inpe.br/vCSR/files/capitulo_1.pdf. Acesso em: nov. de 2017.

Morid S., Smakhtin V. e Moghaddasi M. 2006. Comparison of seven meteorological indices for drought monitoring in Iran. *International Journal of Climatology*, **26**(7), 971–985. doi: 10.1002/joc.1264

Muhammad W., Yang H., Lei H., Muhammad A. e Yang D. 2018. Improving the regional applicability of satellite precipitation products by ensemble algorithm. *Remote Sensing*, **10**(4), 577. doi: 10.3390/rs10040577

Mukherjee S., Mishra A. e Trenberth K.E. 2018. Climate Change and Drought: A Perspective on Drought Indices. *Current Climate Change Reports*, **4**(2), 145–163. doi: 10.1007/s40641-018-0098-x

Murthy C.S., Singh J., Kumar P. e Sesha Rai M.V.R. 2017. A composite index for drought hazard assessment using CPC rainfall time series data. *International Journal of Environmental Science and Technology*, **14**(9) 1981–1988. doi: 10.1007/s13762-017-1278-2

Naumann G., Barbosa P., Carrao H., Singleton A. e Vogt J. 2012. Monitoring drought conditions and their uncertainties in Africa using TRMM data. *Journal of Applied Meteorology and Climatology*, **51**(10), 1867–1874. doi: 10.1175/jamc-d-12-0113.1

NDMC, National Drought Mitigation Center. 2019. Disponível em: <http://drought.unl.edu>. Acesso em: nov. de 2019.

Ng J.L., Aziz A.S., Huang Y.F., Wayayok A. e Rowshon M. 2018. Generation of a stochastic precipitation model for the tropical climate. *Theoretical and Applied Climatology*, **133**(1-2), 489–509. doi: 10.1007/s00704-017-2202-x

NOAA, National Oceanic and Atmospheric Administration. 2017. Disponível em http://www.noaanews.noaa.gov/stories2010/20100401_tiros.html. Acesso em: nov. de 2017.

Nogueira S.M.C., Moreira M.A. e Volpato M.M.L. 2018. Evaluating precipitation estimates from Eta, TRMM and CHIRPS data in the south-southeast region of Minas Gerais state-Brazil. *Remote Sensing*, **10**(2), 313–328. doi: 10.3390/rs10020313

Oliveira-Júnior J.F., Xavier F.M.G., Teodoro P.E., Gois G., Delgado R.C. 2017. Cluster analysis identified rainfall homogeneous regions in Tocantins State, Brazil. *Bioscience Journal*, **33**(2), 333–340. doi: 10.14393/BJ-v33n2-32739

Palmer W.C. 1965. Meteorological drought. Research Paper no. 45, US Weather Bureau, Washington, DC, USA.

