



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE  
CENTRO DE CIÊNCIAS EXATAS E DA TERRA  
Programa de Pós-Graduação em Ciências Climáticas

PPGCC

TESE DE DOUTORADO

**ANÁLISE DE EVENTOS EXTREMOS DE PRECIPITAÇÃO NO NORDESTE  
DO BRASIL**

Daniele Tôrres Rodrigues

Natal/RN, outubro de 2019.

ANÁLISE DE EVENTOS EXTREMOS DE PRECIPITAÇÃO NO NORDESTE DO  
BRASIL

Daniele Tôres Rodrigues

Tese de doutorado apresentada ao Programa de Pós-Graduação em Ciências Climáticas, do Centro de Ciências Exatas e da Terra da Universidade Federal do Rio Grande do Norte, como parte das exigências para obtenção do título de Doutor em Ciências Climáticas.

COMISSÃO EXAMINADORA

<b>Orientador:</b> Dr. Weber Andrade Gonçalves	(UFRN)
<b>Coorientadora:</b> Dra. Maria Helena Constantino Spyrides	(UFRN)
Dr. Cláudio Moises Santos E Silva	(UFRN)
Dr. Paulo Sergio Lucio	(UFRN)
Dra. Clênia Rodrigues Alcântara	(UFCEG)
Dr. Renato Galante Negri	(INPE)

Natal/RN, outubro de 2019.

Rodrigues, Daniele Torres.

Análise de eventos extremos de precipitação no Nordeste do Brasil / Daniele Torres Rodrigues. - 2019.  
123f.: il.

Tese (doutorado) - Universidade Federal do Rio Grande do Norte, Centro de Ciências Exatas e da Terra, Programa de Pós-Graduação em Ciências Climáticas. Natal, 2019.

Orientador: Weber Andrade Gonçalves.

Coorientadora: Maria Helena Constantino Spyrides.

1. Climatologia - Tese. 2. TRMM - Tese. 3. Período de retorno - Tese. 4. Microfísica da nuvem - Tese. I. Gonçalves, Weber Andrade. II. Spyrides, Maria Helena Constantino. III. Título.

RN/UF/CCET

CDU 551.58

## ANÁLISE DE EVENTOS EXTREMOS DE PRECIPITAÇÃO NO NORDESTE DO BRASIL

### RESUMO

Eventos climáticos extremos estão se tornando cada vez mais frequentes no Brasil, provocando inundações, estiagem, incêndios florestais, desabamentos, ondas de frio ou de calor, entre outras. Estes eventos têm grandes implicações na sociedade, em especial na saúde, agricultura e recursos hídricos. Diante deste cenário, ter o conhecimento do comportamento e da frequência com que valores extremos ocorrem é de grande importância para sociedade. No entanto, um grande fator de dificuldade para realização destas análises está na qualidade das séries de dados utilizadas, principalmente as que estão na escala diária. Portanto, os objetivos deste estudo são avaliar a qualidade dos métodos de imputação múltipla para o preenchimento de dados faltantes de precipitação diária, investigar a capacidade do produto 3B42 da *Multisatellite Precipitation Analysis* (TMPA) do *Tropical Rainfall Measuring Mission* (TRMM) em estimar a ocorrência e intensidade dos eventos de precipitação diária e extrema, estimar o nível de retorno dos eventos extremos de precipitação diária e classificar os parâmetros microfísicos das nuvens geradoras de precipitação extrema para o Nordeste do Brasil. Esta região apresenta alta variabilidade espacial e temporal da precipitação e é vulnerável a extremos de precipitação diária. Para isso, fez o uso de dados diários de precipitação provindos de pluviômetros, durante o período de 01/01/1986 à 31/12/2015 e dos produtos 3B42, 2ACLIM e 2A12 do satélite TRMM, durante o período de desde 01/01/2000 à 31/12/2015. A análise dos dados se deu por meio de medidas e métodos estatísticos como: média, desvio-padrão, viés, erro quadrático médio, correlação, imputação múltipla, teste *t-student*, análise de sensibilidade, análise de *cluster*, teoria de valores extremos, análise de variância, teste F, teste de Tukey, entre outros. Os principais resultados indicaram que a imputação múltipla de dados por meio do método *Bootstrap EM algorithm* pode ser uma ferramenta que venha a corroborar com a reconstrução de séries históricas de dados de precipitação diária. De forma geral, os dados do produto 3B42 do satélite TRMM apresentaram um bom desempenho ao estimar os valores de precipitação para o NEB. Sua qualidade varia de acordo com a localização e a escala temporal em que ocorre a precipitação. As estimativas do nível de retorno apontaram que a intensidade da precipitação extrema diária esperada depende do período sazonal e do local de ocorrência da mesma. O leste do Nordeste do Brasil destacou-se como a região onde são esperadas as maiores intensidades de precipitação extrema. Foram caracterizados parâmetros, como quantidade de água líquida e gelo integrado, altura do topo de congelamento e tipo de chuva, das nuvens geradoras de precipitação extrema em relação a diferentes regiões do NEB.

**Palavras-chaves:** TRMM, período de retorno, microfísica da nuvem.

# ANÁLISE DE EVENTOS EXTREMOS DE PRECIPITAÇÃO NO NORDESTE DO BRASIL

## ABSTRACT

Extreme weather events are becoming increasingly frequent in Brazil, causing floods, drought, forest fires, landslides, river flows, cold or hot flashes, among others. These events have major implications for society, especially health, agriculture and water resources. Given this scenario, having knowledge of the behavior and frequency with which extreme values occur is of great importance to society. However, a major difficulty factor in performing these analyzes is the quality of the data series used, especially those on the daily scale. Therefore, the objectives of this study are to evaluate the quality of multiple imputation methods for filling in missing daily rainfall data, to investigate the ability of Tropical Rainfall Measuring Mission (TRMM) Multisatellite Precipitation Analysis (TMPA) 3B42 product to estimate occurrence and intensity of daily and extreme precipitation events, to estimate the return level of extreme daily precipitation events and to classify the microphysical parameters of the extreme precipitation generating clouds for Northeast of Brazil (NEB). This region has high spatial and temporal variability of precipitation and is vulnerable to extremes of daily precipitation. For this purpose, it made use of daily rainfall data from rainfall during the period from 01/01/1986 to 12/31/2015 and from products 3B42, 2ACLIM and 2A12 from the TRMM satellite during the period from 01/01/2000 to 12/31/2015. Data analysis was performed by means of statistical measures and methods such as mean standard deviation, bias, mean square error, correlation, multiple imputation, t-student test, sensitivity analysis, cluster analysis, extreme value theory, analysis of variance, F test, Tukey test, among others. The main results indicated that multiple data imputation using the Bootstrap EM algorithm method could be a tool that corroborates the reconstruction of historical series of daily precipitation data. Overall, TRMM 3B42 product data performed well when estimating precipitation values for NEB. Its quality varies according to the location and time scale at which precipitation occurs. Estimates of the return level indicate that the expected daily extreme rainfall intensity depends on the seasonal period and where it occurs. The East of the NEB stands out as the region where the highest intensities of extreme precipitation are expected. Parameters such as amount of liquid water and integrated ice, height of the freezing top and type of rain were characterized, generating extreme precipitation clouds in relation to different NEB regions.

**Keywords:** TRMM, return period, cloud microphysics.

## SUMÁRIO

LISTA DE FIGURAS	7
LISTA DE TABELAS	9
LISTA DE SÍMBOLOS E SIGLAS	10
CAPÍTULO 1 - INTRODUÇÃO	12
1.1. Objetivos	15
1.2. Estrutura da Tese	16
CAPÍTULO 2 - AVALIAÇÃO DE MÉTODOS DE IMPUTAÇÃO MÚLTIPLA PARA DADOS CLIMÁTICOS	17
2.1. Introdução	19
2.2. Material e Método	21
2.2.1. Banco de dados	21
2.2.2. Imputação Múltipla	21
2.2.3. Procedimentos para comparação dos métodos de MI	25
2.3. Resultados	27
2.4. Conclusão	29
CAPÍTULO 3 - SPATIAL AND TEMPORAL ASSESSMENT OF THE EXTREME AND DAILY PRECIPITATION OF THE TROPICAL RAINFALL MEASURING MISSION SATELLITE IN NORTHEAST BRAZIL	30
3.1. Introduction	32
3.2. Material and Methods	36
3.2.1. Study area	36
3.2.2. Data	36
3.2.2.1. Weather Stations	36
3.2.2.2. 3B42 V7 Product of the TRMM satellite	36
3.2.3. Methods	37
3.2.3.1. Daily Precipitation Analysis	38
3.2.3.2. Sub-regions of NEB	40
3.2.3.3. Extreme Precipitation Analysis	41
3.3. Results and Discussion	42
3.3.1. Daily Precipitation	42
3.3.2. Extreme Precipitation	52

3.4. Conclusions	55
CAPÍTULO 4 - SPATIAL DISTRIBUTION OF THE LEVEL OF RETURN OF EXTREME PRECIPITATION EVENTS IN NORTHEAST BRAZIL	58
4.1. Introduction	60
4.2. Material and Methods	63
4.2.1. Study area	63
4.2.2. Database	64
4.2.3. Methods	65
4.3. Results and discussion	66
4.3.1. Assessment of TRMM for extremes	67
4.3.2. Spatial distribution of extremes	69
4.3.3. Association with natural disasters	73
4.4. Conclusion	75
CAPÍTULO 5 - MICROFÍSICA DAS NUVENS GERADORAS DE PRECIPITAÇÃO EXTREMA NO NORDESTE DO BRASIL	77
5.1. Introdução	79
5.2. Material e Métodos	81
5.2.1. Área de estudo	81
5.2.2. TRMM <i>database</i>	83
5.2.3. Métodos estatísticos	84
5.3. Resultados	85
5.4. Conclusão	94
CAPÍTULO 6 - CONSIDERAÇÕES FINAIS	96
REFERÊNCIAS	99

## LISTA DE FIGURAS

Figura 2.1 - Localização do Nordeste Brasileiro e estações meteorológicas, cada círculo preenchido representa uma estação meteorológica.	21
Figura 2.2 - Conjunto de dados com $m$ imputações para cada valor não disponível (NA – do inglês: <i>Not Available</i> ).	23
Figura 2.3 - Ilustração resumida dos passos para gerar os bancos de dados imputados.	26
Figura 2.4 - Gráfico de dispersão com o coeficiente de correlação de Pearson para os quatro métodos de imputação múltipla, por cenário.	28
Figura 2.5 - Mapa do Nordeste do Brasil com o coeficiente de correlação de Pearson para o método BootEM para os três cenários, (a) 10% de dados faltantes; (b) 20% de dados faltantes e (c) 30% de dados faltantes.	29
Figure 3.1. (a) Limits of South America (b) Limits of NEB, location of weather stations and grid points of the TRMM satellite.	37
Figure 3.2. Spatial distribution of bias by seasonal period, (a) DJF, (b) MAM, (c) JJA and (d) SON.	43
Figure 3.3. Spatial distribution of RMSE by seasonal period, (a) DJF, (b) MAM, (c) JJA and (d) SON.	44
Figure 3.4. Spatial distribution of correlation coefficient ( $r$ ) by seasonal period, (a) DJF, (b) MAM, (c) JJA and (d) SON.	45
Figure 3.5. Spatial distribution of $p$ -value, resulting from paired $t$ -test by seasonal period, (a) DJF, (b) MAM, (c) JJA and (d) SON.	46
Figure 3.6. Spatial distribution of sensitivity by seasonal period, (a) DJF, (b) MAM, (c) JJA and (d) SON.	47
Figure 3.7. ROC curves for NEB capitals.	48
Figure 3.8. Representation of regionalization in NEB according to daily precipitation.	49
Figure 3.9. (a) Precipitation dispersion (mm) per month in each Region. (b) Boxplot of annual precipitation (mm) in each Region. The filled circle represents the average annual precipitation, the triangle and the square represent the 90th and 10th percentile values, respectively.	50
Figure 3.10. Sensitivity of the extreme values of precipitation for each sub-region in different periods: daily, every two, three, four, five, six days, weekly, every two and three weeks and monthly.	53
Figure 3.11. Density of extreme values of daily precipitation by region of NEB, (a) R <sub>1</sub> , (b) R <sub>2</sub> , (c) R <sub>3</sub> , (d) R <sub>4</sub> , and (e) R <sub>5</sub> and density of extreme values of precipitation every two days by region of NEB, (f) R <sub>1</sub> , (g) R <sub>2</sub> , (h) R <sub>3</sub> , (i) R <sub>4</sub> , and (j) R <sub>5</sub> .	54
Figure 4.1. Geographic location of Northeast Brazil.	63
Figure 4.2. Return level per return period of daily extreme precipitation (mm) over NEB, per seasonal period. (a) DJF, (b) MAM, (c) JJA, (d) SON.	67



Figure 4.3. Return level (mm) of daily extreme precipitation by grid points and seasonal period, (a) DJF, (b) MAM, (c) JJA, (d) SON, for a return period of 2 years. The model was not applied to the data of the area represented in gray, since it contains a number of days with extreme precipitation shorter than five days. 70

Figure 4.4. Return level (mm) of the daily extreme precipitation by grid point and seasonal period, (a) DJF, (b) MAM, (c) JJA, (d) SON, for a return period of 5 years. The model was not applied to the data of the area represented in gray, since it contains a number of days with extreme precipitation shorter than five days. 71

Figure 4.5. Return level (mm) of daily extreme precipitation by grid points and seasonal period, (a) DJF, (b) MAM, (c) JJA, (d) SON, for a 10 year return period. The model was not applied to the data of the area represented in gray, since it contains a number of days with extreme precipitation shorter than five days. 72

Figure 4.6. Frequency of occurrences of disasters (pluvial floods, landslides, flash floods, and fluvial floods) by NEB municipality during the period from January 2016 to February 2019. 74

Figura 5.1 Área de estudo e limites das sub-regiões (Região 1 (R1), Região 2 (R2), Região 3 (R3), Região 4 (R4) e Região 5 (R5) do NEB definidas por Rodrigues et al., (2019). 82

Figura 5.2. Intervalo de Confiança da taxa de precipitação em superfície da nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB. 86

Figura 5.3. Intervalo de Confiança do conteúdo integrado de gelo na nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB. 88

Figura 5.4. Intervalo de Confiança do conteúdo integrado de água líquida na nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB. 89

Figura 5.5. Intervalo de Confiança da altura do nível de congelamento da nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB. 91

Figura 5.6: Modelo empírico dos parâmetros das nuvens geradoras de precipitação extrema por sub-regiões do NEB. 93

## LISTA DE TABELAS

Tabela 2.1 - Medidas de Viés*, SD* e EQM*, para os quatro métodos de imputação por cenário. *Média obtida a partir das medidas feitas para as 94 estações meteorológicas.	27
Table 3.1. Possible results of a diagnostic test.	39
Table 3.2. Daily mean and standard deviation of extreme precipitation by seasonal period and NEB sub-region.	51
Table 3.3. Values of bias, RMSE and correlation coefficient (r) between satellite estimates and observed rain gauge measurements for daily and 2 days accumulated data on extreme precipitation, broken down by NEB sub-regions.	55
Table 4.1. Statistics D and p-value by the Kolmogorov-Smirnov test by seasonal period and data source, pluviometers and 3B42 TRMM.	69
Tabela 5.1. Parâmetros microfísicos das nuvens associados aos produtos 2ACLIM e 2A25.	84
Tabela 5.2: Resultados do teste de Tukey. Diferença entre pares de médias e seus respectivos limites de IC de 95% para as sub-regiões do NEB por parâmetros microfísicos da nuvem geradora de precipitação extrema. Os valores significativos (Valor-p < 0,05) estão representados por um asterisco.	87
Tabela 5.3: Resultados do teste de Dunn. Estatística do teste e seus respectivos valores-p para as sub-regiões do NEB. Os valores significativos (Valor-p < 0,05) estão representados por um asterisco.	90

## LISTA DE SÍMBOLOS E SIGLAS

BDMEP	Banco de Dados Meteorológicos para Ensino e Pesquisa
BootEm	Bootstrap EM algorithm
CCM	Complexos Convectivos de Mesoescala
DOL	Distúrbios Ondulatórios de Leste
EM	Expectation Maximization
EMV	Estimadores de Máxima Verossimilhança
ENSO	El Niño Southern Oscillation
EQM	Erro Quadrático Médio
GDP	Generalized Pareto Distribution
GEV	Generalized Extreme Values
i.d.	identicamente distribuídas
i.i.d.	independente e identicamente distribuídas
INMET	Instituto Nacional de Meteorologia
IPCC	Intergovernmental Panel on Climate Change
JAXA	Japan Aerospace Exploration
LI	Linhas de instabilidade
MCMC	Monte Carlo via cadeias de Markov
MI	Multiple Imputation
MRL	Mean Residual Life Plot
NA	Not Available
NAO	North Atlantic Oscillation
NASA	National Aeronautics and Space Administration
NEB	Nordeste do Brasil
Norm	Bayesian linear regression
PDO	Pacific Decadal Oscillation Index
PMM	Predictive Mean Matching
PP <i>plot</i>	gráficos de probabilidade
PR	Precipitation Radar
QQ <i>plot</i>	gráficos de quantis
Sample	Random sample from the observed values
SCM	Sistemas Convectivos de Mesoescala
SD	Standard Deviation

SF	Sistemas Frontais
SREX	Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation
TMI	Microwave Imager
TMPA	Multisatellite Precipitation Analysis
TRMM	Tropical Rainfall Measuring Mission
TSM	Temperatura da Superfície do Mar
TVE	Teoria dos Valores Extremos
v.a.s.	variáveis aleatórias
VCAN	Vórtices Ciclônicos de Altos Níveis
VIRS	Visible and Infrared Radiometer System
ZCAS	Zona de Convergência do Atlântico Sul
ZCIT	Zona de Convergência Intertropical

## CAPÍTULO 1

### INTRODUÇÃO

O Nordeste do Brasil (NEB) está localizado na região tropical entre 1° N e 18° S e 34,5° W e 48,5° W, no extremo nordeste da América do Sul, e engloba os Estados do Maranhão, Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe e Bahia, totalizando uma área de aproximadamente 1.558.196 km<sup>2</sup> e com 53.081.950 habitantes (IBGE, 2010). O NEB é banhado ao norte e a leste pelo Oceano Atlântico. Apesar de sua localização o NEB não apresenta uma distribuição de chuvas típica das áreas tropicais (Moura e Shukla, 1981). A região abrange especialmente três tipos de climas, são eles: clima litorâneo úmido (do litoral da Bahia ao do Rio Grande do Norte), clima tropical (em áreas dos estados da Bahia, Ceará, Maranhão e Piauí); e clima tropical semiárido (em todo o sertão nordestino) (Cavalcanti et al., 2009).

A variabilidade do clima no NEB é determinada especialmente por diversos mecanismos físicos que interagem e são responsáveis pela distribuição da precipitação na região. A posição geográfica, relevo, características da superfície, e sistemas meteorológicos que atuam na região, estão entre os principais fatores que determinam a variação sazonal da distribuição dos dados climáticos no NEB. (Cavalcanti et al., 2009; Fernandez et al. 2017; Oliveira et al. 2017).

A precipitação no NEB é influenciada, principalmente, pelos episódios de El Niño Oscilação Sul (ENOS), com períodos secos em condições de El Niño e períodos úmidos com La Niña (Ropelewski e Halpert, 1987; Marengo et al., 2017), Temperatura da Superfície do Mar (TSM) sobre o oceano Atlântico (Uvo, 1998; Bombardi et al., 2014; Rodrigues et al., 2015) e pelos sistemas meteorológicos, como Zona de Convergência Intertropical (ZCIT) (Hastenrath e Heller, 1977; Uvo, 1989; Reboita et al. 2012; Utida et al., 2019), Vórtices Ciclônicos de Altos Níveis (VCAN) (Kousky e Gan, 1981; Reboita et al., 2012; Fedorova et al., 2016), Linhas de instabilidade (LI) (Kousky, 1980; Oliveira e Oyama, 2019), Zona de Convergência do Atlântico Sul (ZCAS) (Kodama, 1992; Zilli et al., 2019), Sistemas Frontais (SF) (Kousky, 1979; Oliveira et al., 2016; Palharini e Vila, 2017), Sistemas Convectivos de Mesoescala (SCM) (Kousky, 1980; Silva Dias, 1987; Palharini e Vila, 2017) e Distúrbios Ondulatórios de Leste (DOL) (Yamazaki e Rao, 1977; Torres e Ferreira, 2011; Gomes et al., 2015; Gomes et al., 2019).

De acordo com o relatório do *Intergovernmental Panel on Climate Change* (IPCC, AR4), a precipitação no NEB apresenta alta variabilidade espacial e temporal, o que influencia na ocorrência de eventos extremos, tornando-o altamente susceptível a mudanças climáticas. Nos últimos anos, estudos científicos, como os realizados por Marengo et al. (2009), Dos Santos et al. (2012), Oliveira et al. (2013), Costa et al. (2015), Oliveira et al. (2017) e Da Silva et al. (2019) têm observado tendências positivas nos extremos de precipitação sobre o NEB.

Os eventos extremos sobre o NEB são caracterizados por grandes secas ou precipitações intensas. Precipitações intensas podem causar tanto benefícios quanto malefícios, isto irá depender, principalmente, de sua magnitude, duração e localização. Elas contribuem para o abastecimento de açudes, reservatórios de hidrelétricas e podem ser benéficas para algumas culturas de sequeiro. Porém, podem provocar grandes prejuízos, como alagamentos, deslizamentos de terra, enxurradas e inundações, especialmente nas regiões costeiras do NEB (Oliveira et al. 2013). Esses eventos têm grandes implicações na sociedade (Marengo and Espinoza, 2016; Demirdjian et al., 2018), em especial na saúde e agricultura, podendo causar prejuízos econômicos, baixa qualidade de vida e até mortes. Como exemplo, pode-se citar as fortes chuvas, que ocorreram no semiárido do NEB em 2004, em que várias comunidades ficaram isoladas, casas, barragens e açudes foram destruídos, causando mortes e perda na produção (Marengo, 2007).

Pesquisas que envolvem a precipitação são essenciais para estudos hidrometeorológicos (Katiraie-Boroujerdy et. al., 2013; Cai et. al., 2016; Yang et al., 2017), sobretudo, aqueles que envolvem os valores extremos de precipitação. Ter o conhecimento da frequência com que esses eventos ocorrem, identificar seus padrões de variabilidade temporais e espaciais são de fundamental importância para planejar seus impactos, positivos e negativos, causados em diversos segmentos da sociedade. Para isso, é de extrema importância ter acesso a dados confiáveis e com alta resolução espacial e temporal (Marengo, 2007).

Os pluviômetros, radares e satélites estão entre as formas capazes de medir a precipitação (Tapiador et al. 2010). Os pluviômetros medem os quantitativos da chuva de forma direta e pontual. Porém, o banco de dados proveniente deste instrumento, geralmente, contém dados faltantes, isto ocorre devido a muitos fatores, tais como, interrupções ocasionais das estações meteorológicas, mau funcionamento dos instrumentos de medição, erros na digitação, entre outras. Os radares estimam a

precipitação, com alta cobertura espacial, contudo, no Brasil não são distribuídos em todo o território nacional. As estimativas de precipitação por satélite têm sido amplamente utilizadas em estudos meteorológicos e climáticos (Melo et al., 2015; Maggioni et al., 2016; Darand et al., 2017; Hermance e Sulieman, 2018) em diversas regiões do globo.

Dentre os satélites existentes, o *Tropical Rainfall Measuring Mission* (TRMM) se destaca na estimação da precipitação (TRMM, 2015). O TRMM é uma missão conjunta entre a *National Aeronautics and Space Administration* (NASA) e o *Japan Aerospace Exploration* (JAXA) para estudar a distribuição e variabilidade da precipitação nos trópicos, o mesmo cobre as regiões tropicais e semitropicais da Terra, 35° ao Norte e 35° ao Sul do Equador, possui órbita equatorial com inclinação de 35° em relação ao Equador e altitude de 403 km (a partir de setembro de 2001) com um período de 92,5 minutos gira ao redor da Terra, aproximadamente 16 vezes por dia. O satélite TRMM foi lançado em novembro de 1997 e seus sensores foram desligados em abril de 2015. Seu sucessor Global Precipitation Measurement (GPM) foi lançado em fevereiro de 2014.

O TRMM apresentava a bordo os sensores de Microwave Imager (MI), Precipitation Radar (PR) e Visible and Infrared Radiometer System (VIRS) capazes de fornecer informações valiosas sobre a precipitação, como por exemplo informações sobre a intensidade da precipitação, perfil vertical da distribuição da chuva, quantidade de partículas de água e gelo integrados na nuvem, entre outras (Kummerow et al., 1998; Huffman et al., 2007; Liu et al. 2008; Banze, 2016). Além destes, o TRMM possuía o Lighting Imaging Sensor (LIS) e o Clouds and earths Radiant energy System, capazes de detectar relâmpagos e estimar a energia da atmosfera, respectivamente (Huffman et al., 2007).

Diante do exposto, esta pesquisa foi realizada com a finalidade de responder quatro principais questionamentos: i) Métodos estatísticos de imputação múltipla são capazes de preencher dados faltantes de precipitação diária no NEB? ii) O satélite TRMM é capaz de estimar a intensidade da precipitação diária em diferentes regiões do NEB? iii) Qual o nível de retorno dos eventos extremos de precipitação diária no NEB? iv) Quais são as características microfísicas das nuvens geradoras de precipitação extrema em diferentes regiões do NEB?

As respostas destas questões estão associadas a diversos fatores, dentre eles estão fatores como vegetação, relevo, climatologia, e distribuição da precipitação na região do NEB e até mesmo aos métodos utilizados para estimar os dados utilizados neste estudo. É esperado que a qualidade da estimativa feita por meio do método de imputação múltipla

dependa do número de dados faltantes e da localização a qual a série de dados representa. Devido à variabilidade temporal e espacial do NEB é esperado que a capacidade das estimativas do satélite TRMM dependam do período sazonal e da localização em que a precipitação diária ocorre. Uma vez que pesquisas científicas sugerem o aumento de eventos extremos de precipitação, é esperado que estes eventos apresentem uma intensidade elevada em um curto período de retorno. É esperado que as características microfísicas das nuvens geradoras de precipitação extrema dependam da região em que elas estão localizadas.

### 1.1. Objetivos

O objetivo geral é analisar os eventos extremos de precipitação diária sobre o NEB, quanto ao nível de retorno e características microfísicas de suas nuvens.

Os objetivos específicos são:

- ✓ Investigar se os métodos estatísticos de imputação múltipla são capazes de preencher dados faltantes em séries históricas de precipitação diária no NEB.
- ✓ Verificar se o satélite *Tropical Rainfall Measuring Mission* (TRMM) é capaz de estimar a intensidade da precipitação diária em diferentes regiões do NEB.
- ✓ Estimar o nível de retorno dos eventos extremos de precipitação diária no NEB
- ✓ Analisar as características microfísicas das nuvens geradoras de precipitação extrema em diferentes regiões do NEB.

### 1.2. Estrutura da Tese

A presente tese está estruturada da seguinte forma: o Capítulo 2 apresenta uma avaliação dos métodos de imputação múltipla para o preenchimento de dados faltantes de precipitação diária no NEB. O Capítulo 3 investiga a qualidade das estimativas de precipitação diárias e extremas do satélite TRMM sobre o NEB. O Capítulo 4 exhibe estimações dos níveis de retorno de precipitação extrema para o NEB. No Capítulo 5 é apresentado as características microfísicas das nuvens geradoras de precipitação extrema sobre o NEB. Por fim, no Capítulo 6 são apresentadas as considerações finais da tese e sugestões para trabalhos futuros. Na sequência são apresentados os artigos que deram origem aos capítulos:



Capítulo 2 – Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H., Lucio, P.S. Avaliação de métodos de imputação múltipla para dados de precipitação. Artigo em fase final para submissão.

Capítulo 3 - Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H.C., e Silva, C.M.S. (2019) Spatial and temporal assessment of the extreme and daily precipitation of the Tropical Rainfall Measuring Mission satellite in Northeast Brazil. **International Journal of Remote Sensing**, 1-24, doi: 10.1080/01431161.2019.1643940.

Qualis CAPES: B1 - Geociências. Fator de impacto: 2.493.

Capítulo 4 - Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H.C., e Silva, C.M.S, de Souza, D.O. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. **International Journal of Climatology** (em revisão).

Qualis CAPES: A1 - Geociências. Fator de impacto: 3.601.

Capítulo 5 - Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H.C. Microfísica das nuvens geradoras de precipitação extrema no Nordeste do Brasil. Artigo em fase final para submissão.

## CAPÍTULO 2

### AVALIAÇÃO DE MÉTODOS DE IMPUTAÇÃO MÚLTIPLA PARA DADOS DE PRECIPITAÇÃO

#### RESUMO

O objetivo deste estudo é avaliar a capacidade de quatro métodos estatísticos de imputação múltipla para o preenchimento de dados faltantes de precipitação diária no NEB. Para isso, se fez uso de um banco de dados que contém informações sobre a precipitação diária dispostas em 94 pluviômetros distribuídos sobre o NEB durante um período de 30 anos, desde janeiro de 1986 a dezembro de 2015. As medidas estatísticas como viés, desvio padrão, erro quadrático médio e coeficiente de correlação de Pearson foram utilizadas para avaliar cada método de imputação, *Sample*, *Predictive Mean Matching* (PMM), Norm e *Bootstrap Expectation Maximization* (BootEM). Os resultados indicaram que quanto menor o número de dados faltantes melhor a qualidade dos métodos de imputação. O método BootEM apresentou os melhores resultados estatísticos em comparação aos resultados dos outros métodos analisados. Conclui-se que este pode ser uma boa ferramenta para a reconstrução de dados históricos de precipitação no NEB.

Palavras-chave: preenchimento de dados, *Bootstrap*, dados faltantes.

## ABSTRACT

The aim of this study is to evaluate the ability of four statistical multiple imputation methods to fill in daily rainfall missing data in NEB. For this, a database containing information on daily rainfall arranged in 94 rainfall gauges distributed over the NEB over a period of 30 years, from January 1986 to December 2015 was used. Statistical measures such as bias, standard deviation, mean square error and Pearson correlation coefficient were used to evaluate each imputation method, Sample, Predictive Mean Matching (PMM), Norm, and Bootstrap Expectation Maximization (BootEM). The results indicated that the smaller the number of missing data the better the quality of the imputation methods. The BootEM method presented the best statistical results compared to the results of the other methods analyzed. It is concluded that this can be a good tool for reconstructing historical NEB precipitation data.

Keywords: filling data, Bootstrap, missing data.

## 2.1. Introdução

Uma lacuna comum em banco de dados de diversos estudos científicos é a ocorrência de dados faltantes ou dados perdidos (*missing data*). Na área de ciências climáticas não é diferente. É comum encontrar séries temporais climatológicas providas de instrumentos com dados omissos devido a várias razões, como por exemplo, interrupções ocasionais de estações automáticas, mau funcionamento dos instrumentos de medição, reorganização das redes de estações, erros na digitação, entre outras.

Muitos estudos são realizados a partir de séries de dados, como por exemplo, as pesquisas relacionadas às mudanças climáticas do *Intergovernmental Panel on Climate Change* (IPCC). No entanto, um grande fator de dificuldade está na qualidade das séries utilizadas, principalmente as que estão na escala diária, estas quase sempre apresentam falhas que muitas vezes inviabilizam a investigação para determinada localidade, ou para determinados índices. Teegavarapu e Chandramouli (2005) enfatizaram que nos tratamentos de dados meteorológicos é frequente o fato de várias estações apresentarem falhas em seu banco de dados. Haylock et al. (2006) e Vincent et al. (2006) ressaltaram que a falta de qualidade das séries históricas em várias partes da América do Sul, é o maior obstáculo para a quantificação das mudanças extremas durante o século passado. É certo que evitar que os dados faltantes ocorram seria a melhor solução, porém nem sempre é possível ou viável, neste caso, é necessário buscar alternativas para tratá-los da melhor forma possível.

Uma medida comumente utilizada é excluir os períodos e/ou variáveis com dados faltantes das análises ou ignorar o problema, porém, esse tipo de medida desconsidera informações que podem ser relevantes para a análise dos dados e pode induzir viés no resultado final, principalmente se a quantidade de dados faltantes for muito grande (Rubin, 1996 e Nunes et al., 2009). Além destas complicações, a ocorrência de dados faltantes inibe o uso de medidas e métodos estatísticos paramétricos, os quais necessitam de dados completos para realização de seus cálculos (Allison, 2001 e Molenberghs et al., 2004), como testes de hipóteses, modelos de regressão, análise de variância, coeficiente de correlação, análise de cluster, entre outros. Algumas medidas e métodos estatísticos não parâmetros, como Mann-Whitney, Kruskal-Wallis, Kendall, Spearman, entre outros, também necessitam de dados completos para sua aplicação (Burke, 1998). Para contornar esse problema, vários pesquisadores (Lo Presti et al., 2010; Yendra et al., 2013; Yozgatligil et al., 2013; Dikbas, 2016) têm utilizado métodos estatísticos, comumente

chamados de imputação de dados. Estes métodos propõem a substituição dos dados faltantes por estimativas de valores plausíveis. O estudo feito por Firat et al. (2010) utilizou a imputação de dados para preencher observações faltantes das séries de precipitação mensal e anual provindas de 267 estações meteorológicas localizadas na Turquia. Os pesquisadores Wesonga (2015), Borzooei et al. (2019) e Rodrigues et al. (2019) também utilizaram de métodos de imputação para substituir, respectivamente, dados faltantes de séries de velocidade do vento, temperatura e precipitação provenientes de estações meteorológicas localizadas no Aeroporto Internacional de Entebbe, na Uganda e em Castiglione Torinese, na Itália e no nordeste do Brasil.

Dentre os métodos, estão os de imputação simples e de imputação múltipla (MI – do inglês *Multiple Imputation*). Enquanto no primeiro cada valor faltante é substituído por um único valor, no segundo as lacunas são substituídas por  $m$  valores. Dessa forma, são geradas bases de dados completas que podem ser analisadas através de procedimentos convencionais (Rubin, 1987). A MI possibilita a inclusão da incerteza da imputação nos resultados, corrigindo o maior problema associado à imputação única (Rubin, 1996; Zhou et al., 2001 e Little e Rubin, 2002). No entanto, apenas na última década a IM vem sendo mais utilizada devido ao desenvolvimento computacional e implementação de seus métodos em *softwares*, a MI tornou-se a classe de métodos mais indicada para manipular dados faltantes (Mcknight et al., 2007).

Estudos como os dos pesquisadores Lo Presti et al. (2010), Yendra et al.(2013), Yozgatligil et al. (2013) e Dikbas (2016), Burhanuddin et al. (2017), Fernandes et al. (2017), Aieb et al. (2019) investigaram metodologias de MI para o preenchimento de banco de dados na área de ciências climáticas. De forma geral, os autores sugerem que a metodologia de MI apresenta um bom desempenho para imputar séries de dados nesta área. Porém, existem vários métodos de MI disponíveis na literatura (Buuren e Groothuis-Oudshoorn, 2010; Honaker et al. 2010). E uma questão bastante delicada e essencial é determinar a abordagem analítica adequada para imputar os dados faltantes, já que é sabido que a utilização de técnicas inadequadas pode levar a conclusões equivocadas sobre os dados (Rubin, 1987; Rubin, 1996; Little e Rubin, 2002). Diante do exposto, o presente estudo tem como objetivo avaliar quatro métodos estatístico de imputação múltipla, *Random sample from the observed values* (Sample), *Predictive Mean Matching* (PMM), *Bayesian linear regression* (Norm) e *Bootstrap Expectation Maximization algorithm* (BootEm) em uma base de dados diária de precipitação, proveniente de 94

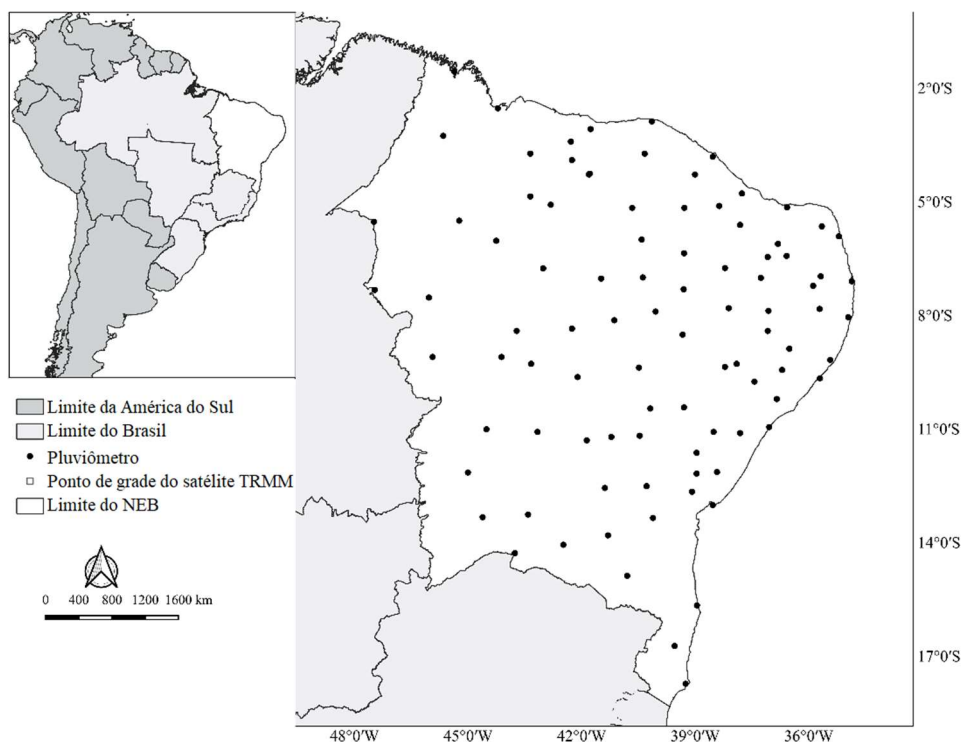
estações meteorológicas distribuídas no Nordeste Brasileiro (NEB), no período de janeiro de 1986 à 31 de dezembro de 2015.

## 2.2. Material e Método

### 2.2.1. Banco de dados

Os dados de estações meteorológicas foram provenientes do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET) - disponível em: <[www.inmet.gov.br](http://www.inmet.gov.br)>. O banco de dados refere-se à série de precipitação (mm) diária, disponíveis em 94 estações meteorológicas distribuídas no NEB, desde 01/01/1986 à 31/12/2015 (Figura 2.1).

**Figura 2.1** - Localização do Nordeste Brasileiro e estações meteorológicas, cada círculo preenchido representa uma estação meteorológica.



### 2.2.2. Imputação Múltipla

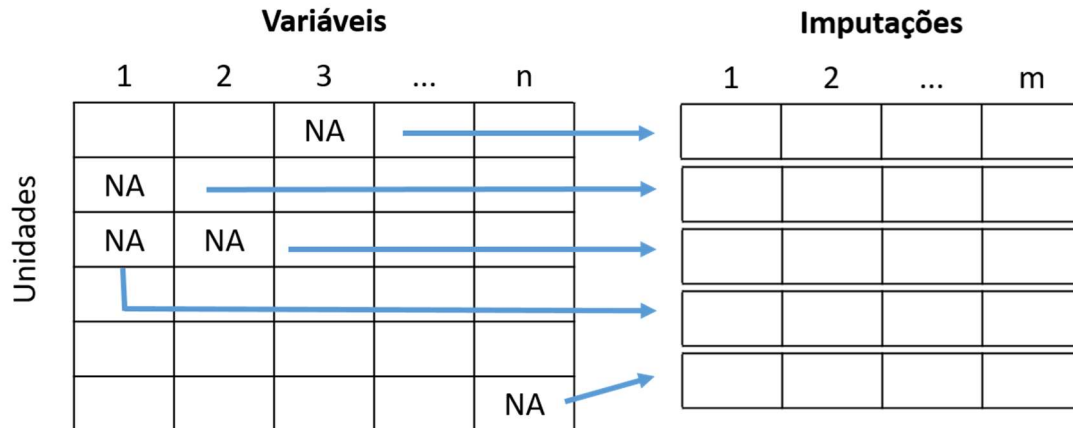
Na estatística existem técnicas que são utilizadas para preencher valores faltantes em bancos de dados por estimativas de valores plausíveis, possibilitando a análise com

os dados completos. As primeiras técnicas de imputação de dados abrangiam metodologias simples, como por exemplo a substituição dos valores faltantes pela média, pela mediana, pelo vizinho mais próximo, por regressão linear ou outros métodos estatísticos. Todas essas metodologias permitem substituir os dados faltantes por meio do que se chama de imputação simples ou única, ou seja, o dado faltante é preenchido uma única vez e então se utiliza o banco de dados completo para as análises (Engels e Diehr, 2003). Entretanto, na imputação simples não é levada em consideração a incerteza associada à imputação (Zhou et al., 2001 e Little e Rubin, 2002). Com o intuito de solucionar esse problema e investir mais nos estudos referentes a imputação de dados Rubin, em 1987, publicou o livro “*Multiple Imputation for Nonresponse in Surveys*” (GRAHAM, 2009).

Destaca-se que a MI só começou a ser utilizada, com o avanço da computação e com a proliferação de softwares que implementam vários métodos de imputação múltipla. Dentre os mais utilizados, pode-se citar os aplicativos SAS, S-Plus, MICE, MIXED e Amelia. Análises do desempenho dos aplicativos computacionais para imputação Múltipla têm sido publicadas na literatura por vários autores (Horton et al., 2001; Acock, 2005 e Horton et al., 2007). De acordo com Mcknight et al. (2007), a MI tornou-se a classe de métodos mais indicada para manipular dados faltantes.

Proposta por Rubin (1987) a MI envolve, basicamente, três etapas. A primeira, começa com o banco de dados com valores observados e faltantes, por meio de algum método de MI cada dado faltante será imputado  $m$  vezes, obtendo-se  $m$  bancos de dados completos, como ilustra a Figura 2.2. O método utilizado para imputação dos  $m$  valores é o mesmo, mas os valores diferem. A magnitude destas diferenças reflete as incertezas acerca de qual valor a ser imputado e nesta propriedade reside o poder deste método, os valores observados permanecem os mesmos.

**Figura 2.2** - Conjunto de dados com  $m$  imputações para cada valor não disponível (NA – do inglês: *Not Available*).



Fonte: Adaptado de Rubin (1987).

A segunda etapa consiste em estimar o(s) parâmetro(s) de interesse de cada conjunto de dados imputados, por meio da aplicação de métodos de análises padrão para dados completos. Na última etapa, os resultados obtidos podem ser combinados usando-se as regras propostas por Rubin (1987), estas estão amplamente divulgadas na literatura que trata de imputação múltipla, são independentes da metodologia utilizada para fazer a imputação.

A finalidade é que a partir de cada análise sejam obtidas as estimativas para o parâmetro de interesse  $X$ , ou seja,  $X_j$  para  $j = 1, 2, \dots, m$ . Segundo Schafer (1999),  $X$  pode ser qualquer medida escalar a ser estimada, tal como média, correlação, coeficiente de regressão ou razão de chances. Neste estudo, a estimativa combinada foi a média das estimativas individuais, Equação (2.1).

$$\bar{X} = \frac{1}{m} \sum_{j=1}^m \hat{X}_j \quad (2.1)$$

E a variância total é a combinação entre a variância dentro e entre as imputações (Equação 2.2).

$$T = \bar{U} + 1 + \frac{1}{m} B \quad (2.2)$$



em que:

$$\bar{U} = \frac{1}{m} \sum_{j=1}^m U_j \in B = \frac{1}{m-1} \sum_{j=1}^m (\hat{X}_j - \bar{X})^2 \quad (2.3)$$

Os métodos de MI utilizados neste estudo foram o aleatório, denominado *Sample*, *Predictive Mean Matching* (PMM), *Imputation by Bayesian linear regression* (Norm) e o método de remostarem *bootstrap* via algoritmo *Expectation Maximization* (EM), designado BootEM. Os três primeiros utilizam a *Multivariate Imputation by Chained Equations* (MICE). O MICE é um método de cadeia de Markov Monte Carlo, que gera várias imputações para dados multivariados incompletos por amostragem de Gibbs, técnica de simulação Bayesiana, que amostra distribuições condicionais com a finalidade de obter amostras da distribuição conjunta (GANDOLFI, 2016).

O algoritmo MICE inicia com um sorteio aleatório dos dados observados e imputa os dados faltantes variável por variável, em seguida ocorre uma interação que consiste em um ciclo de todas as observações da variável de interesse (BUUREN, 2012). O número de iteração  $T$  geralmente é baixo, 5 ou 10, o algoritmo gera várias imputações ( $m$ ) executando os passos descritos a seguir (RUBIN, 1987):

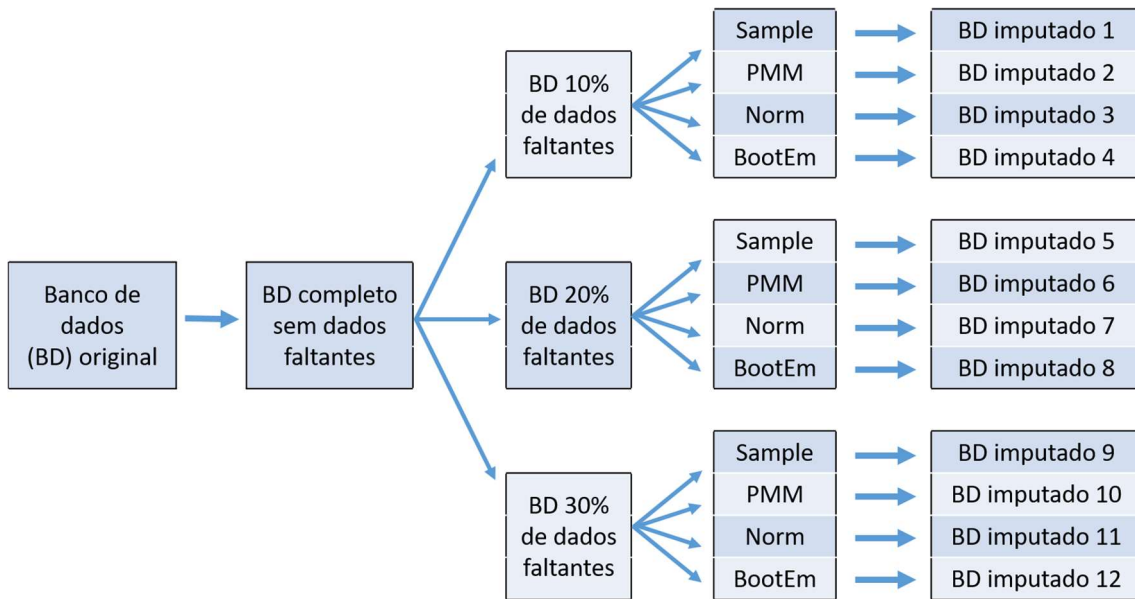
1. Especificar um modelo de imputação  $P(Y_{faltante,i} | Y_{observado,i}, Y_{-i}, R)$  para variável  $Y_i$ , e  $R$  é a matriz indicadora de resposta da variável  $Y_i$ , com  $i = 1, 2, \dots, n$ .
2. Para cada  $i$ , inicia-se o preenchimento das imputações, por retirada aleatória de  $Y_{observado,i}$ .
3. Repete-se  $t = 1, 2, \dots, T$ , em que  $t$  é a quantidade de iterações.
4. Repete-se para  $i = 1, 2, \dots, n$ , em que  $i$  é a quantidade de variáveis incompletas.
5. Defini-se  $Y_{preenchido,-i} = (Y_{preenchido,1}, Y_{preenchido,i-1}, Y_{preenchido,n})$  como os dados atualmente completos.
6. Retira-se  $\theta_{preenchido,i} \sim P(\theta_{preenchido,i} | Y_{observado,i}, Y_{preenchido,-i}, R)$ , em que  $\theta_{preenchido,i}$  é o parâmetro do modelo de dados faltantes da  $i$ -ésima variável incompleta na  $t$ -ésima iteração.
7. Retira-se imputações  $Y_{preenchido,i} \sim P(Y_{faltante,i} | Y_{observado,i}, Y_{preenchido,-i}, \theta_{preenchido,i})$
8. Finaliza-se repetição  $i$ .
9. Finaliza-se repetição  $t$ .

Dentre os modelos utilizados no primeiro passo do algoritmo MICE o *Sample* é considerado o mais simples. Este escolhe aleatoriamente um valor já observado para substituir o valor faltante. De acordo com Di Zio e Guarnera (2009), Schafer (1997), e Li et al. (1991), o PMM é uma variante da regressão linear. São calculados valores preditos para os valores observados ( $y_{observados}$ ) e faltantes ( $y_{faltantes}$ ). Os dados faltantes são substituídos pelos dados observados em que os valores preditos para  $y_{observados}$  e  $y_{faltantes}$  são mais próximos. Assim como no PMM, o método Norm faz uso da regressão linear, porém as imputações são feitas pelos próprios valores preditos para os  $y_{faltantes}$ . O método BootEM imputa os valores faltantes de uma série temporal por estimativas geradas pelos algoritmos EM implementados em várias amostras *bootstrap* dos dados originais (Rubin, 1994 e Honaker et al., 2011).

### **2.2.3. Procedimentos para comparação dos métodos de MI**

Para comparação dos métodos de MI, o primeiro procedimento foi excluir os dados faltantes do banco de dados original. Com o banco de dados completo, sem dados faltantes, o passo seguinte consistiu na criação de três cenários, em que foram retiradas aleatoriamente 10%, 20% e 30%, para cada estação do banco de dados completo. Feito isso, aplicou-se para cada cenário os métodos de imputação múltipla, um por vez, obtendo assim, doze bancos de dados imputados, quatro para cada cenário (Figura 2.3).

**Figura 2.3** - Ilustração resumida dos passos para gerar os bancos de dados imputados.



A comparação entre o banco de dados completo e cada banco de dados com os valores imputados deu-se pelas medidas estatísticas: Viés, Desvio Padrão (*Standard Deviation* - SD), Erro Quadrático Médio (EQM) e Coeficiente de Correlação de Pearson( $\rho$ ). Estas são dadas, respectivamente, pelas Equações (2.4), (2.5), (2.6) e (2.7).

$$Viés = X_i - Y_i \quad (2.4)$$

$$SD = \hat{\sigma} = \sqrt{\frac{\sum_i^n (Y_i - \bar{Y})^2}{n - 1}} \quad (2.5)$$

$$EQM = \frac{\sum_i^n (X_i - Y_i)^2}{n - 1} \quad (2.6)$$

$$\rho(X, Y) = \frac{\sum_i^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i^n (X_i - \bar{X})^2 \sum_i^n (Y_i - \bar{Y})^2}} \quad (2.7)$$

em que  $X_i$  é o valor de precipitação diária da série de dados completa,  $\hat{Y}_i$  é o valor de precipitação diária da série de dados imputada,  $\bar{Y}$  é a média da precipitação diária da série de dados imputada e  $n$  é o total de dias da série de dados.

### 2.3. Resultados

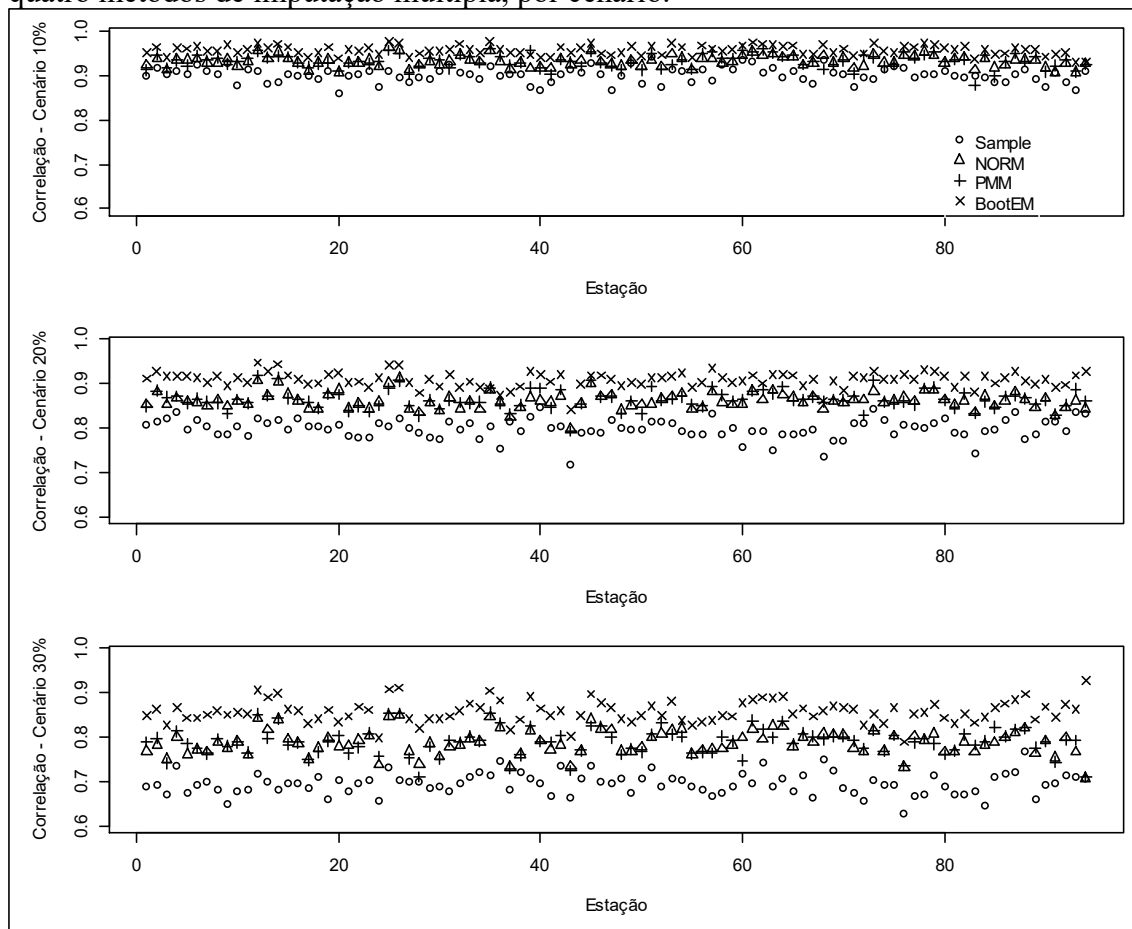
Observa-se, Tabela 2.1, que para todos os cenários, em todos os métodos, o viés é baixo, com máximo de 0,0072 e mínimo de 0,0001 (valores em módulo). Isto significa que, em média, a diferença entre o banco de dados real e imputado é próxima de zero. Verifica-se, também que os valores do desvio padrão e do erro quadrático médio aumentam quando se aumenta a porcentagem de dados faltantes. Porém, as medidas possuem menores valores quando o método BootEM é aplicado, respectivamente 0,0006; 0,0014 e 0,0022 para os cenários de 10%, 20% e 30% de dados faltantes.

**Tabela 2.1** - Medidas de Viés\*, SD\* e EQM\*, para os quatro métodos de imputação por cenário. \*Média obtida a partir das medidas feitas para as 94 estações meteorológicas.

Cenário	Método	Viés*	SD*	EQM*
10%	Sample	0,0036	0,0338	0,0011
	NORM	-0,0014	0,0323	0,0010
	PMM	-0,0024	0,0360	0,0013
	BootEM	0,0014	0,0256	0,0006
20%	Sample	0,0018	0,0517	0,0026
	NORM	-0,0010	0,0478	0,0023
	PMM	-0,0054	0,0404	0,0016
	BootEM	-0,0023	0,0382	0,0014
30%	Sample	0,0001	0,0715	0,0051
	NORM	0,0033	0,0639	0,0040
	PMM	-0,0072	0,0686	0,0047
	BootEM	0,0062	0,0470	0,0022

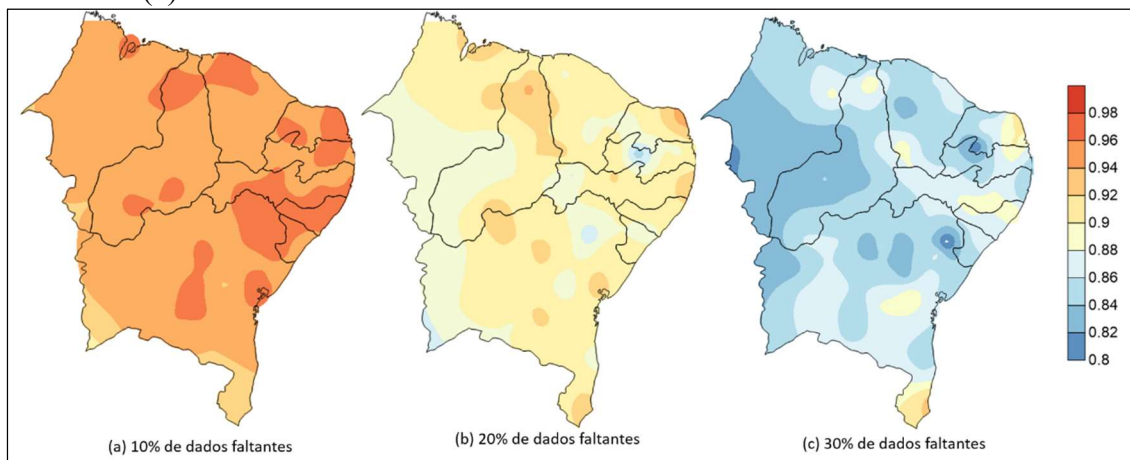
A qualidade da IM, com base nos coeficientes de correlação, varia conforme a estação meteorológica, método aplicado e no percentual de dados faltantes (Figura 2.4). De forma geral, a correlação entre o banco de dados completo e imputado diminui conforme o percentual de dados faltantes aumenta, o método BootEM é o que apresenta melhores correlações para todos os cenários, a diferença entre os métodos de IM dentro do mesmo cenário aumenta conforme o percentual de dados faltantes aumenta (Figura 2.4).