- Palmer W.C. 1968. Keeping track of crop moisture conditions, nationwide: The new crop moisture index. *Weatherwise*, **21**(4), 156–161. doi: 10.1080/00431672.1968.9932814
- Páscoa P., Gouveia C.M., Russo A. e Trigo R.M. 2017. Droughts trends in the Iberian Peninsula over the last 112 years. *Advances in Meteorology*, **2017**, 1–13. doi: 10.1155/2017/4653126
- Ped D.A. 1975. On indicators of droughts and wet conditions. *Proceedings of USSR Hydrometeorology Centre*, **156**, 19–39.
- Pereira G., Silva M.E.S., Moraes E.C. e Cardozo F.S. 2013. Avaliação dos Dados de Precipitação Estimados pelo Satélite TRMM para o Brasil. *Revista Brasileira de Recursos Hídricos*, **18**(3), 139–148. doi: 10.21168/rbrh.v18n3.p139-148
- Rad A.M. e Khalili D. 2015. Appropriateness of clustered raingauge stations for spatio-temporal meteorological drought applications. *Water Resources Management*, **29**(11), 4157–4171. doi: 10.1007/s11269-015-1051-6
- Rahman G., Atta-ur-Rahman, Samiullah e Dawood M. 2018. Spatial and temporal variation of rainfall and drought in Khyber Pakhtunkhwa Province of Pakistan during 1971–2015. *Arabian Journal of Geosciences*, **11**(3), 1–13. doi: 10.1007/s12517-018-3396-7
- Rahmat S.N., Jayasuriya N. e Bhuiyan M. 2015. Assessing droughts using meteorological drought indices in Victoria, Australia. *Hydrology Research*, **46**(3), 463–476. doi: 10.2166/nh.2014.105
- Rao V.B., Franchito S.H., Santo C.M.E. e Gan M.A. 2015. An update on the rainfall characteristics of Brazil: seasonal variations and trends in 1979–2011. *International Journal of Climatology*, **36**(1), 291–302. doi: 10.1002/joc.4345
- Reboita M.S., Gan M.A., Rocha R.P. e Ambrizzi T. 2010. Regimes de precipitação na América do Sul: Uma revisão bibliográfica. *Revista Brasileira de Meteorologia*, **25**(2), 185–204. doi: 10.1590/S0102-77862010000200004
- Ren M., Xu Z., Pang B., Liu W., Liu J., Du L. e Wang R. 2018. Assessment of Satellite-Derived Precipitation Products for the Beijing Region. *Remote Sensing*, **10**(12), 1914. doi: 10.3390/rs10121914
- Roebber P.J. 2009. Visualizing Multiple Measures of Forecast Quality. *Weather Forecasting*, **24**(2), 601–608. doi: 10.1175/2008WAF2222159.1

- Rozante J.R., Vila D.A., Chiquetto J.B., Fernandes A.A. e Alvim D.S. 2018. Evaluation of TRMM/GPM Blended Daily Products over Brazil. *Remote Sensing*, **10**(6), 882–898. doi: 10.3390/rs10060882
- Rousseeuw P.J. 1987. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, **20**, 53–65. doi: 10.1016/0377-0427(87)90125-7
- Sahoo A.K., Sheffield J., Pan M. e Wood E.F. 2015. Evaluation of the Tropical Rainfall Measuring Mission Multi-Satellite Precipitation Analysis (TMPA) for assessment of large-scale meteorological drought. *Remote Sensing of Environment*, **159**, 181–193. doi: 10.1016/j.rse.2014.11.032
- Sanò P., Panegrossi G., Casella D., Di Paola F., Milani L., Mugnai A., Petracca M. e Dietrich S. 2015. The Passive microwave Neural network Precipitation Retrieval (PNPR) algorithm for AMSU/MHS observations: Description and application to European case studies. *Atmospheric Measurement Techniques*, **8**(2), 837–857. doi: 10.5194/amt-8-837-2015
- Santos C.A.G., Brasil Neto R.M., Passos J.S.A. e Silva R.M. 2017. Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil. *Environmental Monitoring and Assessment*, **189**(6), 250–270. doi: 10.1007/s10661-017-5948-9
- Santos C.A.G., Brasil Neto R.M., Silva R.M. e Passos J.S.A. 2018. Integrated spatiotemporal trends using TRMM 3B42 data for the Upper São Francisco River basin, Brazil. *Environmental Monitoring and Assessment*, **190**(3), 175–194. doi: 10.1007/s10661-018-6536-3
- Santos C.A.G., Brasil Neto R.M., Silva R.M. e Costa S.G.F. 2019a. Cluster analysis applied to spatiotemporal variability of monthly precipitation over Paraíba state using Tropical Rainfall Measuring Mission (TRMM) data. *Remote Sensing*, **11**(6), 637. doi: 10.3390/rs11060637
- Santos C.A.G., Brasil Neto R.M., Silva R.M. e Santos D.C. 2019b. Innovative approach for geospatial drought severity classification: a case study of Paraíba state, Brazil. *Stochastic Environmental Research and Risk Assessment*, **33**(2), 545–562. doi: 10.1007/s00477-018-1619-9