**Figura 2.4** - Gráfico de dispersão com o coeficiente de correlação de Pearson para os quatro métodos de imputação múltipla, por cenário.



As informações presentes na Figura 2.5, corroboram com as afirmações feitas anteriormente de que o coeficiente de correlação diminui, quando o cenário piora e de que existem diferentes valores de coeficientes de correlação no NEB dentro do mesmo cenário. O primeiro cenário, Figura 2.5 (a), é o que possui maiores coeficientes de correlação, variando de 0,93 até 0,98. Sendo parte do litoral leste, norte do Ceará e Maranhão e centro da Bahia possuem melhores coeficientes. No segundo cenário, Figura 2.5 (b), nota-se, de modo geral, que o litoral norte e leste possuem os melhores coeficientes, os menores coeficientes de correlação foram apresentados na área central de Pernambuco e o leste da Bahia, neste cenário o coeficiente de correlação variou de 0,85 a 0,95. O pior cenário, Figura 2.5 (c), foi o que obteve a maior variabilidade do coeficiente de correlação, 0,8 a 0,93. Neste, destaca-se o oeste do NEB com valores de coeficientes de correlação mais baixos e leste do Rio Grande do Norte com os coeficientes mais altos, próximos a 0,93. Nota-se ainda, que para o sul da Bahia o coeficiente de correlação é próximo a 0,9 para os três cenários em estudo.

**Figura 2.5** - Mapa do Nordeste do Brasil com o coeficiente de correlação de Pearson para o método BootEM para os três cenários, (a) 10% de dados faltantes; (b) 20% de dados faltantes e (c) 30% de dados faltantes.



## 2.4. Conclusão

Os resultados apresentados neste trabalho mostram que o uso adequado dos métodos estatísticos de imputação múltipla mostrou-se bastante eficiente no preenchimento de dados faltantes em séries de precipitação diária no Nordeste do Brasil. Foi possível verificar que quanto menor o percentual de dados faltantes na série de dados maior a capacidade dos métodos de imputação múltipla em preenche-los corretamente.

De forma geral, o método BootEM apresentou baixos valores de viés e menores valores de desvio padrão e erro quadrático médio em relação aos resultados dos demais métodos. Os coeficientes de correlação entre as séries completas e as séries preenchidas foram mais elevados quando foi utilizado o método de BootEM, mesmo no cenário em que as séries de dados possuíam um grande percentual de dados faltantes, 30%.

Diante dos resultados observados conclui-se que a utilização de séries sintéticas imputadas pelo método BootEM pode ser uma ferramenta que venha a corroborar com a reconstrução de séries históricas de dados climáticos que auxiliam no monitoramento e planejamento dos recursos hídricos.

## CAPÍTULO 3

### SPATIAL AND TEMPORAL ASSESSMENT OF THE EXTREME AND DAILY PRECIPITATION OF THE TROPICAL RAINFALL MEASURING MISSION SATELLITE IN NORTHEAST BRAZIL

(Avaliação espacial e temporal da precipitação diária e extrema do satélite *Tropical Rainfall Measuring Mission* no Nordeste do Brasil)

Qualis CAPES: B1 - Geociências. Fator de impacto: 2.493

#### RESUMO

Este estudo avalia a capacidade do produto 3B42 V7 da *Multisatellite Precipitation Analysis* (TMPA) do *Tropical Rainfall Measuring Mission* (TRMM) em estimar a ocorrência e intensidade dos eventos de precipitação diária, enfatizando os eventos extremos de precipitação para um período de 16 anos (2000 a 2015) sobre a região Nordeste do Brasil (NEB), que é caracterizada por diferentes condições climáticas e pela alta variabilidade sazonal e espacial da precipitação. Para isso, utilizou-se de técnicas estatísticas como o teste *t-student* pareado, curva ROC (*Receiver Operating Characteristic Curve*), análise de sensibilidade, análise de cluster, gráfico de densidade e medias descritivas, como viés, desvio padrão, erro quadrático médio e raiz do erro quadrático médio. Os resultados apontam que a qualidade das estimativas do satélite depende do período sazonal, do local e da escala temporal em que ocorrem os eventos de precipitação. De forma geral, as estimativas diárias de precipitação do satélite são estatisticamente iguais (*valor - p > 0,05*) às observadas pelos pluviômetros, exceto no litoral leste do NEB, onde os valores de precipitação observada são associados à ocorrência nuvens quentes. Em relação aos eventos extremos, verificou-se que o satélite não apresentou boas estimativas de precipitação extrema diária. Porém, a chuva acumulada em dois dias é o suficiente para obter melhores resultados em relação a qualidade das estimativas de precipitação extremas provindas do satélite. Assim, o estudo fornece ao usuário do TMPA 3B42 V7 o conhecimento prévio a respeito da qualidade de suas estimativas em relação a ocorrência e a intensidade dos eventos de precipitação, especialmente os eventos extremos de precipitação, por período sazonal em diferentes áreas do NEB.

Palavras-chave: Eventos extremos, TMPA 3B42 V7, Precipitação por satélite.

Rodrigues, D.T., Gonçalves, W.A., Spyrides, M.H.C., e Silva, C.M.S, de Souza, D.O. Spatial distribution of the level of return of extreme precipitation events in Northeast Brazil. **International Journal of Climatology** (em revisão).

## ABSTRACT

This study assesses the ability of the Tropical Rainfall Measuring Mission (TRMM) Multisatellite Precipitation Analysis (TMPA) 3B42 Version 7 (3B42 V7) product to estimate the occurrence and intensity of daily precipitation events, emphasizing extreme events, over a 16 year period (2000 to 2015) in the Northeast region of Brazil (NEB), which is characterized by different climatic conditions and high seasonal and spatial variability of rainfall. Statistical techniques such as the paired Student t-test, receiver operating characteristic curve (ROC), sensitivity analysis, cluster analysis and density graphing, along with descriptive statistics such as bias, standard deviation, mean square error and root mean square error were used. The results indicate that the quality of the satellite estimates depends on the seasonal period and the location and time scale in which the precipitation events occur. In general, the daily precipitation estimates of the satellite are statistically equal ( $p\text{-value} > 0.05$ ) to those observed by rain gauges, except in the NEB east coast, where the observed precipitation values are associated with the occurrence of warm clouds. Regarding the extreme events, the satellite did not provide good estimates of extreme daily precipitation. However, rain accumulated in two days is enough to obtain better results for the quality of the extreme precipitation estimates coming from the satellite. Thus, the study provides users of the TMPA 3B42 V7 with prior knowledge regarding the quality of the estimates regarding the occurrence and intensity of precipitation events, especially extreme ones, by seasonal period in different areas of NEB.

Keywords: Extreme Events, TMPA 3B42 V7, Precipitation estimation by satellite.



### 3.1. Introdução

A precipitação é uma variável essencial para estudos hidrometeorológicos (Katiraie-Boroujerdy et al., 2013; Cai et al., 2015; Yang et al., 2017). Ter o conhecimento da sua variabilidade, que inclui o ciclo diário, oscilações intrazonal, sazonalidade, tendências, variabilidade interanual e interdecadal, é essencial para as atividades económicas e sociais. Identificar os padrões de variabilidade temporal e espacial é de fundamental importância no planeamento dos impactos das chuvas, tanto positivas como negativas, em uma variedade de atividades, tais como agricultura, gestão dos recursos hídricos e formulação de políticas de saúde pública. Portanto, o acesso a dados precisos com alta resolução temporal e espacial é essencial para a previsão hidrológica e monitoramento dos recursos hídricos (Sorooshian et al., 2005; Yong et al., 2010; Kucera et al., 2013).

Dentre as formas capazes de medir o volume de precipitação estão os pluviômetros, radares e satélites (Tapiador et al., 2012). Com pluviômetros, é possível realizar medições diretas (precisas) e imediatas, com fácil instalação e baixo custo individual. Radares pode cobrir simultaneamente áreas maiores e executar alta amostragem espacial, mas eles são muito caros e, no caso do Brasil, eles não são distribuídos em todo o território, deixando lacunas em áreas importantes, onde o monitoramento só pode ser realizado por técnicas que envolvem dados de satélite.

Apesar da sua importância, as redes pluviométricas e radares meteorológicos são escassos em muitos países em desenvolvimento, especialmente devido ao alto custo de instalação e manutenção de sua infra-estrutura (Su et al., 2008; Behrangi et al., 2011; Katiraie-Boroujerdy et al., 2013; Salio et al., 2015). No Brasil, a maioria das bacias hidrográficas apresentam uma densidade pluviômetro menor do que o recomendado pela Organização Mundial de Meteorologia (Curtarelli et al., 2014).

Como uma fonte alternativa, bases de dados de satélite têm sido amplamente utilizados em estudos meteorológicos e climáticos, principalmente devido à sua resolução espacial e temporal. Dentre os satélites existente o TRMM (*Tropical Rainfall Measuring Mission*) se destaca na estimativa de precipitação. O satélite TRMM foi uma missão conjunta entre a NASA (*National Aeronautics and Space Administration*) e JAXA (*Japan Aerospace Exploration Agency*) para estudar a distribuição e variabilidade da precipitação nas regiões tropicais e subtropicais do mundo, fornecendo dados de precipitação através de seus algoritmos diferentes (Huffman et al., 2007). O TRMM tinha três instrumentos

capazes de medir a precipitação: TRMM *Microondas Imager* (TMI), *Precipitation Radar* (PR) e *Visible and Infrared Scanner* (VIRS). Além disso, o satélite TRMM carrega o *Lighting Imaging Sensor* e o *Clouds and the Earth's Radiant Energy System*, capazes de detectar raios e estimar a energia da atmosfera, respectivamente.

De acordo com Yin et al. (2008), Vila et al. (2009), Chen et al. (2013) e Gaona et al. (2016), as estimativas de precipitação dos produtos de satélite tendem a superestimar a precipitação de baixa intensidade e a subestimar a precipitação de alta intensidade. Salio et al. (2005) avaliaram o desempenho de produtos do TRMM, *Climate Prediction Center* (CPC) *Morphing Technique* (CMORPH), *Hydroestimator* (HYDRO) e o *Combined Scheme* (CoSch) *algorithm* na América do Sul durante dezembro de 2008 a novembro 2010. Os autores enfatizaram a importância de estudos futuros sobre este assunto, especialmente em regiões com diferentes regimes de precipitação, a fim de obter informações mais detalhadas sobre as discrepâncias entre as estimativas dos produtos de satélite e os valores diários de precipitação observados por pluviômetros.

O estudo feito por Paredes-Trejo et al. (2017) comparou as estimativas de precipitação do *Climate Hazards Group InfraRed Precipitation* (CHIRPS) com os dados de precipitação observados por 21 estações meteorológicas no Nordeste do Brasil (NEB) durante o período de 1981 a 2013. Os autores observaram que as estimativas de CHIROS tendem a superestimar os valores baixos de precipitação e subestimar valores elevados, e que frequentemente o valor do viés é negativo na estação chuvosa da região. Islam (2018) avaliaram as estimativas de precipitação de seis produtos derivados do *Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks* (PERSIANN), CMORPH, *Integrated Multisatellite Retrievals for Global Precipitation Measurement* (IMERG) e *Global Precipitation Measurement* (GPM), usando como referência os dados de precipitação observados por pluviômetros, durante um período de três anos, a partir de Janeiro de 2014 até Dezembro de 2016. Os autores concluíram que o desempenho das estimativas de precipitação dos seis produtos foi satisfatório em detectar a ocorrência de precipitação, mas afirmaram que o desempenho foi fraco ao estimar a magnitude da mesma, especialmente no inverno. Beaufort et al. (2019) avaliaram as estimativas de precipitação do satélite GPM sobre a Guiana Francesa entre abril de 2015 e março de 2016. Eles concluíram que o satélite subestimou a precipitação na estação chuvosa.

Muitos estudos têm sido realizados a partir das estimativas de precipitação provindos do TRMM, disponível a partir de diferentes produtos, em termos de

representação do regime de precipitação observada por estações meteorológicas, seja a nível global (Maggioni et al., 2016), continental (Vila et al., 2009; Sylla et al., 2013), nacional (Islam e Uyeda, 2008; Franchito et al., 2009; Zhao e Yatagai, 2014; Melo et al., 2015; Darand et al., 2017) ou nível regional (Curtarelli et al., 2014; Abiodun et al., 2016). No geral, os resultados sugerem que a precisão das estimativas de precipitação provenientes de satélite para uma determinada região depende de fatores, tais como terreno, tipo de precipitação e clima.

Assim, é mais apropriado avaliar as estimativas de precipitação por satélite em escala regional (Huffman et al., 1997; Kummerow et al., 2000; Guo et al., 2016), embora em regiões áridas e semi-áridas a precisão contínua de estimativas de precipitação seja um desafio (Akbari et al., 2017). Na maioria destas regiões, a precipitação é a principal fonte de água fresca (Yang et al., 2017). Nesse contexto, estudos têm focado na avaliação das estimativas de precipitação provindas de produtos do TRMM em várias escalas temporais e espaciais em regiões áridas e semiáridas em vários locais do mundo, como Rozante et al. (2010), que estudaram regiões da América do Sul; Katiraie-Boroujerdy et al. (2013), Akbari et al. (2017) e Darand et al. (2017), que estudaram regiões do Irã; Peng et al. (2014) e Cai et al. (2015), que estudaram regiões da China; Melo et al. (2015), estudaram o Brasil; e Hobouchian et al. (2017), que estudaram encostas dos Andes subtropicais. Na maioria desses estudos, os autores descobriram que as estimativas de satélite tendem a subestimar a precipitação em sub-regiões úmidas, especialmente no inverno.

No entanto, poucos estudos incluem em suas avaliações as estimativas de valores extremos de precipitação que são essenciais em pesquisas que visam compreender a natureza dos fenômenos climáticos extremos e avaliar as mudanças e impactos desses acontecimentos sobre o clima futuro (Demirdjian et al., 2018). Em relação à análise das estimativas de valores extremos de precipitação provenientes do TRMM, Hermance e Sulieman (2018) avaliaram sete eventos diários extremos em um período de 17 anos registrados no Sudeste Sahel, na África, e descobriu que apenas um caso foi sincronicamente detectado pelo produto 3B42 do TRMM. Sekaranom e Masunaga (2017) avaliaram as estimativas de precipitação não-extremas e extremas (valores superiores a 99% da base de dados) de três produtos do satélite TRMM (2A25, 2A12, e 3B42) sobre o continente e oceano entre 1998 e 2014. O autores afirmaram que existe diferenças entre as estimativas dos produtos de ambas as taxas de precipitação, extremas e não-extremas. Além disso, os autores descobriram que as diferenças entre as taxas de precipitação dos

produtos foram maiores nas regiões costeiras e continentais em comparação com áreas oceânicas.

No caso das regiões semi-áridas da América do Sul, o NEB é uma região caracteriza-se predominantemente pela alta variabilidade interanual e sazonal de precipitação (Moura e Schukla, 1981; Zhou e Lau, 2001; Oliveira et al., 2017), com a ocorrência frequente de longos períodos de seca (Marengo et al., 2017). A região é afetada por impactos relacionados aos sistemas de abastecimento de água e agricultura de sequeiro (Marengo et al., 2013). Esses fatores influenciam a economia e qualidade de vida da população (Coelho et al., 2004; Paredes et al., 2015).

Paradoxalmente, esta região é também caracterizada por eventos extremos de precipitação (Oliveira et al., 2014; Oliveira et al., 2017; Da Silva et al., 2018), o que em alguns casos pode causar benefícios, por exemplo, para o fornecimento de electricidade sistema em grandes bacias hidrográficas (Bezerra et al., 2018). Neste sentido, ter acesso a dados confiáveis com alta cobertura espacial são necessários para estudos, como monitoramento hídrico e gestão de recursos agrícolas.

Existem poucos estudos sobre eventos extremos de precipitação no NEB, que possui clima úmido em sua área costeira e clima semi-áridas nas demais áreas. Assim, o objetivo geral deste estudo é avaliar a qualidade do produto 3B42 versão 7 (3B42 V7) do satélite TRMM no NEB para os dados diários de precipitação, enfatizando os eventos extremos de precipitação durante o período de 2000 a 2015.

Neste contexto, as principais questões abordadas neste estudo são: (a) A qualidade dos dados TRMM variam espacialmente? (B) A qualidade dos dados do TRMM é a mesma em diferentes períodos sazonais? (C) O satélite TRMM é capaz de detectar a presença e ausência da precipitação diária? (D) A capacidade do satélite TRMM para detectar a presença de precipitação extrema é a mesmo em dados acumulados para diferentes períodos de tempo? (E) O satélite TRMM é capaz de estimar a intensidade dos dados de precipitação extrema diária e acumulada a cada dois dias?

É extremamente importante avaliar estas questões, uma vez que as respostas vão permitir aos investigadores, empresas e órgãos públicos ter o conhecimento sobre o quanto esses dados podem ser confiáveis para esta região. Isto irá permitir-lhes obter melhores resultados, ou pelo menos tomar decisões mais bem informadas.

## **3.2. Material e métodos**

### **3.2.1. Área de estudo**

O NEB está localizado na região tropical entre 1,0 °N e 18,0 °S e 34,5 °W e 48,5 °W, no extremo nordeste da América do Sul. Banhado ao norte e leste pelo oceano Atlântico. Possui área de aproximadamente 1.558.196 km<sup>2</sup>, com 53,081,950 habitantes (IBGE, 2010). O NEB se caracteriza por diferentes condições climáticas, as quais estão diretamente relacionadas com a distribuição de precipitação na região. Afetada por longos períodos de seca, o centro do NEB apresenta uma média de 500 mm de precipitação acumulada anual, enquanto há áreas, como a costa onde a média de precipitação acumulada anual é superior a 1.500 mm (Alvarez et al., 2013).

A precipitação no NEB é influenciada, principalmente, pela variabilidade interanual da temperatura do Oceano Pacífico, associado com o El Niño Oscilação Sul (ENOS). Tem tipicamente períodos secos durante condições El Niño, períodos húmidos durante condições de La Niña (Ropelewski e Halpert 1987; Marengo et al., 2017), e é sujeito a variabilidade interanual de temperaturas do Oceano Atlântico (Bombardi et al., 2014; Rodrigues et al., 2015), juntamente com os sistemas meteorológicos, como a Zona de Convergência Intertropical (ZCIT) (Hastenrath e Heller 1977; Bombardi et al., 2018), *Upper Tropospheric Cyclonic Vortices* (UTCVs) (Kousky e Gan, 1981; Fedorova et al., 2016), *Mesoscale convective Systems*, geralmente organizadas em linhas de instabilidade (Kousky, 1980; Silva et al., 2017), *South Atlantic Convergence Zone* (SACZ), Frontal Systems (FSs) (Kousky, 1979; Fedorova et al., 2018; Zilli et al., 2018) e *Easterly Waves Disturbances* (EWD) (Yamazaki e Rao, 1977; Gomes et al., 2015).

### **3.2.2. Dados**

#### **3.2.2.1. Estações meteorológicas**

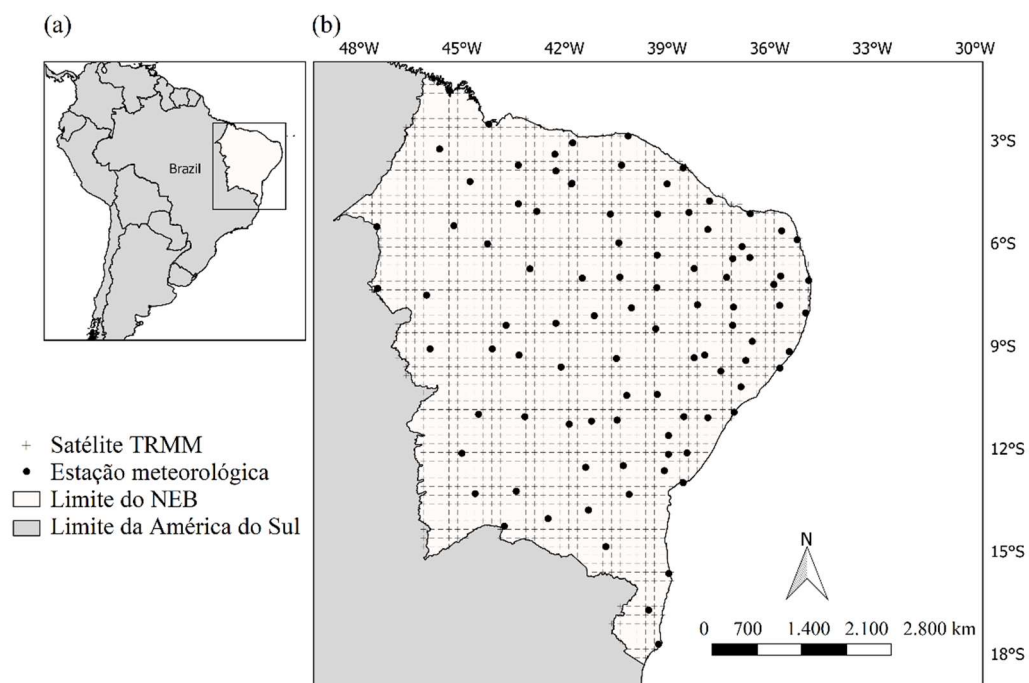
Os dados das estações meteorológicas são provenientes do Banco de Dados Meteorológicos de Ensino e Pesquisa (BDMEP) Do Instituto Nacional Meteorologia do Brasil (INMET). A base de dados refere-se à série diária precipitação (mm) observada por pluviômetro, disponível a partir de 94 estações meteorológicas distribuídas no NEB, de 01 de janeiro de 2000 até 31 de dezembro de 2015 (Figura 3.1).

#### **3.2.2.2. 3B42 V7 Produto do satélite TRMM**

Os dados de precipitação, estimados pelo algoritmo 3B42 V7 do satélite TRMM, foram obtidos a partir da técnica TRMM *Multisatellite Precipitation Analysis*

(TMPA) (Huffman et al., 2007). As estimativas do produto 3B42 V7 cobre uma área latitudinal de 50,0 °S a 50,0 °S e longitudinal de 0,0° a 360,0°, com espaçamento horizontal de 0,2° e amostragem temporal a cada 3 horas, o que permite a obtenção de acumulados diários de precipitação. Este produto é uma parte integrante da missão conjunta entre a NASA e JAXA para estudar a distribuição e variabilidade da precipitação nos trópicos (Kummerow et al., 1998). Lançado no final de 1997, o satélite inclui vários instrumentos para monitorar a precipitação usando microondas, infravermelho e sensores de comprimentos de onda visíveis.

Figura 3.1. (a) Limites da América do Sul (b) Limites do NEB, localização das estações meteorológicas e pontos de grade do satélite TRMM.



### 3.2.3. Métodos

O método descrito a seguir foi utilizado para avaliar a qualidade do produto TRMM 3B42 na reprodução de variações espaciais e temporais da precipitação em comparação com as observações *in situ*. O primeiro passo foi converter as estimativas temporais em estimativas diárias, compatível com a amostragem dos dados do BDMEP. Em seguida, foi feita uma comparação entre as observações obtidas com os pluviômetros (estações) e as estimativas de satélite (pontos da grade), seguindo o método adotado por Darand et al. (2017), onde o ponto de grade mais próximo foi usado.

As análises foram realizadas para dados diários de precipitação, juntamente com análises específicas para precipitação extrema. A análise da precipitação diária foi realizada para cada ponto de observação, considerando diferentes sub-regiões do NEB e as estações do ano. A análise dos casos de precipitação extrema foi realizada em várias escalas de tempo nas sub-regiões do NEB.

### 3.2.3.1 Análise Diária de Precipitação

A comparação entre os dados diários foi realizada de duas formas: i) considerando a precipitação acumulada observada; ii) analisando a ocorrência ou não ocorrência da precipitação. Na comparação da precipitação acumulada diariamente, os dados das duas fontes foram comparados usando o viés de medidas estatísticas, *Root Mean Square Error* (RMSE) e coeficiente de correlação ( $r$ ), calculado pelas Equações (3.1) - (3.3).

$$\text{Bias} = X_i - Y_i \quad (3.1)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n - 1}} \quad (3.2)$$

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.3)$$

Além desses, também foi utilizado o teste *t* de *Student* pareado. Este teste é útil para comparar resultados medidos de diferentes fontes (pluviômetros e 3B42 V7), mas com a mesma frequência de amostragem (diária). Para isso, cada fonte de dados foi considerada uma amostra independente  $X_1, \dots, X_n$  e  $Y_1, \dots, Y_n$ , em que  $X_i$  é o valor da precipitação no dia  $i$  da série de dados da estação e  $Y_i$  é o valor da precipitação no dia  $i$  da série de dados estimada pelo satélite. Para isso,  $D_i = X_i - Y_i$  foi definido para  $i = 1, 2, \dots, n$  e a distribuição das diferenças diárias foi obtida,  $D_1, \dots, D_n$ , que foi considerada distribuída normalmente, com média e variância, respectivamente, de  $\mu_D$  e  $\sigma_D^2$ ,  $D_i \sim N(\mu_D, \sigma_D^2)$ . O parâmetro  $\mu_D$  foi estimado pela média amostral das diferenças,  $\bar{D}$ , e o

parâmetro  $\sigma_D^2$  foi estimado pela variação amostral de  $s_D^2$ . A estatística do teste é dada pela Equação (3.4). E  $\bar{D}$  e  $s_D^2$  são dados pela Equação (3.5).

$$T = \frac{\bar{D} - \mu_D}{\sqrt{\frac{s_D^2}{n}}} \quad (3.4)$$

em que:

$$\bar{D} = \frac{\sum_{i=1}^n D_i}{n} \text{ and } s_D^2 = \frac{\sum_{i=1}^n (D_i - \bar{D})^2}{n - 1} \quad (3.5)$$

Neste estudo, a hipótese nula afirma que a média da diferença entre os dados diários de precipitação acumulada da estação e do satélite são as mesmas,  $H_0: \bar{D} = \mu_D = 0$ . Para decidir se deve ou não rejeitar essa hipótese, o  $p - value$ , que é a probabilidade de obter uma estatística de teste igual ou maior que o valor observado em uma amostra, é calculado sob a hipótese nula.

Os dados da estação e do satélite foram dicotomizados para investigar a capacidade do satélite de estimar corretamente a presença ou ausência de precipitação diária. Dias que apresentaram precipitação acumulada igual ou superior a 1 mm, foram codificados como 1, enquanto os dias com precipitação menor que 1 mm, foram codificados como 0. Nesta análise, foi utilizada a curva *Receiver Operating Characteristic* (ROC), amplamente utilizada em estudos na área da saúde (Pollack et al., 2000). A curva ROC mede graficamente as probabilidades, sensibilidade e 1-especificidade em um plano chamado plano ROC unitário.

A sensibilidade representa a probabilidade de detecção, ou seja, a taxa de verdadeiros positivos e a especificidade representa a taxa de verdadeiros negativos. Seus cálculos podem ser auxiliados pela tabela de contingência (Tabela 3.1), que apresenta os possíveis resultados da comparação entre os bancos de dados.

Tabela 3.1. Resultados possíveis de um teste de diagnóstico.

Dados	Precipitação observada (estação meteorológica)		
	Sim	Não	
Precipitação estimada (satélite)	Sim	Verdadeiro positivo ( <i>a</i> )	Falso positivo ( <i>b</i> )
	Não	Falso negativo ( <i>c</i> )	Verdadeiro negativo ( <i>d</i> )



As equações (3.6) - (3.7) representam, respectivamente, as medidas de sensibilidade e especificidade.

$$\text{Sensibilidade} = \frac{\text{Número de verdadeiro positivo estimados}}{\text{Número de casos positivo observado}} = \frac{a}{a + c} \quad (3.6)$$

$$\text{Especificidade} = \frac{\text{Número de verdadeiro negativo estimados}}{\text{Número de casos negativo observado}} = \frac{d}{b + d} \quad (3.7)$$

Assim, as medidas de sensibilidade e especificidade avaliam a capacidade do satélite de estimar corretamente a presença ou ausência de precipitação em um determinado dia, respectivamente.

### 3.2.3.2 Sub-regiões do NEB

Nesta etapa, o objetivo foi dividir o NEB em sub-regiões homogêneas de acordo com a precipitação diária. Os dados dos pluviômetros foram utilizados, pois são coletados *in situ*. As regiões foram determinadas através da aplicação da técnica de análise de *cluster*, utilizada por vários autores na área de ciências climáticas, inclusive no NEB (Lyra et al., 2004; Oliveira et al., 2017). A análise de *cluster* é um método estatístico multivariado, com o objetivo de dividir os elementos da amostra ou população em grupos para que os elementos pertencentes ao mesmo grupo sejam semelhantes entre si em relação às variáveis envolvidas e os elementos em grupos diferentes são heterogêneos para essas mesmas variáveis (Mingoti, 2005). A idéia é maximizar a homogeneidade dos elementos dentro do grupo enquanto maximiza a heterogeneidade entre os grupos (Hair et al., 2005). No entanto, como os dados diários das estações continham falhas e o uso da técnica de análise de *cluster* para um banco de dados com observações ausentes não é possível, a técnica de imputação múltipla foi usada apenas para o banco de dados usado nesta etapa.

De acordo com McKnight et al. (2007), a imputação múltipla é a técnica mais apropriada, dentre os métodos estatísticos, para imputar as observações ausentes. O método de imputação múltipla utilizado foi *bootstrap resampling algorithm for expectation maximization* (EM). Este imputa os valores ausentes de uma série temporal por estimativas geradas pelos algoritmos EM implementados em várias amostras *bootstrap* dos dados originais (Efron, 1994; Honaker et al., 2011).

Após a imputação dos dados ausentes, foi iniciada a primeira fase do processo de agrupamento, calculando uma medida de similaridade ou dissimilaridade. O segundo consistiu na construção dos *clusters*, com duas abordagens: hierárquica e não hierárquica. Neste estudo, várias configurações foram testadas, mas a análise realizada pelo cálculo da distância euclidiana e a abordagem hierárquica proposta por Ward (1963) foram as mais confiáveis para as características climáticas da região.

### 3.2.3.3 Análise de Precipitação Extrema

Valores extremos são classificados como eventos raros. Muitos pesquisadores, como Santos et al. (2015) e Sekaranom e Masunaga (2017), classificam esses eventos como aqueles acima de um determinado percentual da distribuição de dados. Neste estudo, optamos por classificar eventos extremos como aqueles acima do percentil 95, como realizado por Della-Marta et al. (2009), Wu et al., (2015) e Acero et al. (2018), que estudaram extremos de precipitação, respectivamente, na Europa, China e Península Ibérica.

As técnicas estatísticas utilizadas na análise dos eventos extremos de precipitação dependem do objetivo de cada estudo e geralmente são realizadas por meio de estatística descritiva, análise de tendências e estimativa de períodos de retorno. A comparação de diferentes fontes extremas de dados geralmente é realizada em um único período de tempo (acumulado diariamente, mensalmente ou anualmente) por meio de medidas estatísticas como média, desvio padrão e viés, entre outras (Sekaranom e Masunaga, 2017; Hermance e Sulieman, 2018). Neste estudo, a comparação foi feita utilizando as medidas de estatística descritiva, como média (Equação (3.8)) e desvio padrão (Equação (3.9)), juntamente com a análise de sensibilidade e plotagem de gráficos das densidades das distribuições extremas de dados, ao longo de vários períodos de tempo, para cada sub-região NEB. Os resultados das aplicações dessas técnicas demonstram a capacidade do satélite TRMM em detectar corretamente a ocorrência de precipitação extrema e também a capacidade do TRMM em estimar corretamente a intensidade da precipitação extrema ao longo de vários períodos de tempo.

$$\mu = \bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (3.8)$$

$$SD = \hat{\sigma} = \sqrt{\frac{\sum_{i=1}^n (Y_i - \bar{Y})^2}{n - 1}} \quad (3.9)$$

Com as sub-regiões definidas pela análise de agrupamentos usando os dados diários dos pluviômetros, foi possível construir várias configurações do banco de dados, considerando algumas escalas de tempo. O primeiro passo foi transformar os dados diários em dados acumulados a cada dois, três, quatro, cinco e seis dias, bem como uma, duas e três semanas e mensalmente.

Sequencialmente, para cada banco de dados derivado das estações, os valores acima do percentil 95 (limiar) para cada sub-região NEB foram definidos como extremos. Além de registrar a intensidade do extremo, a data de cada evento também foi registrada, de modo que a avaliação das estimativas do produto de satélite foi realizada nas mesmas datas em que os eventos extremos foram observados pelo pluviômetro. É importante mencionar que cada banco de dados *in situ* possui um limite diferente para cada sub-região.

A comparação entre os dados extremos foi realizada para investigar a qualidade das estimativas de satélite para a ocorrência de eventos extremos de precipitação e sua intensidade. Para verificar a capacidade do satélite de estimar corretamente a presença de precipitação extrema em cada sub-região do NEB para cada escala de tempo em estudo, foi utilizada a análise de sensibilidade. Para essa análise, cada banco de dados foi dicotomizado, classificado como 1 para datas em que houve precipitação extrema, definido como valores acima do limiar (percentil 95) e 0 para datas em que não houveram precipitação extrema, valores abaixo do limiar. Assim, para cada escala de tempo, foram calculados cinco valores de sensibilidade, um para cada sub-região, totalizando 50 valores. Os dados de intensidade dos extremos foram comparados por um gráfico de densidade. A comparação foi realizada dentro de cada sub-região para os dados diários e os dados de precipitação acumulados a cada dois dias.

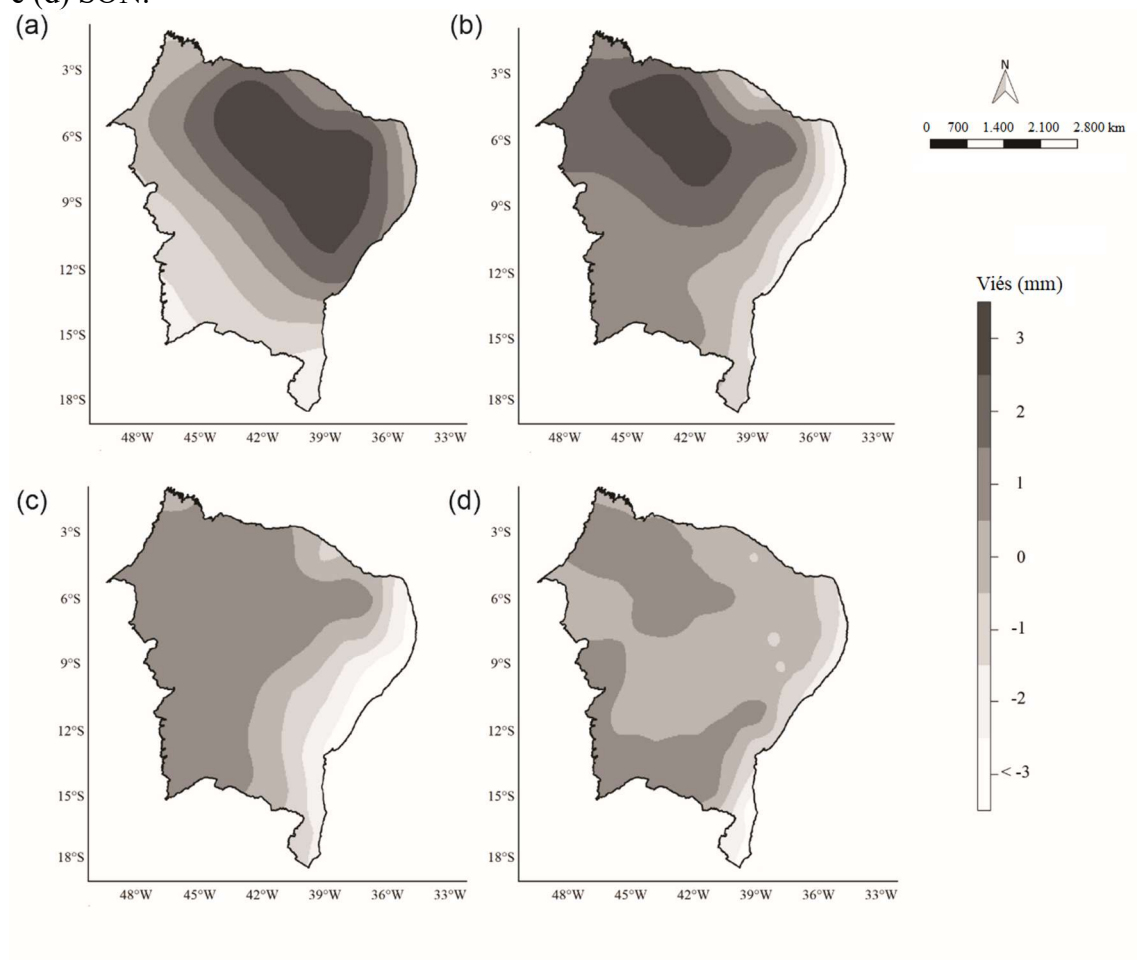
### 3.3 Resultados e discussão

#### 3.3.1 Precipitação Diária

Os valores de viés entre os dados estimados (TRMM) e observados (estação), em média, variam entre -5,0 mm e 3,0 mm por dia. Essa variação depende do período sazonal e do local em que a precipitação ocorre. Os valores de viés de dezembro, janeiro

e fevereiro (DJF) (Figura 3.2) variam de -2,0 mm a 3,0 mm por dia, sendo essa variação positiva, especialmente na região semiárida norte do NEB. Na região sul, as estimativas tendem a subestimar a precipitação diária observada. No período de março, abril e maio (MAM), grande parte das estimativas de satélite do NEB tendem a superestimar os valores de precipitação, especialmente no noroeste e sudoeste do NEB. Os valores do viés apresentados em junho, julho e agosto (JJA), variam de -5,0 mm a 1,0 mm, sendo negativos no NEB leste. No período de setembro, outubro e novembro (SON), grande parte da região tem um viés próximo de zero.

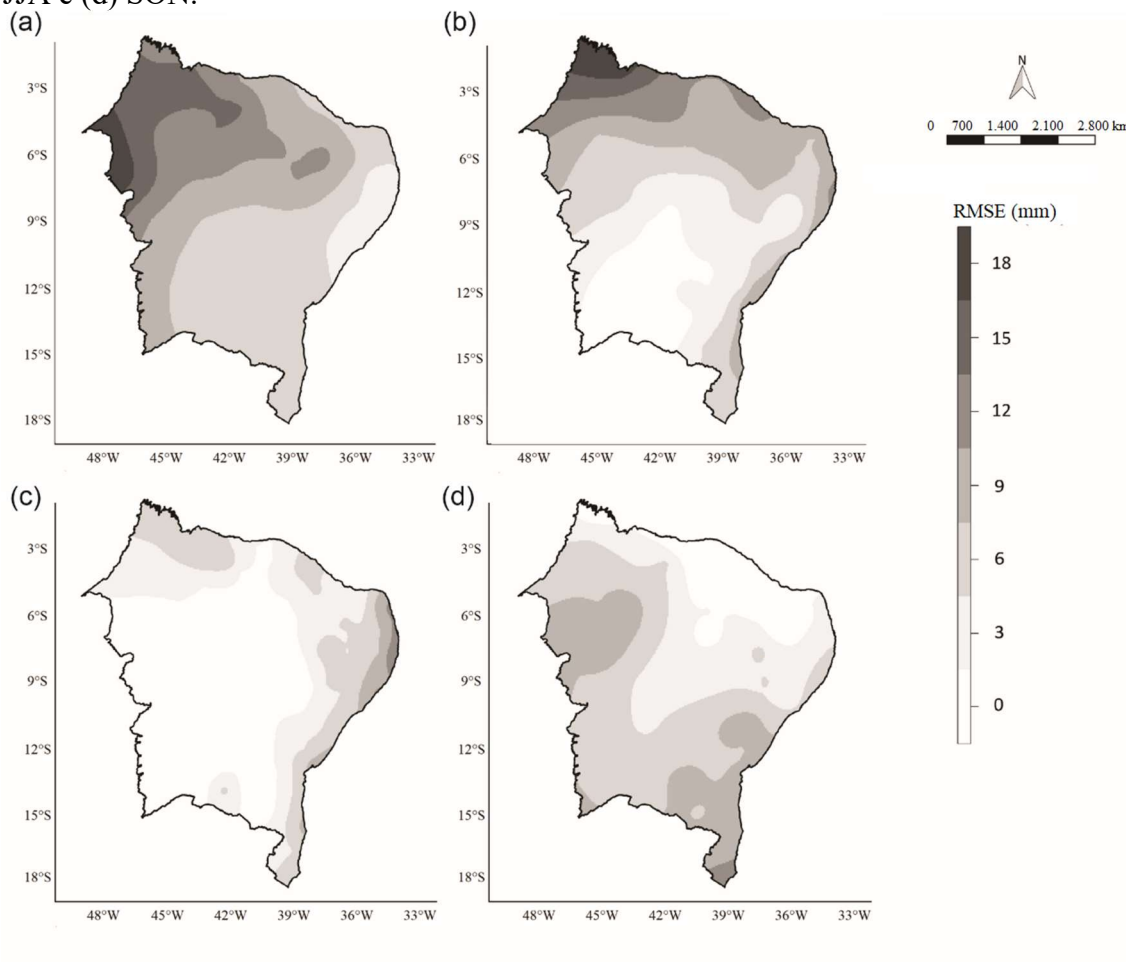
Figura 3.2. Distribuição espacial do viés por período sazonal, (a) DJF, (b) MAM, (c) JJA e (d) SON.



Os valores de RMSE (Figura 3.3) estão em torno de 0,0 mm e 18,0 mm. Os valores mais altos, de 9,0 mm a 18,0 mm, estão presentes nos períodos DJF e MAM, respectivamente, nas regiões noroeste e norte do NEB. Por sua vez, no período JJA, os valores de RMSE são próximos de zero na maioria das regiões do NEB, embora valores mais altos tenham sido calculados especialmente no leste do NEB. Finalmente, no período

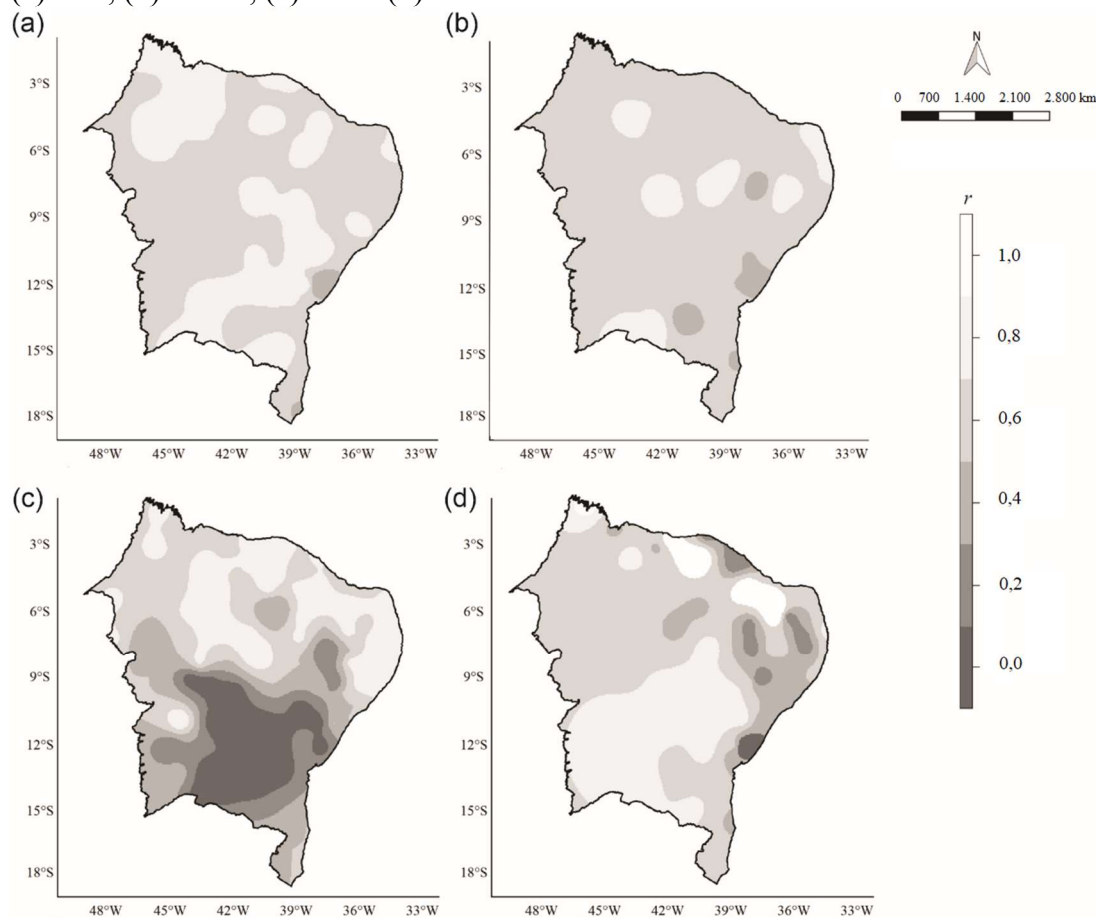
SON, são encontrados baixos valores de RMSE na região nordeste do NEB, enquanto as outras regiões apresentam variações entre 6,0 mm e 12,0 mm.

Figura 3.3. Distribuição espacial do RMSE por período sazonal, (a) DJF, (b) MAM, (c) JJA e (d) SON.



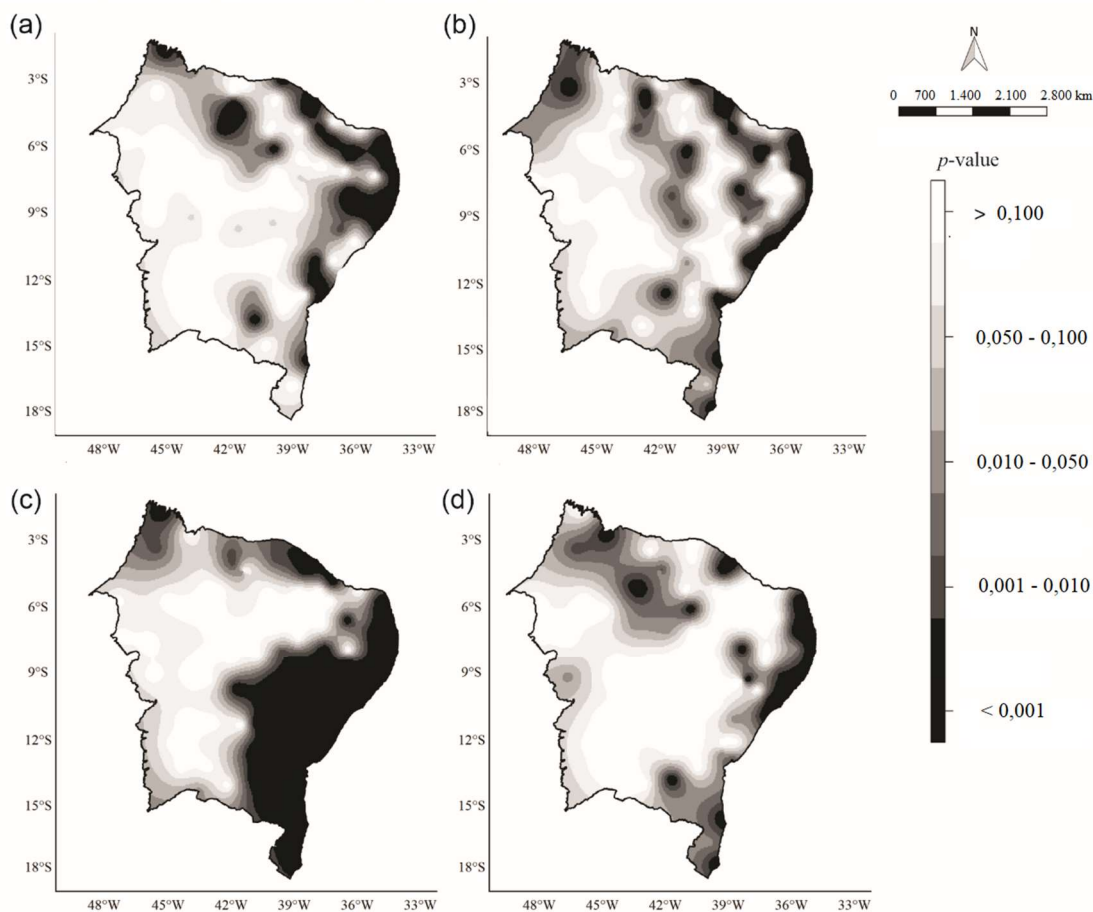
Assim como os valores de viés e RMSE, os coeficientes de correlação variam de acordo com a região e o período sazonal em que a precipitação ocorre (Figura 3.4). Nos períodos DJF e MAM, os valores do coeficiente de correlação são satisfatórios na maioria das regiões NEB, entre 0,6 mm e 0,8 mm. Nos períodos JJA e SON, os valores são mais baixos, principalmente no sul e nordeste do NEB. Em geral, os resultados observados pelas estatísticas descritivas são semelhantes aos relatados anteriormente observados por outros pesquisadores, de que as estimativas de produtos de satélite tendem a subestimar a intensidade da precipitação, principalmente nos períodos chuvosos de cada região (Yin et al., 2008; Vila et al., 2009; Chen et al., 2013; Gaona et al., 2016; Paredes-Trejo et al., 2017; Islam, 2018; Beaufort et al., 2019).

Figura 3.4. Distribuição espacial do coeficiente de correlação ( $r$ ) por período sazonal, (a) DJF, (b) MAM, (c) JJA e (d) SON.



O  $p$ -value associado ao teste t pareado realizado para cada período sazonal foi utilizado para avaliar a qualidade das estimativas da precipitação diária acumulada de NEB (Figura 3.5). Em geral, as estimativas diárias de precipitação do satélite foram estatisticamente iguais ( $p$ -value > 0,05) às observadas pelos pluviômetros em todos os períodos sazonais, exceto na costa leste do NEB, especialmente no inverno austral, que é o período chuvoso nessa região.

Figura 3.5. Distribuição espacial do  $p$ -value, resultante do teste t pareado por período sazonal, (a) DJF, (b) MAM, (c) JJA e (d) SON.

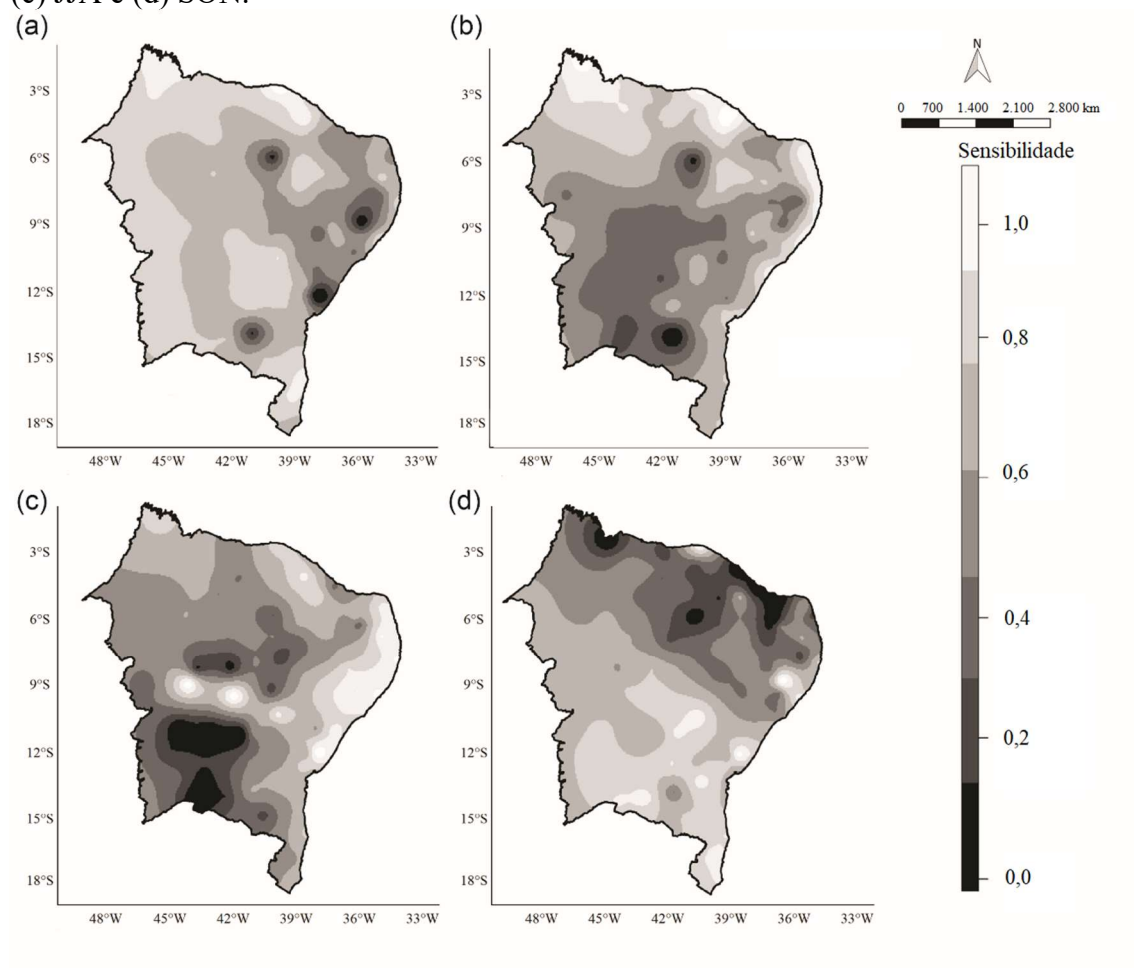


O fraco desempenho do 3B42 V7 no litoral NEB pode estar associado à alta frequência de nuvens quentes nesta região. De acordo com Palharini e Vila (2017), a costa leste do NEB é caracterizada por chuvas convectivas rasas ao longo do ciclo anual, principalmente nos meses de JJA, e é frequentemente associada à EWD, conforme descrito por Gomes et al. (2015). Hobouchian et al. (2017) afirmam que uma das limitações das estimativas de precipitação por satélite é subestimar a precipitação de nuvens quentes. O algoritmo passivo de microondas nem sempre captura a precipitação desse tipo de nuvem, pois muitas vezes não possui crescimento vertical suficiente para atingir temperaturas suficientemente baixas e, conseqüentemente, não produz valores de espalhamento em altas frequências devido à ausência de gelo.

A sensibilidade (Figura 3.6) representa a capacidade do satélite para estimar com precisão a presença de precipitação em um determinado dia. É importante afirmar que os dados de precipitação observados pelas estações meteorológicas foram considerados verdadeiros. A Figura 3.6 mostra uma grande variação espacial e temporal

nos valores de sensibilidade. No geral, os resultados são satisfatórios, com valores de sensibilidade superiores a 0,7. Os piores resultados foram próximos à costa leste no verão austral, no sudoeste no outono e inverno austral e na região norte durante a primavera austral. Esses resultados são semelhantes ao período em que cada sub-região NEB apresentou, em média, a menor precipitação (Barbosa et al., 2006). Também é importante observar que a costa do NEB apresentou altas magnitudes para os valores de sensibilidade no inverno austral. Isso significa que, embora o satélite não consiga estimar corretamente a intensidade da precipitação (Figura 3.5), é capaz de estimar sua presença.

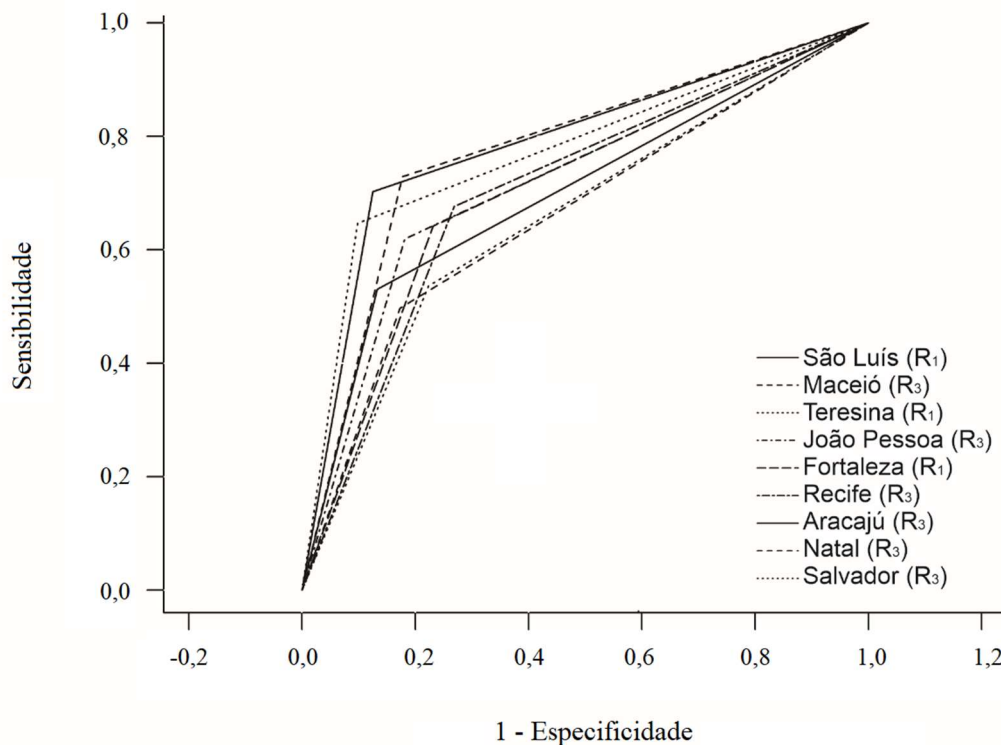
Figura 3.6. Distribuição espacial da sensibilidade por período sazonal, (a) DJF, (b) MAM, (c) JJA e (d) SON.