- Satgé F., Ruelland D., Bonnet M.-P., Molina J. e Pillco R. 2019. Consistency of satellite-based precipitation products in space and over time compared with gauge observations and snow- hydrological modelling in the Lake Titicaca region. *Hydrology and Earth System Sciences*, **23**(1), 595–619. doi: 10.5194/hess-23-595-2019
- Schneider U., Ziese M., Meyer-Christoffer A., Finger P., Rustemeier E. e Becker A. 2016. The new portfolio of global precipitation data products of the Global Precipitation Climatology Centre suitable to assess and quantify the global water cycle and resources. *Proceedings of the International Association of Hydrological Sciences*, **374**, 29–34. doi: 10.5194/piahs-374-29-2016.
- Sen P.K. 1968. Estimates of the Regression Coefficient Based on Kendall's Tau. *Journal of the American Statistical Association*, **63**(324), 1379–1389. doi: 10.1080/01621459.1968.10480934
- Shiau J.-T. e Lin J.-W. 2016. Clustering Quantile Regression-Based Drought Trends in Taiwan. *Water Resources Management*, **30**(3), 1053–1069. doi: 10.1007/s11269-015-1210-9
- Shukla S. e Wood A.W. 2008. Use of a standardized runoff index for characterizing hydrologic drought. *Geophysical Research Letters*, **35**(2), 1–7. doi: 10.1029/2007GL032487
- Silva B.K.N. e Lucio P.S. 2014. Indicator of Agriculture Vulnerability to Climatic Extremes: A Conceptual Model with Case Study for the Northeast Brazil. *Atmospheric and Climate Sciences*, **4**, 334–345. doi: 10.4236/acs.2014.42034
- Silva B.K.N., Lucio P.S., Silva C.M.S., Spyrides M.H.C., Silva M.T. e Andradre L.M.B. 2017. Characterization agricultural vulnerability to drought in the Northeast of Brazil. *Natural Hazards and Earth System Sciences Discussions*, **2017**, 1–18. doi: 10.5194/nhess-2017-377
- Soares A.S.D., Da Paz A.R e Piccilli D.G.A. 2016. Avaliação das estimativas de chuva do satélite TRMM no Estado da Paraíba. *Revista Brasileira de Recursos Hídricos*, **21**(2), 288–299. doi: 10.21168/rbrh.v21n2.p288-299
- Sorooshian S., Hsu K.L., Gao X., Gupta H.V., Imam B. e Dan B. 2000. Evaluation of PERSIANN system satellite-based estimates of tropical rainfall. *Bulletin of the American Meteorological Society*, **81**(9), 2035–2046. doi: 10.1175/1520-0477(2000)081<2035:EOPSS>2.3.CO;2

- Spencer R.W., Goodman H.M. e Hood R.E. 1989. Precipitation retrieval over land and ocean with the SSM/I: Identification and characteristics of the scattering signal. *Journal of Atmospheric and Oceanic Technology*, **6**(2), 254–273. doi: 10.1175/1520-0426(1989)006<0254:PROLAO>2.0.CO;2
- Spinoni J., Naumann G., Carrao H., Barbosa P. e Vogt, J.V. 2014. World drought frequency, duration, and severity for 1951–2010. *International Journal of Climatology*, **34**(8), 2792–2804. doi: 10.1002/joc.3875
- Tan C., Yang J. e Li M. 2015. Temporal-spatial variation of drought indicated by SPI and SPEI in Ningxia Hui Autonomous Region, China. *Atmosphere*, **6**(10), 1399–1421. doi: 10.3390/atmos6101399
- Tan M.L., Tan K.C., Chua V.P. e Chan N.W. 2017. Evaluation of TRMM product for monitoring drought in the Kelantan River Basin, Malaysia. *Water*, **9**(1), 57–71. doi: 10.3390/w9010057
- Tang G.Q., Li Z., Xue X.W., Hu Q.F., Yong B. e Hong Y. 2015. A Study of substitutability of TRMM remote sensing precipitation for gauge-based observation in Ganjiang River Basin. *Advances in Water Science*, **26**(3), 340–346. doi: 10.14042/j.cnki.32.1309.2015.03.005
- Tao H., Fischer T., Zeng Y. e Fraedrich K. 2016. Evaluation of TRMM 3B43 precipitation data for drought monitoring in Jiangsu Province, China. *Water*, **8**(6), 221–233. doi: 10.3390/w8060221
- Teodoro P.E., Oliveira-Júnior J.F., Cunha E.R., Correa C.C.G., Torres F.E., Bacani V.M., Gois G. e Ribeiro L.P. 2016. Cluster analysis applied to the spatial and temporal variability of monthly rainfall in Mato Grosso do Sul State, Brazil. *Meteorology and Atmospheric Physics*, **128**(2), 197–209. doi: 10.1007/s00703-015-0408-y
- Terink W., Leijnse H., Eertwegh G. e Uijlenhoet R. 2018. Spatial resolutions in areal rainfall estimation and their impact on hydrological simulations of a lowland catchment. *Journal of Hydrology*, **563**, 319–335. doi: 10.1016/j.jhydrol.2018.05.045
- Thom H.C.S. 1958. A note on the gamma distribution. *Monthly Weather Review*, **86**, 117–122. doi: 10.1175/1520-0493(1958)086<0117:ANOTGD>2.0.CO;2

- Thomas T., Jaiswal R.K., Galkate R., Nayak P.C. e Ghosh N.C. 2016. Drought indicators-based integrated assessment of drought vulnerability: a case study of Bundelkhand droughts in central India. *Natural Hazards*, **81**(3), 1627–1652. doi: 10.1007/s11069-016-2149-8
- Timimi Y.K. e Osamah O.A. 2016. Comparative study of four meteorological drought indices in Iraq. *Journal of Applied Physics*, **8**(5), 76–84. doi: 10.9790/4861-0805037684
- Tsakiris G., Pangalou D. e Vangelis H. 2007. Regional drought assessment based on the Reconnaissance Drought Index (RDI). *Water Resources Management*, **21**(5), 821–833. doi: 10.1007/s11269-006-9105-4
- Tucci C.E.M. 2001. Hidrologia: ciência e aplicação. Editora da Universidade Federal do Rio Grande do Sul—ABRH, Porto Alegre, 943 p.
- Unal Y., Kindap T. e Karaca M. 2003. Redefining the climate zones of Turkey using cluster analysis. *International Journal of Climatology*, **23**(9), 1045–1055. doi: 10.1002/joc.910
- Van Dijk A.I.J.M., Beck H.E., Crosbie R.S., Jeu R.A.M., Liu Y.Y., Podger G.M., Timbal B. e Viney N.R. 2013. The millennium drought in Southeast Australia (2001–2009): natural and human causes and implications for water resources, ecosystems, economy and society. *Water Resources Research*, **49**(2), 1040–1057. doi: 10.1002/wrcr.20123
- Van Loon A.F. e Van Lanen H.A.J. 2013. Making the distinction between water scarcity and drought using an observation-modeling framework. *Water Resources Research*, **49**(3), 1483–1502. doi: 10.1002/wrcr.20147
- Varikoden H., Preethi B. e Revadekar J.V. 2012. Diurnal and spatial variation of Indian summer monsoon rainfall using tropical rainfall measuring mission rain rate. *Journal of Hydrology*, **475**, 248–258. doi: 10.1016/j.jhydrol.2012.09.056
- Vicente-Serrano S.M., Beguería S. e López-Moreno J.I. 2010. A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, **23**(7), 1696–1718. doi: 10.1175/2009jcli2909.1
- Wable P.S., Jha M.K. e Shekhar A. 2018. Comparison of Drought Indices in a Semi-Arid River Basin of India. *Water Resources Management*, **33**(1), 75–102. doi: 10.1007/s11269-018-2089-z