A combinação de probabilidades, sensibilidade e 1 - especificidade pode ser observada pela curva ROC, Figura 3.7, que mostra que quanto mais próximo o ponto se aproxima do canto superior esquerdo do gráfico, melhor a capacidade do satélite em estimar corretamente os dias com presença ou ausência de precipitação. Bons resultados são observados nas capitais do NEB, principalmente em São Luís e Teresina, localizadas na região norte, e Maceió, na costa leste do NEB.



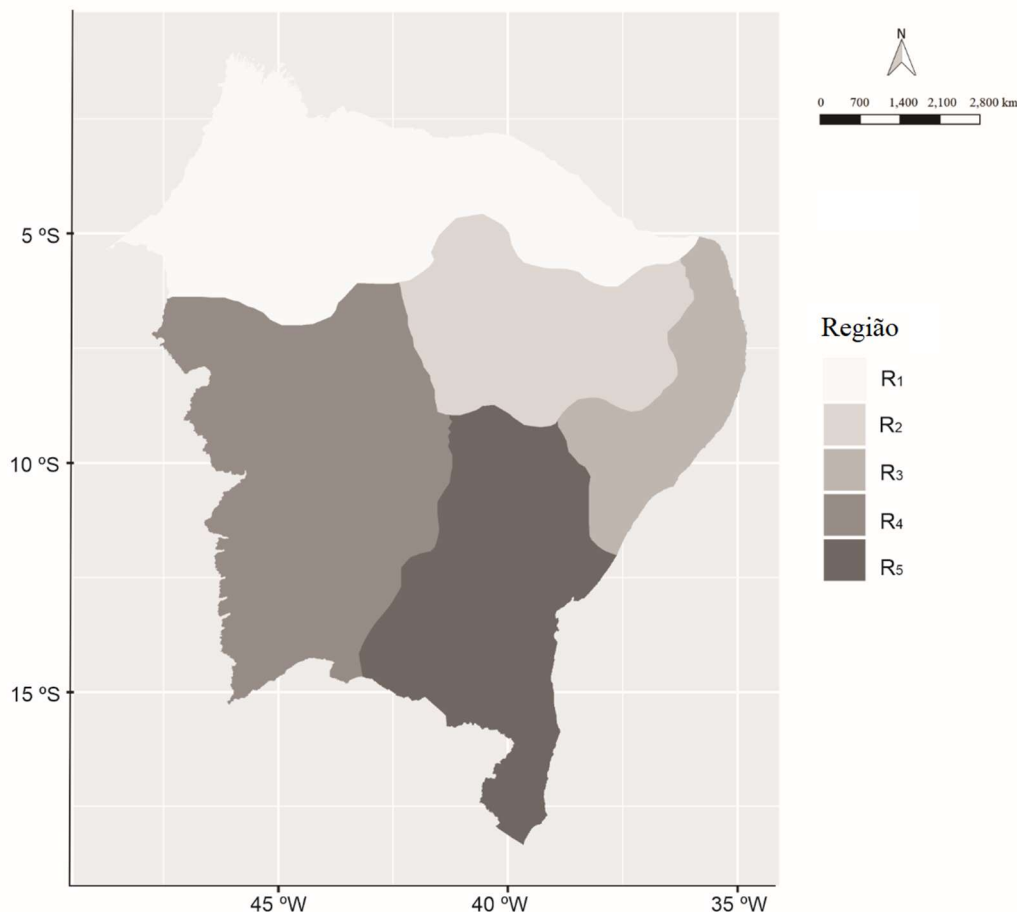
Figura 3.7. Curvas ROC para capitais NEB.



A análise de *cluster* determinou a divisão de cinco sub-regiões pluviométricas homogêneas no NEB (R1, R2, R3, R4 e R5), como mostra a Figura 3.8. A sub-região R1 compreende o NEB do norte, esta possui a ITCZ e o SCM como os sistemas meteorológicos causadores de chuvas mais frequentes na região. A sub-região R2 é caracterizada por baixos valores de precipitação anual, gerados basicamente pela extensão dos sistemas que ocorrem nas sub-regiões R1 e R3, a sub-região R3 faz parte da costa leste do NEB. A precipitação desta área é influenciada principalmente pela EWD. As sub-regiões R4 e R5 compreendem o sudoeste e sudeste do NEB, respectivamente, suas chuvas são influenciadas, principalmente, pela presença da SACZ e FS. Essa configuração se assemelha principalmente às sub-regiões R1 e R3, conforme definidas por Palharini e Vila (2017), que dividiram o NEB em quatro regiões de acordo com o regime de precipitação e a prevalência de sistemas meteorológicos. As sub-regiões R4 e R5 foram semelhantes às encontradas por Oliveira et al. (2016), que utilizaram os valores médios mensais de precipitação no NEB para a aplicação da análise de *cluster*. A

diferença entre este estudo e outros pode estar relacionada ao fato de termos utilizado a precipitação acumulada diariamente.

Figura 3.8. Representação da regionalização do NEB de acordo com a precipitação diária.

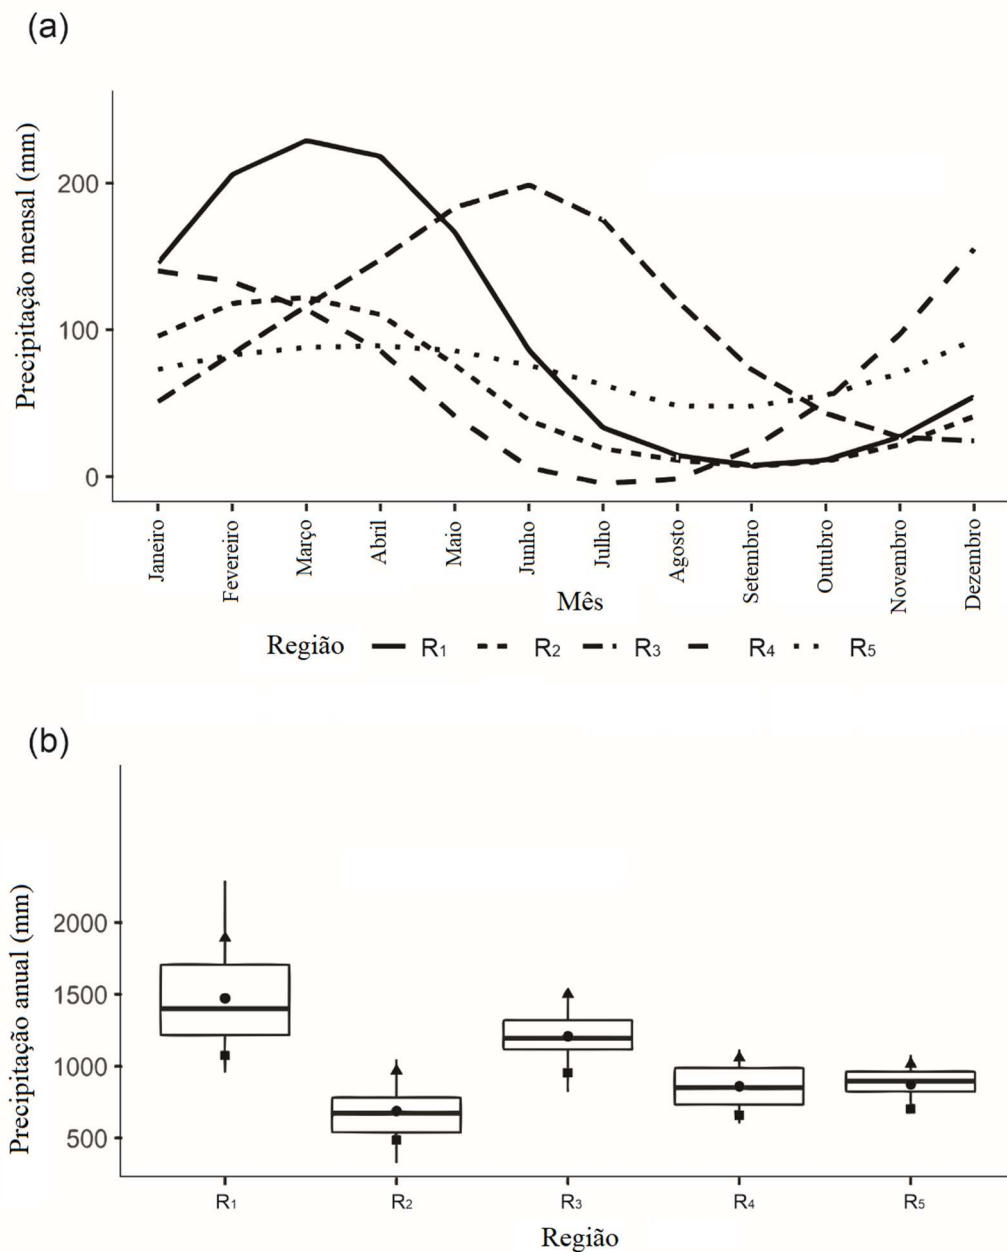


A estação chuvosa na sub-região R1 ocorre entre os meses de fevereiro e maio, enquanto nas sub-regiões R2, R4 e R5 as chuvas ocorrem principalmente durante o período de dezembro a março, e na sub-região R3 a estação chuvosa ocorre de abril a julho, Figura 3.9 (a). Resultados análogos foram descritos por Kousky (1979); Moura e Schukla (1981) e Oliveira et al. (2017), que identificaram maiores chuvas em março e abril no norte, entre dezembro e março no sudoeste e entre abril e julho na costa leste do NEB.

As sub-regiões com maior precipitação anual são R1 e R3, sendo R1 com a maior variabilidade anual, Figura 3.9 (b). A sub-região R2, que é parcialmente semiárida, tem a menor precipitação anual, em média cerca de 650,0 mm. Esses resultados são

semelhantes aos apresentados por Kousky (1979) e Zhou e Lau (2001), que descreveram o interior e o litoral do NEB como regiões que apresentam, respectivamente, as menores e maiores acumulados anuais de precipitação.

Figura 3.9. (a) Dispersão da precipitação (mm) por mês em cada região. (b) *Boxplot* da precipitação anual (mm) em cada sub-região. O círculo preenchido representa a precipitação média anual, o triângulo e o quadrado representam os valores dos percentis 90 e 10, respectivamente.



Além da média e variabilidade da precipitação acumulada anual, o *boxplot* mostra os percentis 10 e 90 da distribuição acumulada anual de precipitação em cada sub-região NEB. Os valores desses percentis variam de acordo com cada sub-região do NEB. Por exemplo, o 10º percentil da sub-região R1, 1.075,4 mm por ano, é maior que o 90º das sub-regiões R2, R4 e R5, respectivamente 968,0 mm, 1.058,2 mm e 1.015,9 mm por ano. Este resultado destaca a importância de avaliar as estimativas de satélite da precipitação extrema para cada sub-região do NEB. Estudos que consideram diferentes regimes de precipitação obtêm resultados mais detalhados de suas avaliações (Salio et al., 2015).

A precipitação média diária registrada pelas estações pluviométricas varia de acordo com o período e o local em que ocorre (Tabela 3.2). Nos períodos DJF e MAM, as sub-regiões R1, R2 e R4 apresentaram as maiores médias diárias, variando de 10,5 mm a 12,9 mm, enquanto as sub-regiões R3 e R5 apresentaram as menores, entre 7,0 mm e 9,7 mm. O desvio padrão nesses períodos variou entre 12,5 mm e 17,7 mm. Na JJA, as sub-regiões R1 e R3 apresentaram as maiores médias diárias, respectivamente 7,3 mm e 8,3 mm. No período SON, a média diária mais alta e mais baixa foram 11,4 mm e 4,6 mm, respectivamente, nas sub-regiões R4 e R3. Os resultados apresentados na Tabela 3.2 corroboram os resultados observados anteriormente, Figura 3.9 (a) - (b), em que o comportamento da precipitação em cada sub-região NEB é diferente.

Tabela 3.2 Média diária e desvio padrão da precipitação extrema por período sazonal e sub-região NEB.

Sub-região	Média (SD) da precipitação por período sazonal (mm)			
	DJF	MAM	JJA	SON
R1	12,1 (17,7)	12,9 (17,2)	7,3 (11,4)	6,4 (12,0)
R2	11,5 (16,9)	10,5 (16,2)	4,8 (8,5)	6,5 (13,2)
R3	7,0 (13,0)	9,7 (15,6)	8,3 (14,4)	4,6 (9,3)
R4	12,9 (16,7)	10,9 (15,2)	3,6 (7,0)	11,4 (16,1)
R5	9,1 (14,7)	7,3 (12,5)	4,3 (7,1)	6,9 (12,9)

As medidas descritivas, viés e RMSE, da comparação entre os dados diários derivados de pluviômetros e satélites para as cinco sub-regiões NEB por período sazonal, são semelhantes às encontradas na literatura (Huffman et al., 2007; Franchito et al. 2009). Em todas as estações, o viés é baixo, com um máximo de 4,8 mm e o mínimo próximo de zero (valores do módulo). Os valores de viés que excederam 1,0 mm foram negativos (-1,9 mm, -4,9 mm e -1,7 mm), respectivamente, provenientes de R3 em MAM e JJA e

R5 em JJA. Esses resultados estão de acordo com os mencionados anteriormente, de que o satélite tende a subestimar, em média, dados *in situ*, principalmente na sub-região R3. Autores como Huffman et al. (2007), Franchito et al. (2009) e Vila et al. (2009) também afirmaram que as estimativas de precipitação estão subestimadas na costa leste do NEB.

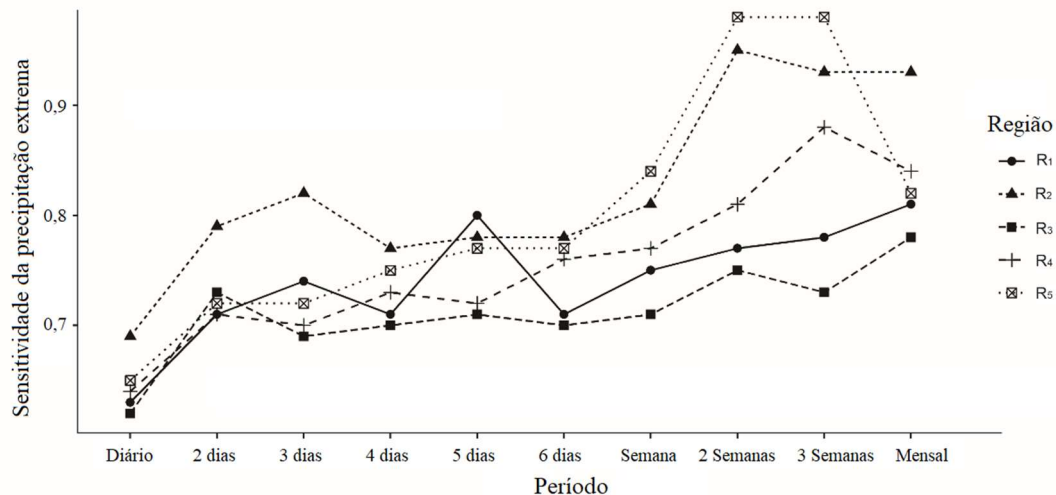
Os valores de RMSE variaram entre 1,0 mm e 17,1 mm. Eles foram estatisticamente significantes (valor de  $p < 0,05$ ). Os menores valores de RMSE na maioria das regiões foram encontrados no inverno e primavera austral. Melo et al. (2015) encontraram valores semelhantes de viés (menor que 5,0 mm) e RMSE (menor que 8,0 mm) em relação à precipitação diária para diferentes períodos sazonais no NEB, mas não consideraram a variabilidade espacial presente no NEB.

### 3.3.2 Precipitação extrema

Para análise dos extremos de precipitação, se acumulou a chuva em outras escalas de tempo além da diária, como: 2, 4, 5, 6, 7, 14, 21 e 30 dias. Cada período dentro de cada sub-região do NEB tem uma distribuição de dados diferente, portanto, um limiar diferente (percentil 95). Por exemplo, os limiares diários para cada sub-região são 43,8 mm, 39,2 mm, 32,2 mm, 44,0 mm e 29,1 mm, e os limiares para os dados acumulados a cada seis dias são 60,6 mm, 50,7 mm, 49,9 mm, 48,4 mm, 48,4 mm, respectivamente para R1, R2, R3, R4 e R5.

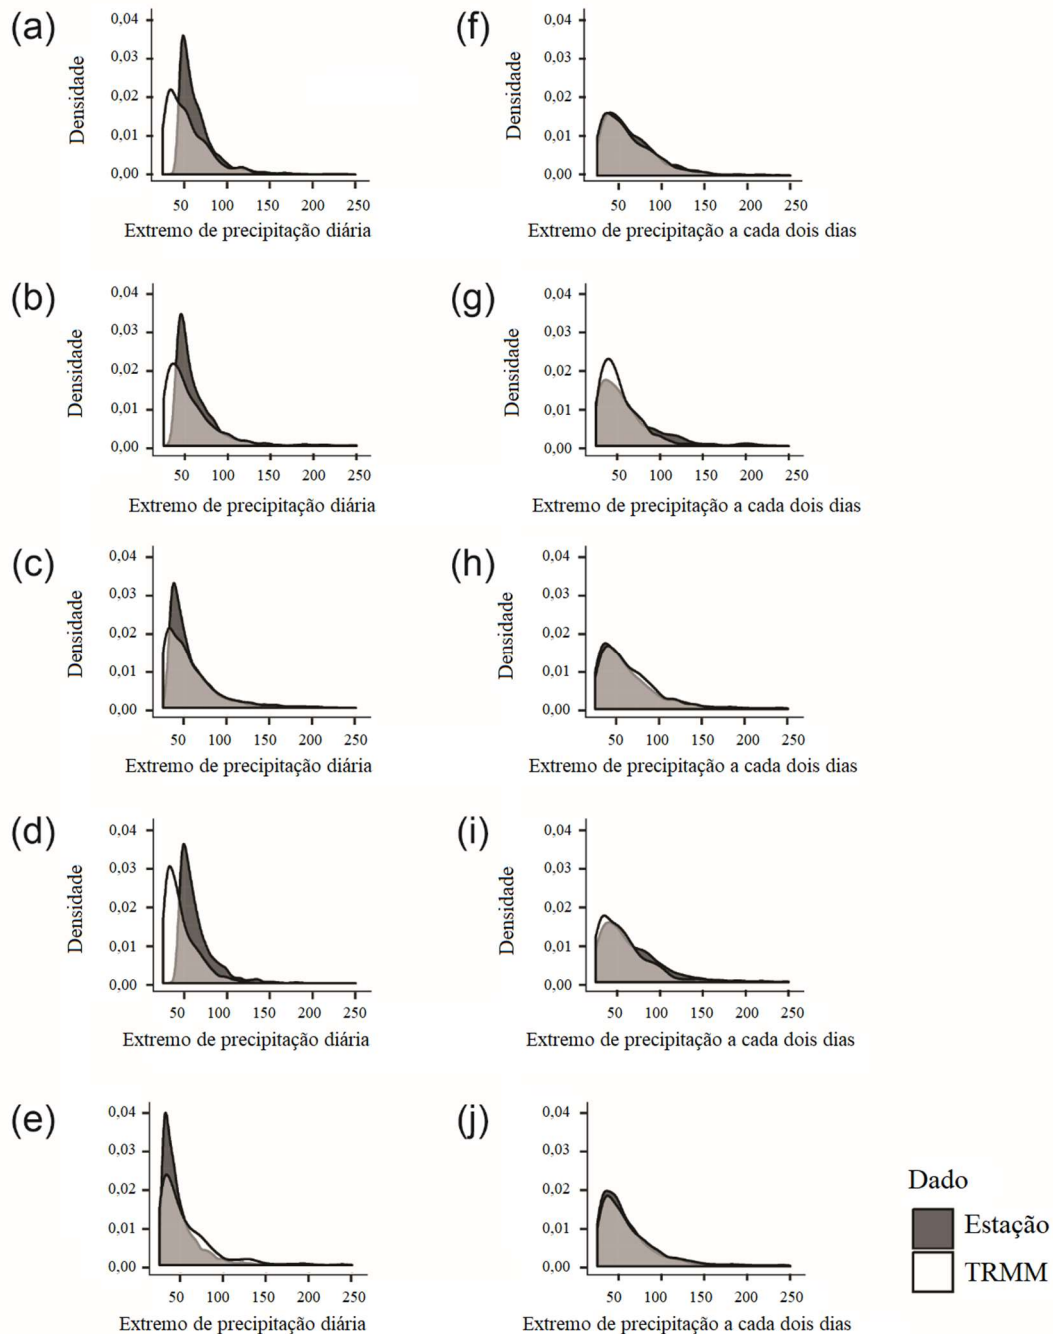
Os valores de sensibilidade, Figura 3.10, calculados para a precipitação diária extrema foram inferiores a 0,7 em todas as sub-regiões. Isso indica que as estimativas do satélite TRMM não são boas o suficiente para estudar extremos diários de precipitação no NEB. Essa descoberta é semelhante às apresentadas por Jiang et al (2017) e Hermance e Sulieman (2018), que afirmaram que as estimativas de precipitação extrema de 3B42 V7 não são confiáveis na região do Mar Circum-Bohai na China e no sudeste do Sahel da África, respectivamente. Apesar deste resultado, quando a escala de tempo do banco de dados foi aumentada, a capacidade do satélite de estimar corretamente a presença de precipitação acumulada extrema também aumentou (Figura 3.10). O satélite TRMM é capaz de representar a precipitação acumulada extrema em uma escala de tempo de dois dias (valores de sensibilidade  $> 0,7$ ) para todas as sub-regiões NEB.

Figura 3.10. Sensibilidade dos valores extremos de precipitação para cada sub-região em diferentes escalas de tempo: diária, a cada dois, três, quatro, cinco, seis dias, semanalmente, a cada duas e três semanas e mensalmente.



Além da análise de sensibilidade, as distribuições de densidade para a precipitação extrema (diária e a cada dois dias) foram plotadas para cada sub-região (Figura 3.11 (a) - (b)). Pode-se observar que a densidade da distribuição dos valores extremos diários (Figura 3.11 (a)) para pluviômetros e conjuntos de dados TRMM são diferentes para todas as sub-regiões NEB. Além disso, as curvas de densidade para o banco de dados TRMM são alteradas para valores mais baixos em comparação com as curvas de densidade do pluviômetro. Esses resultados são semelhantes aos descritos por Jiang et al. (2017), que afirmaram que o algoritmo 3B42 V7 tende a subestimar os extremos diários de precipitação. Esse comportamento ocorreu em todas as sub-regiões, sugerindo, mais uma vez, que os dados de satélite TRMM não são uma boa opção para estudar extremos diários. No entanto, as densidades das distribuições de valores extremos da precipitação acumulada a cada dois dias, tanto dos pluviômetros quanto do satélite, são próximas em todas as sub-regiões NEB (Figura 3.11 (b)).

Figura 3.11. Densidade dos valores extremos de precipitação diária por região de NEB, (a) R1, (b) R2, (c) R3, (d) R4 e (e) R5 e densidade de valores extremos de precipitação a cada dois dias por região de NEB, (f) R1, (g) R2, (h) R3, (i) R4 e (j) R5.



A Tabela 3.3 mostra que os valores de viés entre as estimativas de satélite e os dados de precipitação extrema dos pluviômetros são negativos, com valores de RMSE entre 25,4 mm e 31,5 mm. Autores como Yin et al. (2008), Vila et al. (2009), Chen et al. (2013), Gaona et al. (2016) e Paredes-Trejo et al. (2017) também observaram que as estimativas de satélite tendem a subestimar altos valores de precipitação diária.

Quadro 3.3 Valores de viés, RMSE e coeficiente de correlação ( $r$ ) entre as estimativas de satélite e observadas pelos pluviômetros para acumulados diários e a cada dois dias da precipitação extrema, discriminados por sub-regiões NEB.

Sub-região	Extremo de precipitação diário (mm)			Extremo de precipitação a cada dois dias (mm)		
	Viés	RMSE	$r$	Viés	RMSE	$r$
R <sub>1</sub>	-16,2	31,5	0,3	-5,7	27,0	0,4
R <sub>2</sub>	-9,2	27,3	0,4	-1,5	23,8	0,5
R <sub>3</sub>	-23,1	34,0	0,4	-17,6	30,0	0,5
R <sub>4</sub>	-13,6	25,4	0,3	-4,1	21,8	0,5
R <sub>5</sub>	-13,0	29,1	0,3	-8,5	25,5	0,4

Em média, as estimativas de satélite subestimaram os valores extremos diários em 16,2 mm, 9,2 mm, 23,1 mm, 13,6 mm e 13,0 mm, respectivamente, para as sub-regiões R1, R2, R3, R4 e R5. No entanto, quando a precipitação extrema foi delimitada a partir do acúmulo de precipitação a cada dois dias, as estimativas de satélite tenderam a subestimar os quantitativos das chuvas extremas em menor extensão, em média 5,7 mm, 1,5 mm, 17,6 mm, 4,1 mm e 8,5 mm, respectivamente para o R1, R2, R3, R4 e R5, com RMSE variando de 21,8 mm a 30,0 mm (Tabela 3.3). Além do declínio considerável do viés, os valores de RMSE também diminuíram. Os valores dos coeficientes de correlação são maiores que os valores extremos diários para todas as sub-regiões NEB. Esses resultados corroboram com os observados anteriormente, Figura 3.10 e Figura 3.11 (a) - (b).

Os resultados estatísticos referentes à avaliação dos valores extremos diários de precipitação do TRMM são semelhantes aos observados por Islam et al. (2015). Esses autores concluíram que nenhum dos conjuntos de dados de precipitação por satélite estudados em suas análises (produtos PERSIANN, CMORPH, IMERG e GPM) é ideal para detectar precipitações diárias extremas. De acordo com Timmermans et al. (2019), o uso generalizado de estimativas de produtos por satélite e o aumento do número de estudos em precipitações extremas motivam novas pesquisas que investigam a incerteza dessas estimativas. Eles enfatizaram a necessidade de cautela ao empregar estimativas de produtos de satélite para análises de eventos extremos de precipitação diária.

### 3.4 Conclusões

O objetivo deste trabalho foi avaliar os dados diários de precipitação e precipitação extrema estimados pelo produto TRMM 3B43 em comparação com os dados



coletados *in situ* por meio de pluviômetros. Os resultados deste estudo são relevantes para os pesquisadores que desejam trabalhar com os dados de precipitação do satélite TRMM no NEB. Foi possível analisar a confiabilidade dos dados de satélite para precipitação diária acumulada e extrema, considerando a variabilidade temporal e espacial do NEB.

Este estudo encontrou diferenças na qualidade das estimativas de satélite para NEB, que varia espacial e temporariamente. Em geral, as estimativas diárias de precipitação do TRMM são estatisticamente iguais às observadas nos dados do pluviômetro, exceto na costa leste do NEB, devido à alta frequência de nuvens quentes na região, que ocorre especialmente no período chuvoso (inverno austral) da região. Apesar desse resultado, a análise de sensibilidade mostrou que o satélite é capaz de capturar a presença de precipitação na costa leste do NEB, mesmo subestimando sua intensidade.

Foi possível dividir o NEB em cinco sub-regiões de acordo com a precipitação diária. Essas sub-regiões diferem daquelas usadas por outros pesquisadores, que geralmente usam a climatologia mensal para definir suas sub-regiões. Esse resultado é extremamente importante, principalmente para pesquisadores que desejam trabalhar com dados diários de regiões homogêneas, uma vez que as sub-regiões aqui definidas caracterizam a variabilidade espacial presente no NEB de acordo com os dados diários. Além disso, os padrões mensais e anuais de precipitação foram avaliados para cada sub-região. Essas avaliações são semelhantes às encontradas na literatura. Os valores de viés, desvio padrão, MSE e RMSE entre os conjuntos de dados TRMM e pluviômetro foram baixos para todas as sub-regiões NEB.

Em relação aos dados extremos, o satélite não apresentou boas estimativas de precipitação diária extrema; portanto, elas não são recomendadas para pesquisas envolvendo extremos diários em todas as sub-regiões NEB. No entanto, quando a escala de tempo dos dados foi aumentada, a confiabilidade dos dados de precipitação extrema estimados pelo satélite em todas as sub-regiões também aumentou. A precipitação acumulada por dois dias é suficiente para obter melhores resultados com relação às estimativas de precipitação extrema provindas do satélite. Portanto, ao trabalhar com dados de precipitação extrema do satélite TRMM, a chuva acumulada por pelo menos dois dias deve ser usada. Este é um resultado inovador que ajudará os cientistas a usar os dados extremos do satélite TRMM para essa região escassa de dados.

Em geral, os resultados obtidos fornecerão aos usuários dos dados do produto 3B42 TRMM o conhecimento prévio sobre a qualidade das estimativas em relação à

ocorrência e precipitação diária acumulada, espacialmente e sazonalmente, no NEB. Os usuários interessados em estudar a precipitação extrema podem escolher o melhor número de dias para acumular a precipitação com os dados de satélite TRMM, com um entendimento prévio da qualidade dos dados, que também depende de cada sub-região NEB.

## CAPÍTULO 4

### SPATIAL DISTRIBUTION OF THE LEVEL OF RETURN OF EXTREME PRECIPITATION EVENTS IN NORTHEAST BRAZIL

(Distribuição espacial do nível de retorno dos eventos de precipitação extrema no  
Nordeste do Brasil)

Em revisão na International Journal of Climatology - qualis CAPES: A1 - Geociências.  
Fator de impacto: 3.601.

#### RESUMO

O objetivo deste estudo foi estimar os níveis de retorno dos eventos extremos de precipitação diária, associando-os aos desastres naturais ocorridos no Nordeste do Brasil (NEB), região caracterizada por diferentes condições climáticas e baixas taxas de desenvolvimento socioeconômico. Para isso, foram ajustados modelos *Generalized Pareto Distribution* (GPD) aos dados de precipitação diários extremos estimados pelo satélite *Tropical Rainfall Measuring Mission* (TRMM), por meio do produto 3B42 do TRMM *Multisatellite Precipitation Analysis* (TMPA) para um período de 16 anos (2000 a 2015). Além disso, as estimativas do modelo GPD foram comparadas usando duas fontes de dados, TRMM e pluviômetro. A investigação mostrou que os resultados do modelo GPD estimado por meio dos dados de precipitação extremas provindos do pluviômetro e do TRMM foram estatisticamente iguais, com 95% de confiança. Assim, utilizando os dados referentes aos 2.082 pontos da grade do TRMM, foi possível mapear a distribuição espacial das estimativas dos níveis de retorno de precipitação extrema para os períodos de retorno de 2, 5 e 10 anos, por período sazonal. Em geral, os resultados indicaram que a intensidade da precipitação extrema esperada depende do período sazonal e do local de ocorrência da precipitação. O leste do NEB se destacou como a região onde as maiores intensidades de precipitação extrema são esperadas. Valores extremos de precipitação de até 178 mm são esperados em dois anos. As áreas onde ocorreram desastres naturais nos anos de 2016, 2017 e 2018 são semelhantes àquelas em que as maiores intensidades de precipitação são esperadas. Os resultados deste estudo podem permitir a avaliação da distribuição espacial de riscos relacionados a eventos extremos de precipitação e, portanto, apoiar o planejamento de políticas públicas regionais e a gestão ambiental para a prevenção de desastres naturais no NEB.

Palavras-chave: Precipitação diária; *Generalized Pareto Distribution*; TRMM; Desastres naturais.

## ABSTRACT

This study aimed to estimate levels of return of extreme daily precipitation events, associating them with natural disasters in Northeast Brazil (NEB), a region characterized by different climatic conditions and low rates of social and economic development. For this, generalized Pareto distribution (GPD) models were adjusted to the daily extreme precipitation data estimated by the Tropical Rainfall Measuring Mission (TRMM) 3B42 product of the Multisatellite Precipitation Analysis (TMPA) for a period of 16 years (2000 to 2015). In addition, the estimates of the GPD model were compared using two data sources, TRMM and pluviometer. The investigation showed that the results of the GPD model estimated by means of the extreme data from the rain gauge and the TRMM were statistically the same, with 95% confidence. Thus, using the data referring to the 2,082 grid points of the TRMM, it was possible to map the spatial distribution of the estimates of the levels of return of extreme precipitation to the return periods of 2, 5 and 10 years, per seasonal period. In general, the results indicated that the intensity of expected extreme precipitation depends on the seasonal period and the place of occurrence of precipitation. The eastern NEB stood out as the region where the highest intensities of extreme precipitation are expected. Extreme precipitation values of up to 178 mm are expected in two years. The areas where natural disasters occurred in the years 2016, 2017 and 2018 are similar to those in which the highest rainfall intensities are expected. The results of this study can allow the evaluation of the spatial distribution of risks related to extreme precipitation events, and therefore, support the planning of regional public policies and environmental management for the prevention of natural disasters in NEB.

Keywords: Diaries precipitation; Generalized Pareto Distribution; TRMM; Natural Disaster.

## 4.1 Introdução

Eventos climáticos extremos são um dos principais tópicos estudados relacionados às mudanças climáticas. Projeções futuras divulgadas pelo Painel Intergovernamental de Mudanças Climáticas (IPCC) mostram que esses eventos se tornarão cada vez mais frequentes e intensos em várias regiões do mundo, inclusive em áreas do Nordeste do Brasil (Du et al., 2019). Eventos climáticos extremos podem causar ondas de calor e frio, inundações, deslizamentos de terra, secas, entre outros.

Mudanças no comportamento de eventos extremos de precipitação podem ter implicações significativas para a sociedade humana e o meio ambiente (Marengo e Espinoza, 2016; Demirdjian et al., 2018). Estudos apontam para um aumento geral na frequência e intensidade desses eventos (Min et al., 2011; Donat et al., 2016). Nesse contexto, os modelos de sistemas climáticos projetam aumentos de  $2,7^{\circ}\text{C}$  na temperatura média da superfície dos oceanos tropicais, o que pode causar um aumento de até 60% na frequência de eventos extremos de chuvas (Aumann et al., 2018).

O Quinto Relatório de Síntese sobre Mitigação das Mudanças Climáticas do Painel Intergovernamental sobre Mudanças Climáticas (IPCC) projetou um aumento da temperatura média global de  $1,5^{\circ}\text{C}$  para  $4,8^{\circ}\text{C}$  até o ano 2100 (IPCC-AR5, 2012). No Brasil, de acordo com o Painel Brasileiro de Mudanças Climáticas (PBMC), o aumento de temperatura até 2100 estará entre  $0,5^{\circ}\text{C}$  e  $6,0^{\circ}\text{C}$  (PBMC, 2013), o que pode causar um aumento na frequência e intensidade de eventos extremos de precipitação. Esse aumento pode interferir em eventos causados por déficit ou excesso de chuva, como secas, inundações, entre outros.

Os eventos extremos mais frequentes no Brasil são secas, inundações e deslizamentos de terra. Esses eventos geram impactos socioambientais, principalmente em grandes áreas urbanas. Esses impactos estão fortemente relacionados à maior exposição da população aos riscos, levando ao aumento da vulnerabilidade. A urbanização descontrolada das grandes cidades contribui ainda mais para o aumento desses impactos (Kobiyama et al., 2006; Vestena, 2008), que afetam principalmente as populações mais vulneráveis (Kates 2000, IPCC 2002).

A região Nordeste do Brasil (NEB) é vulnerável às mudanças climáticas devido às suas condições fisiográficas e climáticas e aos baixos índices de desenvolvimento socioeconômico (PBMC, 2013). Segundo a Síntese de Indicadores Sociais (SIS), o NEB é a região do Brasil que possui a maior proporção (46,5%) de pessoas vivendo na pobreza,

equivalente a 25,5 milhões de pessoas (SIS-IBGE, 2018). Com clima equatorial, tropical e semi-árido, o NEB apresenta alta variabilidade temporal e espacial de precipitação (Moura e Schukla, 1981; Zhou e Lau, 2001; Oliveira et al., 2017), com precipitação anual acumulada variando de 480 mm a 2.250 mm (Oliveira et al., 2017).

Portanto, é necessário desenvolver pesquisas que ajudem a entender como esses eventos se comportam ao longo do tempo, além de prever a probabilidade de ocorrência destes eventos em intervalos regulares, considerando o período e localização de ocorrência do mesmo. Neste sentido, a *Extreme Value Theory* (EVT) tem sido frequentemente utilizada para modelar eventos climáticos extremos para estudos globais (Serinaldi e Kilsby, 2014) e estudos regionais, como no Canadá (Thiombiano et al., 2018), Finlândia (Pedretti e Irannezhad, 2018), China (Tu et al., 2017; Mo et al., 2018), Portugal (Santos et al., 2017a), Jacarta (Siswanto et al., 2016), Vietnã (Gobin et al., 2016), Coreia (Chen et al., 2016) e Estados Unidos (Heaton et al., 2011). No Brasil, a EVT tem sido usada para caracterizar a distribuição de extremos de chuva na cidade de São Paulo (Sugahara et al., 2008), na Bacia Amazônica (Santos et al., 2015; Santos et al., 2016) e na cidade de Curitiba (Pedron et al., 2016).

Para aplicar a EVT em estudos que envolvam eventos climáticos extremos, é necessário ter acesso a séries de dados históricos em escala diária. Além disso, é necessário que a série de dados seja precisa e tenha alta resolução espacial e temporal (Sorin et al., 2005; Yong et al., 2010; Kucera et al., 2013; Fang et al., 2019). No entanto, a escassez de redes pluviométricas densas é comum em muitos países em desenvolvimento (Suh et al., 2008, Behrangi et al., 2011, Katiraie-Boroujerdy et al., 2013 e Salio et al., 2014). No Brasil, a escassez, má distribuição espacial e (em alguns casos) a baixa qualidade dos dados diários de precipitação apresentam problemas para a realização de estudos sobre extremos climáticos (Marengo et al., 2007).

Uma alternativa para essa dificuldade é usar dados de satélites, que em geral apresentam uma melhor distribuição espacial e temporal em comparação às redes pluviométricas. Algoritmos baseados em medições feitas pelos satélites da Tropical Rainfall Measuring Mission (TRMM) e, mais recentemente, a iniciativa Global Precipitation Measurement (GPM), fornecem uma rica fonte de dados de precipitação em escala global (Demirdjian et al., 2018). A Análise de Precipitação Multissatélites (TMPA) da TRMM combina estimativas de precipitação de vários satélites para fornecer estimativas de precipitação a cada três horas com cobertura de 50,8 °S - 50,8 °N (Huffman et al., 2007).

Estudos envolvendo a modelagem de eventos climáticos extremos foram desenvolvidos através do uso de estimativas de satélite, como o estudo de Engel et al. (2017), que usaram estimativas de precipitação do TRMM e *Precipitation Estimation from Remotely Sensed Information Using Artificial Neural Networks-Climate Data Record* (PERSIANN-CDR) para estimar o período de retorno de eventos extremos de precipitação em duas áreas urbanas na África Ocidental. Nos EUA, Demirdjian et al. (2018) estimaram os períodos de retorno de extremos de precipitação por meio dos dados do produto 3B42 do satélite TRMM.

Muitos autores usaram estimativas de precipitação de produtos de satélite TRMM para estudar a distribuição de precipitação em regiões do Brasil. Exemplos são Santos et al. (2017b) e Santos et al. (2018), que investigaram, respectivamente, a variabilidade espacial e temporal do déficit de precipitação e as tendências das chuvas em dias úmidos e secos consecutivos na bacia do alto rio São Francisco, Zubietta et al. (2019), que estimaram o índice de concentração da porção diária na bacia amazônica; e Santos et al. (2019), que estudaram a variabilidade espaço-temporal da precipitação no estado da Paraíba, localizado no NEB.

No entanto, poucos estudos modelaram os valores extremos para cada ponto da grade em uma malha regular. Essa escolha pode permitir estimativas mais confiáveis dos períodos de retorno, especialmente para regiões com alta variabilidade espacial e temporal em suas características climáticas, como NEB, além de permitir uma análise rápida dos resultados, com maior nível de detalhe e maior representatividade espacial de a distribuição extrema da precipitação.

Diante do exposto, o objetivo deste estudo foi estimar o nível de retorno da precipitação extrema no NEB para cada ponto de uma rede regular, utilizando estimativas diárias de precipitação do produto 3B42 do satélite TRMM, para cada estação do ano, possibilitando construir mapas que apresentem espacialmente estimativas de chuvas extremas para os períodos de retorno de 2, 5 e 10 anos, por estação do ano. Estes foram associados a frequência de desastres naturais, como alagamentos, enxurradas, inundações e deslizamentos de terra, ocorridos no NEB. Além disso, os resultados obtidos pelo modelo *Generalized Pareto Distribution* (GPD) foram comparados usando dados diários de precipitação estimados pelo produto 3B42 do satélite TRMM e dados registrados por pluviômetros, por um período de 16 anos no NEB.

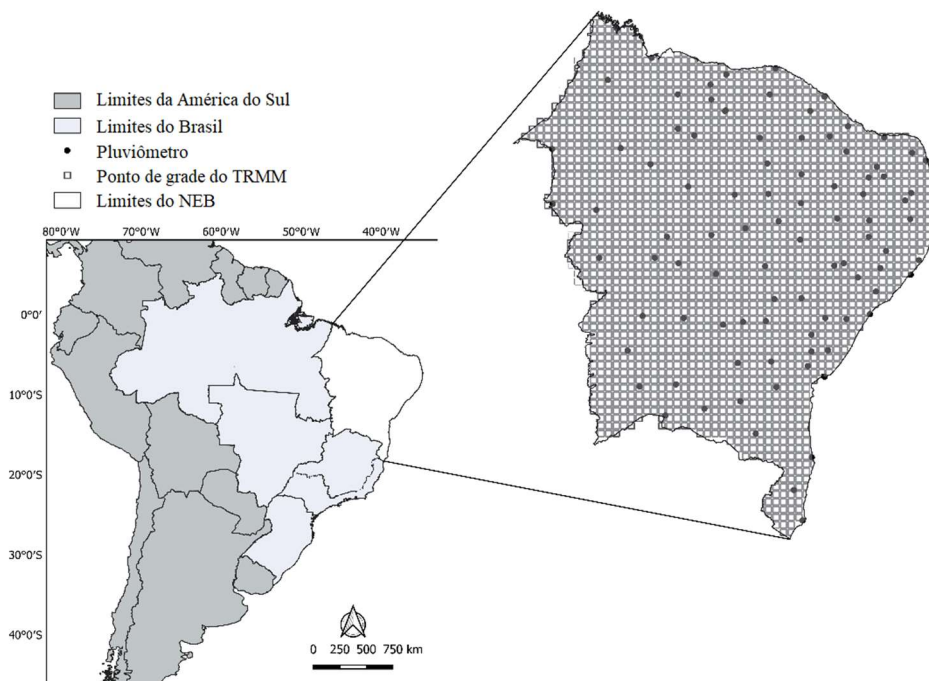
## 4.2 Material e métodos

### 4.2.1 Área de estudo

A área de estudo compreende a região NEB. Localizada entre 1 °N e 18 °S e 34,5 °W e 48,5 °W (Figura 4.1), o NEB é uma das cinco regiões do Brasil definidas pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Possui uma área de aproximadamente 1.558.196 km<sup>2</sup>, com uma população de 53.078.137 habitantes (IBGE, 2010).

A região é caracterizada por longos períodos de seca (Hastenrath e Heller, 1977; Moura e Schukla, 1981; Marengo et al., 2017, Silva et al., 2019), ocorrência de eventos extremos de precipitação (Oliveira et al., 2017 ; Da Silva et al., 2018), variabilidade sazonal da distribuição de precipitação (Valadão et al., 2017) e alta variabilidade sazonal e interanual da precipitação (Moura e Schukla, 1981; Zhou e Lau, 2001; Oliveira et al. 2017). A precipitação acumulada anual é inferior a 500 mm nas regiões semi-áridas, superior a 1.500 mm nas regiões costeiras e entre 1.000 mm e 1.200 mm no norte de NEB (Kousky e Chu, 1978; Rao et al., 2016).

Figura 4.1. Localização geográfica do Nordeste do Brasil.



A variabilidade da precipitação no NEB é influenciada pelos diferentes sistemas que ocorrem na região, como a *Intertropical Convergence Zone* (ITCZ) (Uvo, 1989;



Utida et al., 2019), *South Atlantic Convergence Zone* (SACZ) (Kodama, 1992; Zili et al., 2019), *Easterly Wave Disturbances* (EWD) (Torres and Ferreira, 2011; Gomes et al., 2019), *Upper Tropospheric Cyclonic Vortex* (UTCV) (Kousky and Gan, 1981; Fedorova et al., 2016) e *Squall Lines* (SL) (Kousky, 1980; Oliveira and Oyama, 2019). Além disso, a precipitação é influenciada pela variabilidade interanual da temperatura do Oceano Pacífico, associada a *El Niño Southern Oscillation* (ENSO) (Ropelewski e Halpert 1987; Marengo et al., 2017), e a variabilidade inter-anual das temperaturas do Oceano Atlântico (Bombardi et al., 2014; Rodrigues et al., 2015). A variabilidade de baixa frequência é modulada pela ação dos oceanos Atlântico e Pacífico (Andreoli e Kayano, 2007; Moura et al., 2009; Silva et al., 2019).

#### 4.2.2 Base de dados

Foram utilizadas três fontes de dados. A primeira foi provinda do Banco de Dados Meteorológicos de Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia do Brasil (INMET), disponível em <[www.inmet.gov.br](http://www.inmet.gov.br)>. O banco de dados contém informações diárias de precipitação (mm) observadas por pluviômetros distribuídos em 94 estações meteorológicas localizadas no NEB (Figura 4.1).

O segundo fornece estimativas de precipitação a cada três horas, com espaçamento horizontal de  $0,25^\circ$  (Kummerow et al., 1998; Huffman et al., 2007), o que limita a grade de satélites TRMM. Esta resolução foi usada neste estudo e é representada pela Figura 4.1. Obtido do produto 3B42 Versão 7 (3B42 V7), da TMPA Technique (Huffman et al., 2007), esse banco de dados é uma alternativa aos dados do pluviômetro, que geralmente contém falhas e baixa resolução espacial.

Como o objetivo do estudo era analisar valores extremos diários, além de comparar os resultados dessas análises usando duas fontes de dados, pluviômetro e 3B42 TRMM, tornou-se necessário converter as estimativas temporais a cada 3 horas do produto 3B42 TRMM em estimativas diárias, compatíveis com a amostragem dos dados do BDMEP. Ambas as bases de dados correspondem a um período de 16 anos, de 01/01/2000 a 31/12/2015.

A terceira fonte de dados é referente a informações sobre a ocorrências de desastres naturais no NEB durante um período de três anos e dois meses, de 01/01/2016 a 28/02/2019. Esse banco de dados é proveniente do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) e contém informações como o tipo de

evento (alagamento, enxurrada, inundação e deslizamento de terra), data, latitude, longitude e município em qual o desastre ocorreu.

#### 4.2.3 Métodos

As análises dos extremos de precipitação diária foram realizadas trimestralmente: DJF (dezembro, janeiro e fevereiro); MAM (março, abril e maio); JJA (junho, julho e agosto); SON (setembro, outubro e novembro).

Foi utilizada a *Extreme value theory* (EVT) (Fisher e Tippett, 1928), que é um método probabilístico usado para estudar o comportamento estocástico de valores extremos associados a uma função de distribuição, geralmente desconhecida. Aqui, as séries medidas por pluviômetros e estimadas por satélites foram modeladas pela Generalized Pareto Distribution (GPD).

A GPD pode ser modelada pela distribuição de valores máximos ou mínimos. Para modelagem da GPD, considera-se como valores extremos aqueles acima de um determinado limiar,  $u$ . Pickands (1975) introduziu a GPD como uma família de distribuições com dois parâmetros: forma ( $\xi$ ) e escala ( $\sigma$ ), onde  $u$  representa o limiar da distribuição. A função densidade do GPD é dada pela Equação (4.1):

$$g(x|\xi, \sigma, u) = \begin{cases} \frac{1}{\sigma} \left(1 + \xi \left(\frac{x-u}{\sigma}\right)\right)^{\frac{-(1+\xi)}{\xi}}, & \text{if } \xi \neq 0 \\ \frac{1}{\sigma} \exp\left\{-\left(\frac{x-u}{\sigma}\right)\right\}, & \text{if } \xi = 0 \end{cases}, \quad (4.1)$$

em que  $x - u > 0$  para  $\xi \geq 0$  e  $0 \leq x - u < -\sigma/\xi$  para  $\xi < 0$ .

A GPD pode ser interpretado como uma família de distribuições que dependem do valor do parâmetro shape: distribuição Beta, se  $\hat{\xi} < 0$ , *Pareto distribution* se  $\hat{\xi} > 0$ , e *exponential distribution* se  $\hat{\xi} \rightarrow 0$  (Han, 2003).

Os quantis da GPD podem ser usados para obter a estimativa do nível de retorno em  $t$  períodos de tempo (Abild et al., 1992; Palutikof et al., 1999). Para calcular, basta inverter a função acumulada de  $g(x|\xi, \sigma, u)$ , obtendo-se a Equação (4.2).

$$q_p = \frac{((1 - p^*)^{-\xi} - 1)\sigma}{\xi}, \quad (4.2)$$

em que  $p^* = 1 - (1 - p)N/N_u$ ,  $N$  é o número de observações dos dados originais e  $N_u$  é o número de observações acima do limiar.

O termo  $q_p$  é conhecido como o nível de retorno associado ao período  $1/p$ , ou seja, é o valor esperado que os dados originais excedem o valor  $q_p$  pelo menos uma vez a cada  $1/p$  períodos de tempo. Esses cálculos ajudam a prever em quantos períodos um evento extremo deve ocorrer.

A escolha do limiar,  $u$ , na modelagem GPD é semelhante à escolha do tamanho do bloco na modelagem de distribuição *Generalized Extreme Value* (GEV), onde o viés e a variabilidade devem ser considerados. A escolha de um limiar,  $u$ , muito alto pode implicar um pequeno número de observações, resultando em maior variabilidade dos estimadores, enquanto a escolha de um limiar muito baixo pode não satisfazer as premissas teóricas do GPD, resultando em estimativas não confiáveis (An e Pandey, 2005; Nascimento et al., 2012).

Neste estudo, o valor do percentil 95 foi utilizado como limiar, seguindo estudos anteriores (Della-Marta et al., 2009; Wu et al., 2015; Santos et al., 2015; Santos et al., 2015; Santos et al., 2016; Acero et al., 2018). O percentil 95 foi calculado para cada período sazonal dentro de cada ponto da grade localizado no NEB. Portanto, 5% dos dias com precipitação mais intensa de cada período sazonal pertencente a cada ponto da rede foram modelados por um GPD.

Nesse caso, usamos os dados históricos referentes aos 94 pluviômetros e as estimativas do produto 3B42 TRMM referentes aos 94 pontos da grade com a localização mais próxima das estações meteorológicas. Isso foi feito para comparar os resultados obtidos pela modelagem GPD no NEB, usando as duas fontes de dados estimadas (3B42 TRMM) e observadas (pluviômetro).

As premissas do modelo GPD foram verificadas usando os testes de Runs (Wald e Wolfowitz, 1940) e Ljung-Box (Ljung e Box, 1978). Eles testam, respectivamente, as suposições de que os dados são aleatórios e independentes. A qualidade do modelo GPD ajustado foi avaliada pelo teste de Kolmogorov-Smirnov (Kolmogorov, 1933; Conover, 1971; Marsaglia et al., 2003). Este testa a hipótese de que as séries de precipitação extrema diária seguem a GPD. Um nível de significância de 5% foi escolhido para os testes estatísticos.

### **4.3 Resultados e discussão**

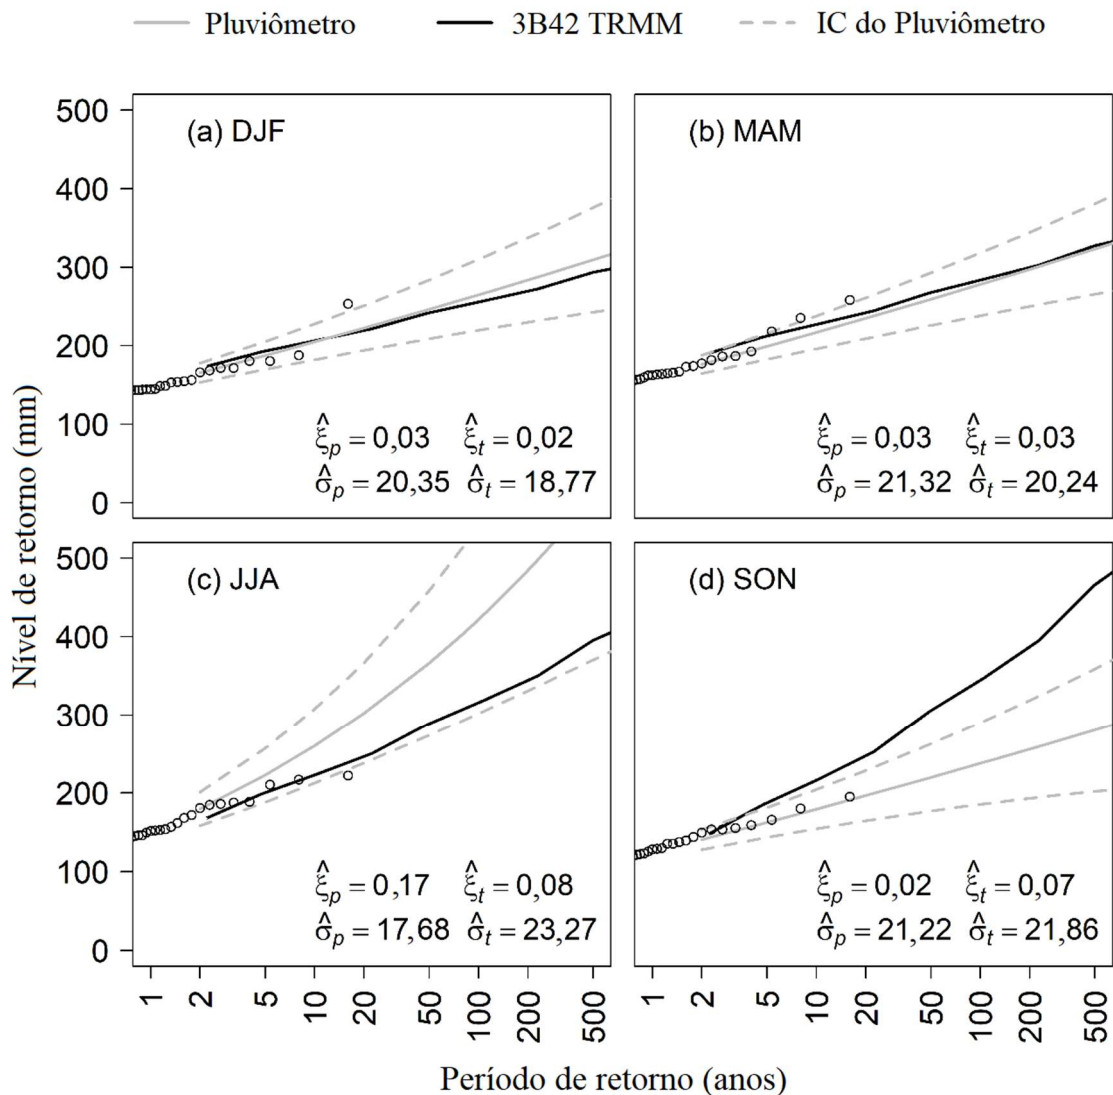
A seção de resultados e discussão está dividida em três subseções. A primeira é dedicada à comparação das estimativas dos períodos de retorno da precipitação extrema

diária das duas fontes de dados no NEB por estação do ano. A segunda apresenta a distribuição espacial (pontos da grade) das estimativas dos níveis de retorno de precipitação extrema (mm) para os períodos de retorno de 2, 5 e 10 anos, por estação do ano. A subseção final visa associar a distribuição espacial das estimativas dos níveis de retorno com a frequência de desastres naturais ocorridos no NEB.

#### 4.3.1 Avaliação do TRMM para extremos

Um modelo GPD foi ajustado para cada período sazonal, considerando um ponto de corte de 5% da precipitação diária mais intensa, considerando os dados referentes aos 94 pluviômetros e aos 94 pontos de grade (3B42 TRMM) em todo o NEB. É possível comparar os resultados dos ajustes das duas fontes de dados através da Figura 4.2 (a) - (d).