- Wagner P.D., Fiener P., Wilken F., Kumar S. e Schneider K. 2012. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. *Journal of Hydrology*, **464–465**, 388–400. doi: 10.1016/j.jhydrol.2012.07.026
- Wang X., Shen H., Zhang W., Cao J., Qi Y., Chen G. e Li X. 2015. Spatial and temporal characteristics of droughts in the Northeast China Transect. *Natural Hazards*, **76**(1), 601–614. doi: 10.1007/s11069-014-1507-7
- Wei G., Lu H., Crow W.T., Zhu Y., Wang J. e Su J. 2018. Comprehensive Evaluation of GPM-IMERG, CMORPH, and TMPA Precipitation Products with Gauged Rainfall over Mainland China. *Advances in Meteorology*, **2018**, 1–18. doi:10.1155/2018/3024190
- Wilhite D.A. e Glantz M.H. 1985. Understanding the Drought Phenomenon: The Role of Definitions. *Water International*, **10**(3), 111–120. doi: 10.1080/02508068508686328
- WMO, World Meteorological Organization, 1994. Guide to Hydrological Practices: Data Acquisition and Processing, Analysis, Forecasting and Other Applications.
- WMO, World Meteorological Organization, 2012. Standardized precipitation index user guide (M Svoboda, M Hayes and D Wood).
- Xia L., Zhao F., Mao K., Yuan Z., Zuo Z. e Xu T. 2018. SPI-based analyses of drought changes over the past 60 years in China's major crop-growing areas. *Remote Sensing*, **10**(2), 171 –185. doi: 10.3390/rs10020171
- Xie P., Janowiak J.E., Arkin P.A., Adler R., Gruber A., Ferraro R., Huffman G.J. e Curtis S. 2003. GPCP pentad precipitation analyses: An experimental dataset based on gauge observations and satellite estimates. *Journal of Climate*, **16**(13), 2197–2214. doi:10.1175/2769.1
- Xu F., Guo B., Ye B., Ye Q., Chen H., Ju X., Guo J. e Wang Z. 2019. Systematical Evaluation of GPM IMERG and TRMM 3B42V7 Precipitation Products in the Huang-Huai-Hai Plain, China. *Remote Sensing*, **11**(6), 697. doi: 10.3390/rs11060697
- Yang P., Xia J., Zhang Y., Han J. e Wu X. 2017. Quantile regression and clustering analysis of standardized precipitation index in the Tarim River Basin, Xinjiang, China. *Theoretical and Applied Climatology*, **134**(3-4), 1–12. doi: 10.1007/s00704-017-2313-4
- Yevjevich V. 1967. An Objective Approach to Definitions and Investigation of Continental Hydrologic Droughts. Hydrology Paper 23. Colorado State U, Fort Collins.

- Zarei A.R. e Eslamian S. 2017. Trend assessment of precipitation and drought index (SPI) using parametric and non-parametric trend analysis methods (case study: Arid regions of southern Iran). *International Journal of Hydrology Science and Technology*, **7**(1), 12–38. doi: 10.1504/ijhst.2017.080957
- Zhang A. e Jia G. 2013. Monitoring meteorological drought in semiarid regions using multi-sensor microwave remote sensing data. *Remote Sensing of Environment*, **134**, 12–23. doi: 10.1016/j.rse.2013.02.023
- Zhao Q., Chen Q., Jiao M., Wu P., Gao X., Ma M. e Hong Y. 2018. The temporal-spatial characteristics of drought in the Loess Plateau using the remote-sensed TRMM precipitation data from 1998 to 2014. *Remote Sensing*, **10**(6), 838. doi: 10.3390/rs10060838
- Zhong R., Chen X., Lai C., Wang Z., Lian Y., Yu H. e Wu X. 2019. Drought monitoring utility of satellite-based precipitation products across mainland China. *Journal of Hydrology*, **568**, 343–359. doi: 10.1016/j.jhydrol.2018.10.072