Figura 4.2. Nível de retorno por período de retorno da precipitação extrema diária (mm) sobre NEB, por período sazonal. (a) DJF, (b) MAM, (c) JJA, (d) SON.



O comportamento dos níveis de retorno da precipitação ao longo dos períodos de retorno estimados para a precipitação diária extrema no NEB usando as duas fontes de dados, 3B42 TRMM e pluviômetros, são semelhantes em todos os períodos sazonais (Figura 4.2 (a) - (d)). As curvas mais distantes são observadas para o período JJA (Figura 4.2 (c)). Este período corresponde à estação chuvosa na região da costa leste do NEB (Oliveira et al., 2013; Oliveira et al., 2017), que, segundo Palharini e Vila (2017), mostram uma forte influência da convecção superficial. Essa observação corrobora a de Hobouchian et al. (2017) e Rodrigues et al. (2019), que uma das limitações dos dados de satélite é a subestimação dos valores de precipitação de nuvens quentes. A estimativa da precipitação por satélite, que usa radiação infravermelha e passiva por microondas, tende a subestimar os valores de precipitação observados quando provêm de nuvens quentes (Ulaby et al., 1981; Braga, 2013; Palharini e Vila, 2017; Rodrigues et al. 2019 )

No entanto, embora a curva derivada dos valores extremos estimados pelo satélite (linha preta) subestime a curva derivada dos valores extremos observados pelos pluviômetros (linha cinza), Figura 4.2 (c), ela está contida no intervalo de confiança de 95% (*Confidence Interval* - CI) (linha pontilhada) do modelo ajustado (linha cinza) usando os dados dos pluviômetros. Portanto, estatisticamente, com 95% de confiança, os resultados estimados pelo modelo GPD são os mesmos para ambas as fontes de dados.

A série de valores extremos de precipitação, tanto dos pluviômetros quanto do 3B42 TRMM, atendeu às premissas de aleatoriedade e independência (*valor de  $p < 0,05$* ) da EVT. As estimativas dos parâmetros de forma  $\xi$  variaram entre 0,02 e 0,17 e entre 0,02 e 0,08, respectivamente, para os dados dos pluviômetros e do 3B42 TRMM (Figura 4.2). Estes estão entre -0,5 e 0,5, conforme recomendado por Smith (1985).

Os resultados do teste de Kolmogorov-Smirnov (Tabela 4.1) indicam que os valores extremos de precipitação diária dos pluviômetros e do 3B42 TRMM seguem uma GPD com seus respectivos parâmetros estimados (Figura 4.2) em todos os períodos sazonais (*valor  $p > 0,05$* ). Esses resultados indicam um bom ajuste do modelo GPD.

Tabela 4.1 Estatísticas D e *valor p* do teste de Kolmogorov-Smirnov por período sazonal e fonte de dados, pluviômetros e 3B42 TRMM.

Período	Dado	D	<i>valor p</i>
DJF	Pluviômetro	0,023	0,409
	3B42 TRMM	0,015	0,820
MAM	Pluviômetro	0,016	0,584
	3B42 TRMM	0,024	0,209
JJA	Pluviômetro	0,019	0,640
	3B42 TRMM	0,031	0,786
SON	Pluviômetro	0,017	0,972
	3B42 TRMM	0,035	0,393

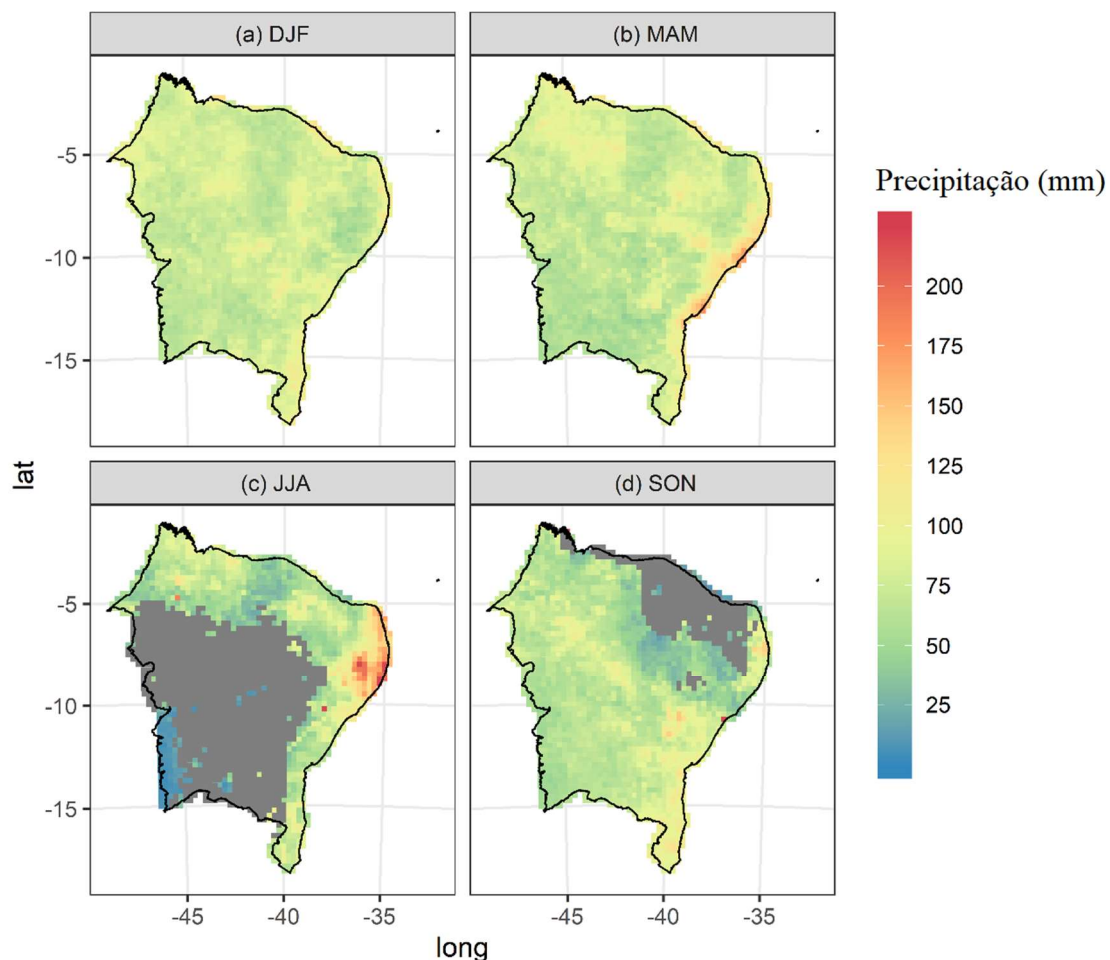
### 4.3.2 Distribuição espacial dos extremos

Nesta análise, após verificar a qualidade do ajuste do modelo GPD para NEB (Tabela 4.1), um modelo GPD foi definido para cada uma das séries diárias de precipitação extrema do produto 3B43 TRMM. Essa análise permitiu estimar níveis de retorno com um nível de detalhe mais alto, uma vez que um modelo foi estimado para cada um dos 2.082 pontos da grade para cada período sazonal. Isso permitiu representar a distribuição espacial das estimativas dos níveis de retorno da precipitação extrema diária para cada estação do ano no NEB. As Figuras 4.3, 4.4 e 4.5 apresentam, respectivamente, níveis de extremos de precipitação (mm) para os períodos de retorno de 2, 3 e 10 anos, por período sazonal.

Os resultados das estimativas dos níveis de retorno da precipitação extrema diária para um período de retorno de 2 anos (Figura 4.3 (a) - (d)) indicaram que a intensidade esperada da precipitação depende do período sazonal e da região em que a precipitação ocorre. Para o período DJF, espera-se que, em média, pelo menos uma vez a cada dois anos, ocorra precipitação diária acima de 69 mm em grande parte da NEB (Figura 4.3a). No período MAM (Figura 4.3b), observa-se um aumento na intensidade da precipitação extrema esperada, principalmente na costa leste do NEB, onde são esperados valores de precipitação diária de até 178 mm. No período JJA, espera-se uma precipitação diária de pelo menos 100 mm em 164 pontos da grade localizados no leste da NEB, enquanto no sudoeste do NEB nesse mesmo período, os eventos máximos diários de precipitação estão em torno de 25 mm (Figura 4.3 c). Uma alta variação espacial entre os valores esperados dos níveis de retorno de precipitação extrema diária são observadas para o período SON (Figura 4.3d), onde se espera precipitação extrema mais intensa em grande parte do

sudeste e precipitação extrema menos intensa na área semi-árida do NEB, com valores precipitação máxima prevista de 10 mm a 220 mm.

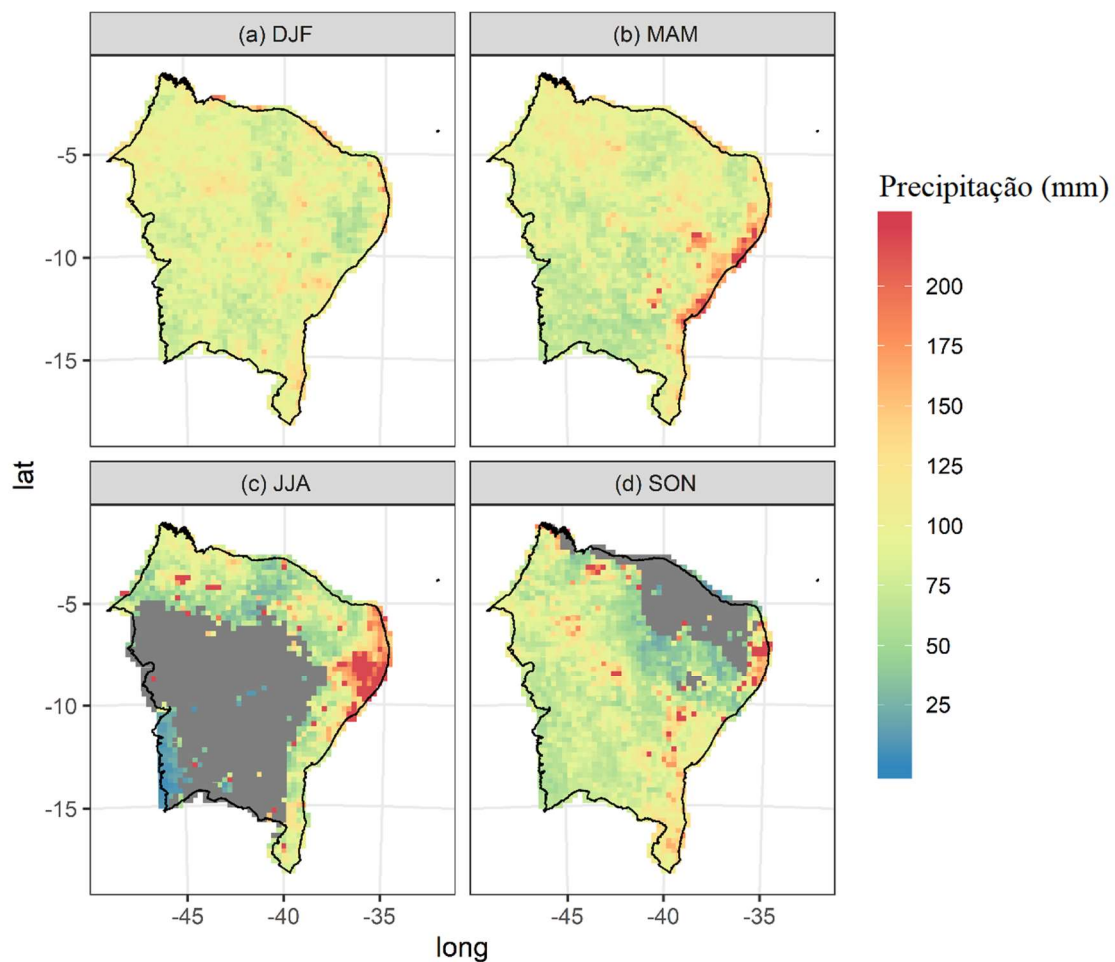
Figura 4.3. Nível de retorno (mm) da precipitação extrema diária por pontos da grade e período sazonal, (a) DJF, (b) MAM, (c) JJA, (d) SON, para um período de retorno de 2 anos. O modelo não foi aplicado aos dados referentes aos pontos de grade situados na área representada pela cor cinza, por conter um número de dias com precipitação extrema inferior a cinco.



Para um período de retorno de 5 anos (Figura 4.4 (a) - (d)), são esperados valores mais intensos de precipitação extrema diária. Nos períodos DJF e MAM, espera-se que a precipitação diária acima de 100 mm ocorra pelo menos uma vez a cada cinco anos em 25% de todas as áreas NEB (Figura 4.4 (a) e (b)). No período JJA, espera-se que eventos extremos de precipitação diária com intensidades superiores a 150 mm sejam observados

em 142 pontos da grade pelo menos uma vez a cada cinco anos, como mostra a Figura 4.4 (c).

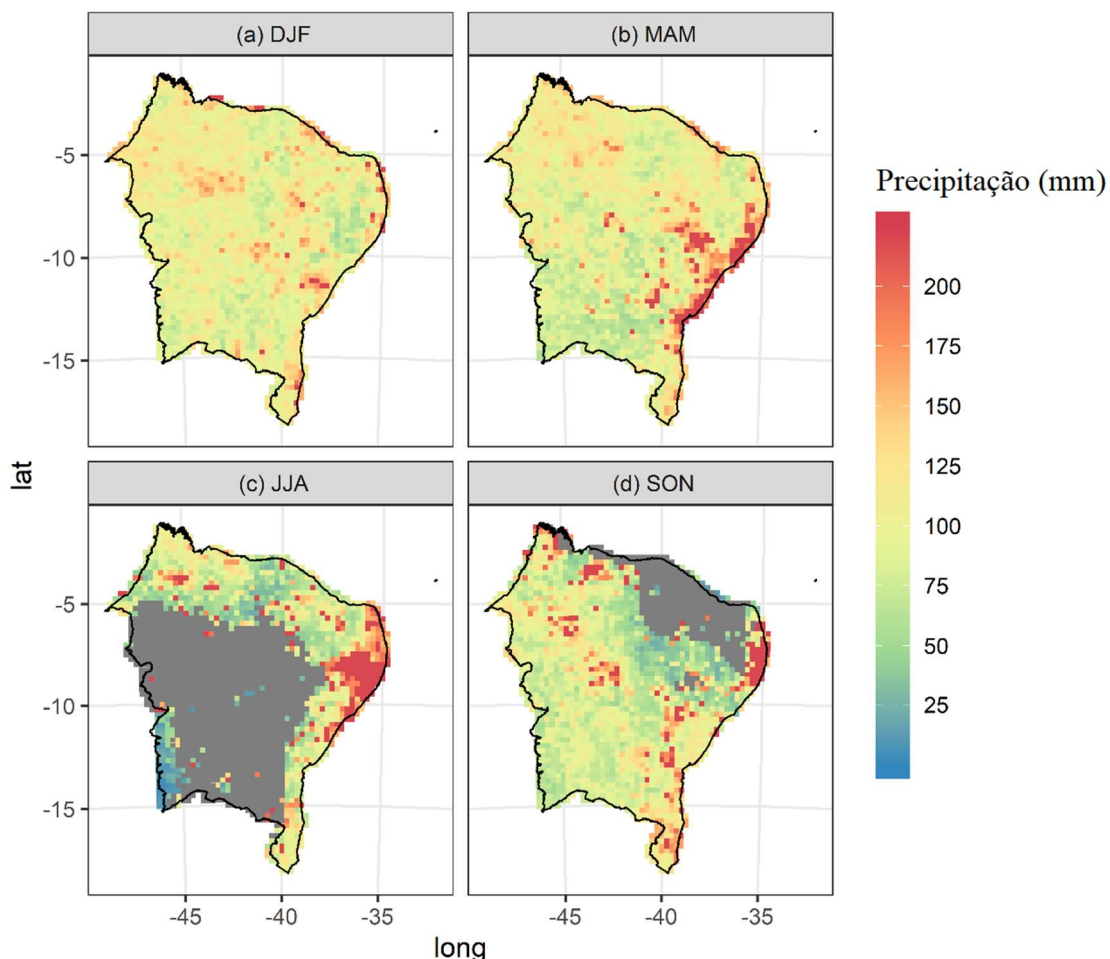
Figure 4.4. Nível de retorno (mm) da precipitação extrema diária por pontos da grade e período sazonal, (a) DJF, (b) MAM, (c) JJA, (d) SON, para um período de retorno de 5 anos. O modelo não foi aplicado aos dados referentes aos pontos de grade situados na área representada pela cor cinza, por conter um número de dias com precipitação extrema inferior a cinco.



Para um período de retorno de 10 anos, os valores das estimativas dos níveis de retorno da precipitação extrema diária (mm) são ainda mais altos, com um aumento significativo nas áreas em que são esperadas chuvas acima de 100 e 150 mm (Figuras 4.3, 4.4 e 4.5 ) Além disso, a precipitação diária extrema superior a 200 mm deverá ocorrer uma vez a cada 10 anos em 23, 80, 126 e 107 pontos de grade, respectivamente, nos períodos DJF, MAM, JJA e SON (Figura 4.5 (a) - (d)).



Figure 4.5. Nível de retorno (mm) da precipitação extrema diária por pontos da grade e período sazonal, (a) DJF, (b) MAM, (c) JJA, (d) SON, para um período de retorno de 10 anos. O modelo não foi aplicado aos dados referentes aos pontos de grade situados na área representada pela cor cinza, por conter um número de dias com precipitação extrema inferior a cinco.



Em geral, pode-se perceber que, à medida que o período de retorno aumenta (Figuras 4.3, 4.4 e 4.5), também aumentam a magnitude e a área em que ocorrem eventos de precipitação mais intensos. A costa leste do NEB é a área onde se espera que ocorram as maiores intensidades de precipitação extrema, especialmente nos períodos MAM e JJA. Esses períodos compreendem a estação chuvosa do leste do NEB, que ocorre entre abril e julho (Oliveira et al., 2013; Oliveira et al., 2017). Nesse período, a precipitação nessa região é determinada, especialmente, pelo EWD (Gomes et al., 2015; Palharini e Vila, 2017). O norte do NEB, que apresenta os maiores acumulados anuais de chuva (Kousky, 1979; Zhou e Lau, 2001; Rodrigues et al., 2019), tem uma estação chuvosa entre

fevereiro e maio (Kousky, 1979; Moura e Schukla, 1981; Oliveira et al., 2017) e possui os sistemas convectivos ITCZ e SCM como os principais sistemas causadores de precipitação (Palharini e Vila, 2017).


A região semi-árida do NEB possui a menor precipitação anual acumulada (Kousky, 1979; Zhou e Lau, 2001). Sua estação chuvosa ocorre entre dezembro e março e sua precipitação é gerada basicamente pela extensão de sistemas que ocorrem na costa norte e leste de NEB (Palharini e Vila, 2017). Os eventos diários mais intensos de precipitação extrema nessa área são esperados no centro-norte e na área de alta topografia, especialmente no período SON (Figura 4.5 (d)), a estação pré-chuvosa da região. A estação chuvosa no sudeste da NEB ocorre entre dezembro e março (Kousky, 1979; Zhou e Lau, 2001), sendo as chuvas desta região influenciadas principalmente pela presença de SACZ e sistemas frontais (Oliveira et al., 2016; Palharini e Vila, 2017). Os eventos diários mais intensos de precipitação extrema nessa área também são esperados no período de pré-chuva, Figura 4.5 (d).

### **4.3.3 Associação com desastres naturais**

É possível associar os mapas referentes às estimativas dos níveis de retorno da precipitação extrema diária, obtidos na subseção anterior, com a distribuição espacial da frequência de ocorrência de desastres naturais registrados pelo Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) no período de janeiro de 2016 a fevereiro de 2019 no NEB. A maioria dos municípios onde ocorreram desastres está localizada na costa leste do NEB (Figura 4.6). Os municípios que possuem as maiores frequências de desastres (Figura 4.6) estão centrados em áreas semelhantes àquelas em que são esperadas as maiores intensidades de eventos extremos diários de precipitação (Figuras 4.3, 4.4 e 4.5).

Durante esses três anos e dois meses, o CEMADEN registrou 508 eventos de desastre no NEB, sendo 55,9% causados por deslizamentos de terra, 22,2% por alagamentos, 12% por inundações e 9,8% por enxurradas. Um total de 93 municípios foram afetados por esses eventos, em 59,8% não houve registros de óbitos, em 3,8% houve registros de óbitos e em 36,4% não houve informações a esse respeito.

Figura 4.6. Frequência de ocorrências de desastres (alagamento, enxurrada, inundação e deslizamento de terra) por município do NEB durante o período de janeiro de 2016 a fevereiro de 2019.



Os municípios de Barreiros, Belém de Maria, Cortês, Fortaleza, Ipojuca, Jaboatão dos Guararapes, João Pessoa, Maceió, Natal, Olinda, Recife, Salvador, São Luís e Sirinhaém registraram mais de 10 eventos neste período (Figura 4.6). Sete desses municípios são capitais, de um total de nove capitais localizadas no NEB. Essa informação é muito preocupante, pois é sabido que nas áreas urbanas os impactos causados por esses eventos são mais intensos (Kobiyama et al., 2006; Vestena, 2008).

Entre todos os registros de eventos naturais registrados pelo CEMADEN, 100% das mortes ocorreram em municípios localizados no leste do NEB, 94% dos quais localizados em áreas metropolitanas, que registraram uma média de 104,58 mm de precipitação extrema nos dias em que esses eventos ocorreram. Esse fato é alarmante,

uma vez que os resultados observados anteriormente (Figura 4.3 (b) - (c)) indicam que a cada dois anos, são esperados valores de precipitação superiores a 100 mm em 207 e 164 pontos de grade, respectivamente, em MAM e JJA localizados na costa leste do NEB. Portanto, podemos considerar que a cada dois anos haverá um desastre natural.

É importante observar que os desastres não ocorreram em todas as áreas onde se esperam altos valores diários de precipitação extrema, como os superiores a 100 mm (Figura 4.3 (a) - (d)) (Figura 4.6). A ocorrência e magnitude dos desastres naturais dependem de fatores como intensidade, duração e local de ocorrência de precipitações extremas. Também estão relacionados a fenômenos que contribuem para aumentar a vulnerabilidade e a exposição da população a desastres, como fenômenos econômicos, sociais e demográficos, entre outros (IBGE, 2018). O estudo realizado pelo IBGE em parceria com o CEMADEN investigou a população brasileira exposta e vulnerável ao risco de desastres naturais, gerando mapas que destacam a população exposta em áreas de risco (IBGE, 2018). No NEB, essas áreas são semelhantes às definidas neste estudo, como as áreas nas quais se espera precipitação diária mais intensa (Figuras 4.3, 4.4 e 4.5). O NEB possui 2.952.628 residentes em áreas de risco, os dois maiores municípios estão situados no leste do NEB, Salvador e Recife, com o maior número de pessoas vivendo em áreas de risco, com 1.217.527 e 206.761 habitantes, respectivamente, em 2010 (IBGE, 2018).

#### **4.4 Conclusão**

Atualmente, a análise de eventos extremos de precipitação é um dos principais tópicos em pesquisas de hidroclimatologia, principalmente devido aos seus possíveis impactos. Valores severos de precipitação podem levar a desastres naturais, como inundações e deslizamentos de terra, entre outros. Isso pode causar sérios danos à sociedade e ao meio ambiente.

Este trabalho teve como objetivo estimar o nível de retorno de eventos extremos de precipitação em 2.082 pontos de grade em todo o NEB para os períodos de retorno de 2, 5 e 10 anos, associando-os à frequência de desastres naturais que ocorreram no NEB. Além disso, avaliamos a qualidade dos resultados dos períodos de retorno estimados por meio dos dados de satélite TRMM.

Por meio dos resultados das análises comparativas entre os dados dos pluviômetros e do produto 3B42 do satélite TRMM, foi possível concluir que estes

produziram períodos de retorno semelhantes para o NEB. Essa avaliação permitirá uma melhor compreensão da qualidade do produto TRMM 3B42 usado para estimar, por meio do modelo GPD, os níveis de retorno da precipitação extrema diária para 2.082 pontos de grade no NEB. Esses resultados podem ser úteis para dar suporte ao uso desses métodos utilizando os dados provenientes do satélite GPM, sucessor do TRMM.

Assim, foram construídos mapas para estimar os níveis de retorno da precipitação extrema diária para os períodos de retorno de 2, 5 e 10 anos, por período sazonal no NEB. Esse mapeamento nos permitiu avaliar a distribuição espacial desses eventos raros, revelando as áreas em que os eventos extremos diários de precipitação devem ser mais e menos intensos.

A distribuição espacial das estimativas dos níveis de retorno da precipitação intensa foi valiosa para a associação de eventos reais. O mapeamento da frequência de ocorrências de desastres naturais por município do NEB corroborou com os resultados observados através dos mapas dos níveis de retorno. As áreas dos municípios nos quais ocorreram desastres no NEB são semelhantes às áreas onde se espera precipitação diária mais intensa para períodos de retorno de 2, 5 e 10 anos.

Esperamos que os resultados obtidos neste estudo sejam úteis para apoiar a formulação de políticas públicas para reduzir a vulnerabilidade das pessoas que vivem no Nordeste do Brasil, especialmente aquelas que vivem em áreas de alto risco, por meio da prevenção e mitigação de desastres que possam ocorrer devido as chuvas extremas.

## CAPÍTULO 5

### MICROFÍSICA DAS NUVENS GERADORAS DE PRECIPITAÇÃO EXTREMA NO NORDESTE DO BRASIL

#### RESUMO

Estudos que investiguem as características microfísicas das nuvens são essenciais para pesquisas sobre mudanças climáticas, sobretudo as que envolvem extremos de precipitação, que podem gerar grandes impactos para sociedade e meio ambiente. O objetivo do estudo é caracterizar parâmetros como conteúdo integrado de gelo, conteúdo integrado de água líquida na nuvem, taxa de precipitação em superfície, altura do nível de congelamento e tipo de chuva das nuvens causadoras de precipitação extrema sobre cinco sub-regiões do Nordeste do Brasil (NEB). Para isso, se fez uso dos dados provenientes dos produtos 2ACLIM e 2A25 do satélite *Tropical Rainfall Measuring Mission* (TRMM). Para analisar os parâmetros microfísicos das nuvens e compará-los entre as sub-regiões estudadas, foram utilizados métodos e medidas estatísticas como média, desvio padrão, intervalo de confiança, análise de variância, testes de Tukey, Kruskal-Wallis, Dunn, entre outros. Por meio dos resultados observados foi possível construir um modelo empírico que apresenta as características dos parâmetros estudados em relação a cada sub-região do NEB. Os principais resultados apontaram que as nuvens sobre o norte e leste do NEB apresentaram os maiores quantitativos dos parâmetros estudados, enquanto as nuvens sobre o sudeste do NEB apresentaram os menores. Não houve significância estatística ( $valor - p > 0,05$ ) entre as médias da altura do nível de congelamento das sub-regiões do NEB, esta variou entre 4.796,0 e 4.852,8 metros. A precipitação extrema no NEB é provinda especialmente das nuvens do tipo convectiva, em média 74%, contra 26% das nuvens do tipo estratiformes.

**Palavras-chave:** 2ACLIM, 2A25, TRMM, nuvem, tipo de chuva.

## ABSTRACT

Studies that investigate the microphysical characteristics of clouds are essential for climate change research, especially those involving precipitation extremes, which can have major impacts on society and the environment. The objective of the study is to characterize parameters such as ice water path, cloud water path, surface precipitation, freezing height and of cloud rain type causing extreme precipitation over five subregions of Northeast Brazil (NEB). For this, data from Tropical Rainfall Measuring Mission (TRMM) satellite products 2ACLIM and 2A25 were used. To analyze the microphysical parameters of the clouds and compare them between the studied subregions, statistical methods and measures such as mean, standard deviation, confidence interval, analysis of variance, Tukey, Kruskal-Wallis, Dunn tests, among others, were used. Through the observed results it was possible to construct an empirical model that presents the characteristics of the studied parameters in relation to each subregion of the NEB. The main results indicated that the clouds over the north and east of NEB presented the highest quantitative of the studied parameters, while the clouds over the southeast of NEB presented the lowest. There was no statistical significance ( $p$  – *value* > 0.05) between the mean freezing height of the NEB subregions, ranging from 4,796.0 to 4,852.8 meters. Extreme precipitation in NEB comes especially from convective clouds, on average 74%, against 26% from stratiform clouds.

## 5.1. Introdução

As nuvens são essenciais para o ciclo hidrológico que ocorre por meio da evaporação, condensação, precipitação, infiltração e transpiração da água. Compreender este ciclo é de extrema importância para gestão de recursos hídricos, agricultura, demografia global e políticas públicas (Heiblum et al., 2011). A precipitação é um parâmetro inerente para estudos hidrometeorológicos (Katiraie-Boroujerdy et al., 2013; Yang et al., 2017). Seu entendimento é de fundamental importância para planejar seus impactos, positivos e negativos, causados em diversos segmentos, tais como: a agricultura, agropecuária, recursos hídricos e saúde pública (Rodrigues et al., 2019).

Embora as nuvens desempenhem um processo fundamental para o ciclo hidrológico, seu processo físico interno constitui um dos fatores mais desconhecidos do sistema climático. Segundo Gilmore et al. (2004), Huang et al. (2005), McFarquhar et al. (2006) este processo é a principal fonte de incertezas nas previsões climáticas por modelos de circulação geral. Além disso, de acordo com pesquisadores como Greenwald et al. (1993) e Trenberth et al. (2009), este processo de precipitação interfere na variação climática global.

Neste sentido, estudos estão sendo desenvolvidos com o intuito de obter informações dos parâmetros microfísicos das nuvens em várias regiões do globo, como as pesquisas realizadas por: Han et al. (2010) que avaliaram as microfísicas das nuvens dos sistemas frontais de precipitação no inverno sobre o Oceano Pacífico Oriental; Chakravarty et al. (2013) que caracterizaram os parâmetros microfísicos das nuvens durante os meses de pré-moção e monção sobre Kolkata, situada na região oriental da Índia; Qin et al. (2018) que investigaram as propriedades microfísicas da nuvem de precipitação quente no Oceano Pacífico tropical (20° S – 20° N) e Yang et al. (2019) que estudaram as características ópticas e microfísicas das nuvens de precipitação e suas relações com as taxas de chuva de superfície no verão sobre o Vale do Rio Yangtze-Huaihe, no nordeste da China.

Para realização destas pesquisas muitos pesquisadores (Liu et al., 2008; Han et al., 2010; Matsui et al., 2016; Fu et al., 2017; Qin et al., 2018; Yang et al., 2019) têm utilizado as fontes de dados provenientes dos sensores *Precipitation Radar (PR) and Microwave Imager (MI)* do satélite *Tropical Rainfall Measuring Mission (TRMM)* e seu sucessor, *Global Precipitation Measurement (GPM)*. Estas fontes são capazes de fornecer parâmetros físicos das nuvens, como quantidade de água líquida e gelo, taxa



de precipitação, altura do nível de congelamento, probabilidade de precipitação, entre outros.

Pesquisas que investiguem as características dos parâmetros microfísicos das nuvens precipitantes são essenciais para auxiliar nos estudos sobre parametrização de modelos dinâmicos de previsão de tempo e clima (Huang et al., 2005; Chakravarty et al., 2013; Yang et al., 2019), mudanças climáticas (Stephens, 2015; Khain et al., 2019), disponibilidade de recursos hídricos (Heiblum et al., 2011; Tan e Storelmo, 2019), efeitos de radiação da nuvem (Wang et al. 2004; Yang et al. (2019)), e interações entre precipitação, aerossol e nuvem (Min et al., 2009; Rosenfeld et al., 2012; Fu, 2014).

Diante do exposto, compreender os processos microfísicos das nuvens precipitantes é de grande importância para a sociedade, especialmente, em regiões sensíveis às variações de chuvas (Heiblum et al., 2011), como é o caso da região Nordeste do Brasil (NEB) (Moura e Shukla, 1981; Zhou e Lau, 2001; Oliveira et al., 2017). Esta Região caracterizada pelos déficits e excessos de precipitação (Hastenrath e Heller, 1977; Moura e Shukla, 1981; Marengo et al., 2017; Da Silva et al., 2018; Silva et al., 2019), que podem causar eventos como seca, deslizamento de terra, alagamento, entre outros.

De acordo com o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), em apenas três anos e dois meses, ocorreram 508 desastres naturais, como alagamento, deslizamento de terra, enxurrada e inundação no NEB (Capítulo 3). Ainda de acordo com os autores é esperado no NEB precipitações extremas diárias de até 178 mm em um período de retorno de 2 anos.

Com o intuito de entender a estrutura interna das nuvens responsáveis por esses extremos de precipitação, o objetivo desta pesquisa é analisar os parâmetros de conteúdo integrado de água líquida na nuvem, conteúdo integrado de gelo, altura do nível de congelamento e tipo de chuva, das nuvens geradoras de precipitação extrema diária em cinco sub-regiões do NEB definidas por Rodrigues et al. (2019). Foi feita uma comparação entre os resultados de cada parâmetro estudado de acordo com cada sub-região do NEB. Por fim, será apresentado um modelo empírico dos parâmetros microfísicos da nuvem associados aos eventos extremos de precipitação diários para as diferentes regiões do NEB baseado na série de dados analisada.

## 5.2. Material e Métodos

### 5.2.1. Área de estudo

O NEB está situado no extremo nordeste da América do Sul, entre 1° N e 18° S e 34,5° W e 48,5° W, a leste da floresta Amazônica. O NEB é uma das cinco regiões do Brasil e possui aproximadamente uma área de 1.558.196 km<sup>2</sup>, com uma população de 53.078.137 habitantes distribuídos em nove estados (IBGE, 2010). Sua costa é a maior entre as regiões do Brasil, sendo a costa norte e leste banhada pelo oceano Atlântico.

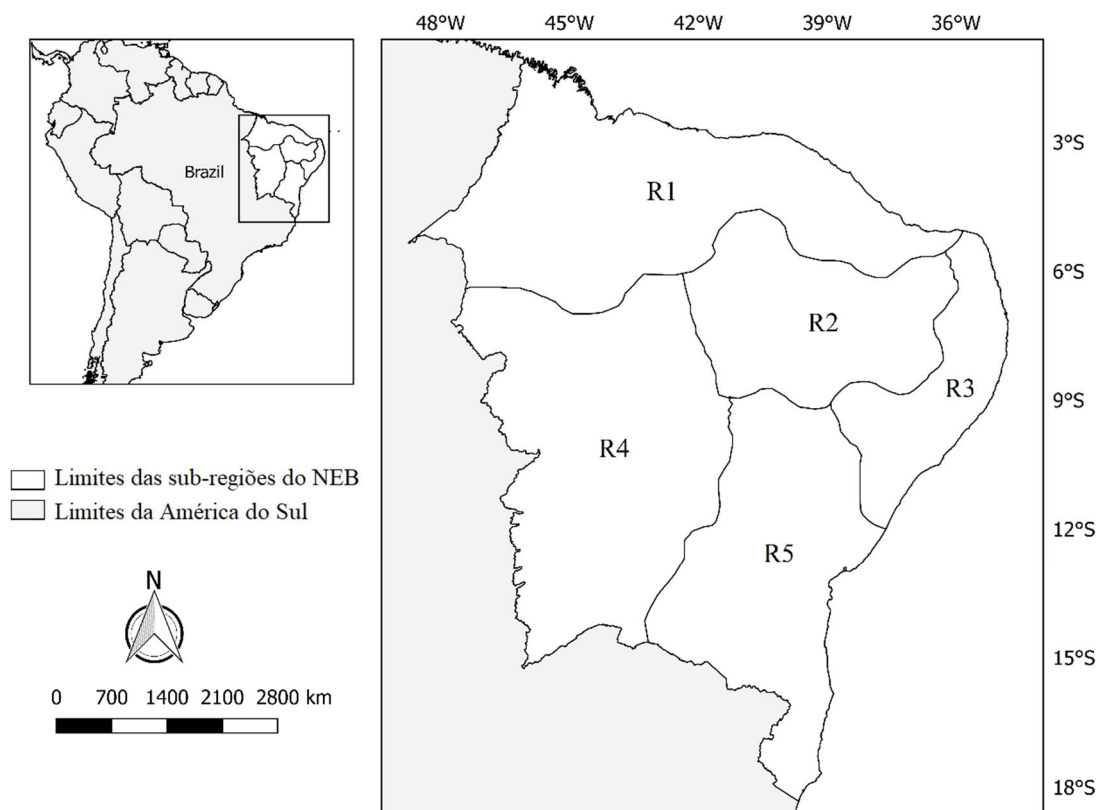
A Região é caracterizada por apresentar uma alta variabilidade climática, com clima tropical, seco e úmido (Köppen, 1936; Alvares, et al., 2005). Essa diversidade está associada a um conjunto de fatores fisiográficos e de sistemas atmosféricos (Silva et al. 2012). Sendo assim, com o intuito de obter resultados mais confiáveis e representativos foi considerada a variabilidade espacial da precipitação sobre o NEB.

Os parâmetros de microfísica das nuvens geradoras de precipitação extrema foram caracterizados para cada sub-região do NEB definidas por Rodrigues et al. (2019). Estes autores utilizaram trinta anos de dados diários de precipitação provindos de 94 pluviômetros distribuídos no NEB. A técnica estatística multivariada denominada Análise de Cluster foi utilizada para definir cinco sub-regiões homogêneas no NEB de acordo com sua precipitação diária (Figura 5.1).

De acordo com Rodrigues et al. (2019) estas sub-regiões caracterizam a variabilidade espacial da precipitação diária presente no NEB. A sub-região 1 (R1) abrange o norte do NEB, caracterizada por apresentar os maiores acumulados de precipitação (Kousky, 1980; Zhou e Lau, 2001; Rodrigues et al., 2019), a estação chuvosa desta região ocorre entre os meses de fevereiro e maio (Kousky, 1979; Moura e Schukla, 1981; Oliveira et al., 2017) e possui a *Intertropical Convergence Zone* (ITCZ) (Uvo, 1989; Reboita et al. 2012; Utida et al., 2019) e os Sistemas Convectivos de Mesoescala (Kousky, 1980; Palharini e Vila, 2017) como principais sistemas causadores de precipitação. Já a sub-região 2 (R2), representa parte do semiárido do NEB, possuindo os menores acumulados de precipitação anual do NEB (Kousky, 1979; Zhou e Lau, 2001; Rodrigues et al., 2019). Sua estação chuvosa ocorre entre os meses de dezembro e março e sua precipitação é gerada, especialmente, pela extensão dos sistemas que ocorrem no litoral norte e leste do NEB (Palharini e Vila, 2017). A sub-região 3 (R3) compreende parte do litoral leste do NEB, seu período chuvoso ocorre entre os meses de abril e julho

(Oliveira et al., 2013; Oliveira et al., 2017; Rodrigues et al., 2019). Sua precipitação é determinada, especialmente, pelo *Easterly Waves Disturbances* (EWD) (Torres e Ferreira, 2011; Gomes et al., 2015; Gomes et al., 2019) e *Upper Tropospheric Cyclonic Vortex* (UTCV) (Kousky e Gan, 1981; Reboita et al., 2012; Fedorova et al., 2016). As sub-regiões 4 (R4) e 5 (R5) compreendem o sudoeste e sudeste do NEB, respectivamente. O período chuvoso destas sub-regiões ocorre entre os meses de dezembro e março (Kousky, 1979; Zhou e Lau, 2001; Rodrigues et al., 2019), sendo influenciadas especialmente pela presença da *South Atlantic Convergence Zone* (SACZ) (Kodama, 1992; Zilli et al., 2019) e de Sistemas Frontais (Oliveira et al., 2016; Palharini e Vila, 2017).

**Figura 5.1** Área de estudo e limites das sub-regiões (Região 1 (R1), Região 2 (R2), Região 3 (R3), Região 4 (R4) e Região 5 (R5) do NEB definidas por Rodrigues et al., (2019).



Fonte: Adaptado de Capítulo 3.

### 5.2.2. TRMM

Para realização desse estudo, utilizaram-se as informações dos parâmetros microfísicos das nuvens que geraram 5% das precipitações diárias mais intensas ocorridas no NEB, consideradas extremas, durante um período de 15 anos, de 2000 a 2015. Estas informações foram extraídas dos produtos 2ACLIM e 2A25, respectivamente, associados aos sensores MI e PR a bordo do satélite TRMM.

O TRMM foi uma parceria entre a *Japan Aerospace Exploration Agency and National Aeronautics and Space Administration* (NASA), sendo a primeira missão da NASA dedicada a observar e entender as chuvas tropicais e como essas afetam o clima global (TRMM, 2015). Os instrumentos a bordo do satélite TRMM são o MI, PR, e o *Visible and Infrared Radiometer System* (VIRS). Além desses, o TRMM carrega o *Lighting Imaging Sensor* e o *Clouds and Earth Radiant Energy System*, que são capazes de detectar relâmpagos e estimar a energia da atmosfera, respectivamente. O TRMM cobre as regiões tropicais e sub-tropicais da Terra, entre 38° N e 38° S e 180° W e 180° W e altitude de 350km (até agosto de 2001) e 403km (a partir de setembro de 2001), com resolução temporal de cerca de 92,5 minutos por órbita, aproximadamente 16 órbitas por dia (TRMM, 2015).

As medições do PR produzem informações valiosas sobre a intensidade e distribuição da chuva, sobre o tipo de chuva, intensidade da tempestade e altura do topo de congelamento (TRMM, 2015). O MI é o sensor de microondas passivo do TRMM, que por meio do *Goddard Profiling Algorithm* 2014 é capaz de fornecer informações sobre a quantidade e tamanho das partículas de água e gelo integrado na nuvem (Kummerow et al., 1998; Liu et al. 2008; Banze, 2016). Os dados provenientes dos dois produtos, 2ACLIM e 2A25, foram considerados bem calibrados por vários pesquisadores (Wang e Wolff, 2009; Liao e Meneghini, 2009; Fisher e Wolff, 2010; Kroodsma et al., 2018), que avaliaram sua qualidade por meio de comparações com dados de superfícies.

No presente estudo foram caracterizados três parâmetros microfísicos associados ao produto 2ACLIM (NASA, 2017) e dois associados ao produto 2A25 (NASA, 2015), Tabela 5.1.

Tabela 5.1. Parâmetros microfísicos das nuvens associados aos produtos 2ACLIM e 2A25.

Produto	Parâmetro
2ACLIM	Conteúdo integrado de água líquida na nuvem ( <i>Cloud water path – kg/m<sup>2</sup></i> )
	Conteúdo integrado de gelo ( <i>Ice water path – kg/m<sup>2</sup></i> )
	Taxa de precipitação em superfície ( <i>Surface precipitation – mm/h</i> )
2A25	Altura do nível de congelamento ( <i>Freezing heigth – m</i> )
	Tipo de chuva ( <i>Rain type</i> )

### 5.2.3. Métodos estatísticos

Calcularam-se as medidas estatísticas, como média e desvio padrão para cada parâmetro quantitativo da microfísica da nuvem geradora de precipitação intensa diária para cada sub-região do NEB. Estas medidas foram calculadas levando em consideração todas as observações diárias dentro de cada sub-região, por meio das Equações 5.1 e 5.2. Os valores médios e a variabilidade de cada parâmetro foram representados por meio de gráficos.

$$\bar{X}_k = \frac{1}{n_k} \sum_{i=1}^{n_k} X_i \quad (5.1)$$

$$Sd_k = \sqrt{\frac{1}{n_k - 1} \sum_{i=1}^{n_k} (X_i - \bar{X}_k)^2} \quad (5.2)$$

Em que  $X$  representa o valor do parâmetro microfísico;  $i$  representa a nuvem geradora de precipitação intensa,  $i = 1, 2, \dots, n$ ;  $n$  representa o número total de nuvens geradoras de precipitação intensa e  $k$  representa cada sub-região do NEB,  $k = 1, 2, 3, 4$  e  $5$ .

Para verificar se existe diferença estatística entre os parâmetros microfísicos de cada sub-região do NEB se utilizou a técnica estatística Análise de Variância (ANOVA). Esta técnica testa, por meio da soma de quadrados das diferenças, as diferenças entre dois pares de médias. A ideia é derivar a variabilidade total das informações em componentes, segundo o modelo estatístico utilizado. O resultado da ANOVA evidencia que a distribuição do parâmetro estudado de pelo menos uma sub-região difere das demais, mas

não indica entre quais sub-regiões a diferença é significativa. Assim, caso a hipótese de igualdade de médias da ANOVA seja rejeitada, será calculado o teste de comparações múltiplas Tukey-Kramer (Tukey, 1949; Driscoll, 1996). Este compara os pares de médias em casos em que os grupos em comparações possuem tamanhos amostrais diferentes (Driscoll, 1996).

Para os resultados da ANOVA e teste de Tukey-Kramer serem válidos é necessário que os resíduos do modelo da ANOVA apresentem distribuição Normal, variância constante e independência. Estas suposições foram verificadas, respectivamente, por meio dos testes de Shapiro-Wilk's (Patrick Royston, 1982) Levene (Brown e Forsythe, 1974) e Ljung-Box (Ljung e Box, 1978). Como nem todas as suposições foram atendidas, aplicou-se a transformação de Box-Cox (Box e Cox, 1964) aos dados, esta transformação é bastante útil para que os dados transformados se aproximassem de uma distribuição normal e possuam variância constante (Box e Cox, 1964). Os testes de Kruskal-Wallis (Myles e Douglas, 1973) e Dunn (Dunn, 1964) foram utilizados como alternativa, respectivamente, a ANOVA e teste de Tukey. Isto foi feito, pois, mesmo após a transformação Box-Box, os dados a respeito dos parâmetros de conteúdo integrado de água líquida na nuvem e altura do nível de congelamento, não seguiram uma distribuição normal. Estes testes são não-paramétricos e não possuem pressuposições a respeito dos dados (Dunn, 1964; Myles e Douglas, 1973).

### 5.3. Resultados

Os primeiros resultados sintetizam, por meio de gráficos e medidas descritivas, as características dos parâmetros de taxa de precipitação em superfície, conteúdo integrado de gelo, conteúdo integrado de água líquida na nuvem e altura do nível de congelamento das nuvens responsáveis pela geração da precipitação extrema diária segundo as cinco sub-regiões do NEB, definidas por Rodrigues et al. (2019). O percentual do tipo de chuva, estratiforme e convectiva, das nuvens geradoras de precipitação extrema foi calculado para cada uma das sub-regiões do NEB.

Os resultados da ANOVA e do teste de Kruskal-Wallis foram estatisticamente significativos (valores- $p < 0,05$ ) para os parâmetros de taxa de precipitação em superfície, conteúdo integrado de gelo e conteúdo integrado de água líquida na nuvem. Estes resultados apontam que a média destes parâmetros é diferente em pelo menos duas sub-regiões do NEB. Já para o parâmetro da altura do nível de congelamento o resultado do

teste de Kruskal-Wallis apontou que não existe diferença estatística (valor- $p > 0,05$ ) do parâmetro entre as sub-regiões do NEB.

Os valores da taxa da precipitação (Figura 5.2) foram maiores na sub-região R1, seguida da sub-região R3. Estas sub-regiões apresentaram os maiores acumulados anuais de precipitação do NEB (Kousky, 1979; Zhou e Lau, 2001; Oliveira et al., 2017; Rodrigues et al., 2019). A região R5, apesar de ser uma região de topografia elevada, apresentou as menores taxas de precipitação em superfície provindas das nuvens geradoras de eventos extremos de precipitação. O teste de comparação múltipla de Tukey (Tabela 5.2), indicou que a taxa de precipitação em superfície nesta sub-região é estatisticamente diferente (valor- $p < 0,05$ ) das demais. Os Intervalos de Confiança (IC) de 95% das diferenças entre R5 e as sub-regiões R1, R2, R3 e R4, são respectivamente IC 95% [-0,342; -0,133], IC 95% [-0,263; -0,017], IC 95% [-0,310; -0,059] e IC 95% [-0,290; -0,065] (Tabela 5.2).

Figura 5.2. Intervalo de Confiança da taxa de precipitação em superfície da nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB.

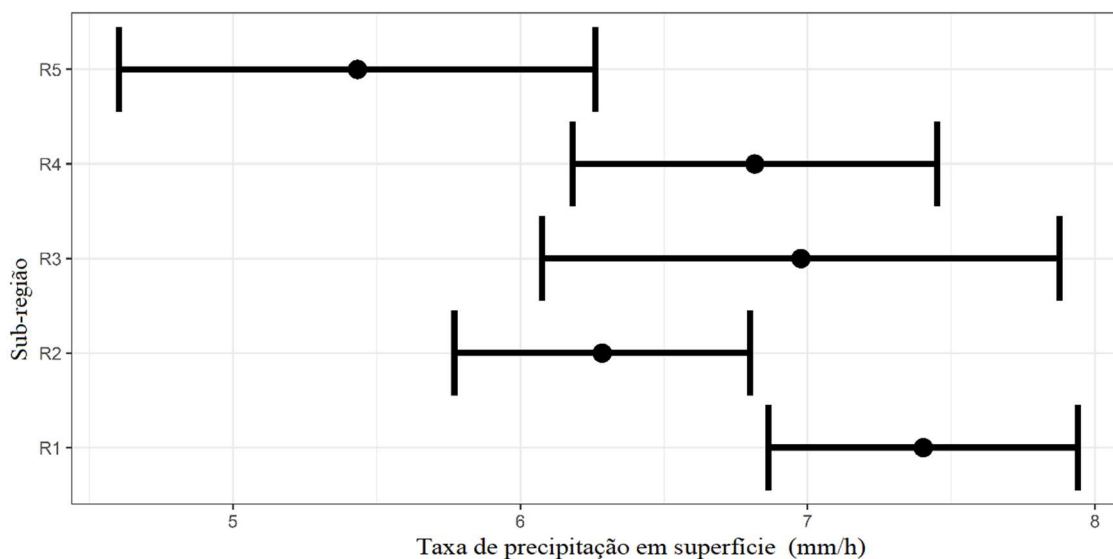


Tabela 5.2: Resultados do teste de Tukey. Diferença entre pares de médias e seus respectivos limites de IC de 95% para as sub-regiões do NEB por parâmetros microfísicos da nuvem geradora de precipitação extrema. Os valores significativos (Valor-p < 0,05) estão representados por um asterisco.

Parâmetros microfísicos	Sub-regiões	Diferença entre médias	Limites IC (95%)		Valor-p
			Inferior	Superior	
Taxa de precipitação em superfície (mm/h)	R2-R1	-0,098	-0,209	0,013	0,112
	R3-R1	-0,053	-0,167	0,060	0,696
	R4-R1	-0,060	-0,159	0,039	0,453
	R5-R1	-0,238	-0,342	-0,133	0,000 *
	R3-R2	0,045	-0,086	0,175	0,882
	R4-R2	0,038	-0,081	0,156	0,906
	R5-R2	-0,140	-0,263	-0,017	0,017 *
	R4-R3	-0,007	-0,128	0,114	1,000
	R5-R3	-0,184	-0,310	-0,059	0,001 *
	R5-R4	-0,177	-0,290	-0,065	0,000 *
Conteúdo integrado de gelo (kg/m <sup>2</sup> )	R2-R1	-0,131	-0,427	0,164	0,738
	R3-R1	-0,055	-0,358	0,247	0,987
	R4-R1	-0,101	-0,365	0,164	0,832
	R5-R1	-0,480	-0,759	-0,202	0,000 *
	R3-R2	0,076	-0,273	0,425	0,975
	R4-R2	0,031	-0,285	0,346	0,999
	R5-R2	-0,349	-0,677	-0,021	0,031 *
	R4-R3	-0,045	-0,367	0,277	0,995
	R5-R3	-0,425	-0,759	-0,091	0,005 *
	R5-R4	-0,380	-0,680	-0,080	0,005 *

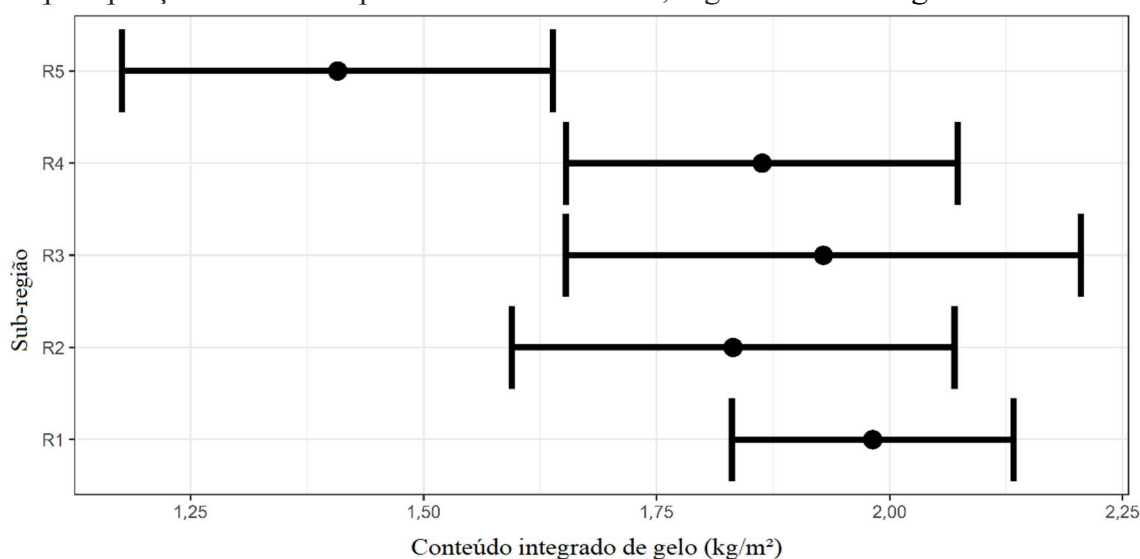
O conteúdo integrado de gelo na nuvem apresentou valores médios de 198,2, 183,2, 192,9, 186,3 e 140,8 g/m<sup>2</sup>, com desvio-padrão de 59,0, 63,7, 71,3, 68,3 e 68,3 g/m<sup>2</sup>, respectivamente para as sub-regiões R1, R2, R3, R4 e R5 (Figura 5.3). As diferenças entre os pares de médias foram significativas (valor-p < 0,05) entre R5 e as sub-regiões R1, R2, R3 e R4 (Tabela 5.2). Portanto, a sub-região R5 é a única que se diferencia, estatisticamente, das demais sub-regiões quando se compara a média de conteúdo integrado de gelo das nuvens geradoras de precipitação extrema. As nuvens geradoras de precipitação extrema da sub-região R5 apresentam as menores quantidades de gelo em relação às nuvens das demais sub-regiões. De acordo com Rodrigues et al. (2019), enquanto os acumulados anuais de precipitações extremas nas sub-regiões R1 e R3 são superiores a 1.500 mm, os acumulados anuais na sub-região R5 não ultrapassam 1.200 mm.

Os resultados observados pelas Figuras 5.2 e 5.3 indicam que os parâmetros da



taxa de precipitação em superfície e conteúdo integrado de gelo na nuvem seguem o mesmo comportamento. As sub-regiões R1 e R3 são caracterizadas por apresentarem os maiores quantitativos destes parâmetros, seguidas das sub-regiões R4 e R2. A sub-região R5 se destaca das demais por apresentar baixas taxas de precipitação em superfície e baixos valores de conteúdo integrado de gelo na nuvem geradora de precipitação extrema. Esta sub-região apresenta o menor limiar (95th *percentile*) diário de precipitação extrema (Rodrigues et al., 2019).

Figura 5.3. Intervalo de Confiança do conteúdo integrado de gelo na nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB.



O conteúdo integrado de água líquida (*Cloud water path*) na nuvem geradora de precipitação extrema no NEB varia de 0 a 60 g/m<sup>2</sup>. A maior média e variação desta quantidade é observada nas nuvens sobre o leste, R3, do NEB, com média 21,5 g/m<sup>2</sup> e desvio padrão de 20 g/m<sup>2</sup>. Uma possível explicação para a sub-região R3 apresentar os maiores valores médios de conteúdo integrado de água líquida em relação às demais sub-regiões do NEB (Figura 5.4) pode ser atribuído ao fato de que no leste do NEB as precipitações são frequentemente provindas de nuvens quentes (Palharini e Vila, 2017).

De forma geral, as nuvens causadoras de precipitação extrema possuem baixas quantidades de valores médios de água líquida, com 9,2, 0,0, 0,2 e 5,3 g/m<sup>2</sup>, respectivamente, nas sub-regiões R1, R2, R4 e R5 (Figura 5.4). Abreu et al. (2018) também observaram baixos valores de água líquida nas nuvens que causam

relâmpagos no NEB. A baixa quantidade de água líquida pode estar associada à nuvem com alto crescimento vertical (Rosenfeld e Lensky, 1998).

Nota-se, ainda, que os valores médios do conteúdo integrado de gelo na nuvem geradora de precipitação extrema (Figura 5.3) são bem maiores do que as quantidades médias de água líquida (Figura 5.4), isto ocorre para todas as sub-regiões do NEB. Esta afirmação corrobora com a feita por Rosenfeld e Lensky (1998) que apontaram que em nuvens precipitantes a quantidade de água líquida é menor devido à presença de água em estado sólido. Segundo Petersen e Rutledge (2001), grandes partículas de gelo se desenvolvem nas nuvens com alto crescimento vertical como resultado do processo da fase mista da nuvem.

Para o parâmetro conteúdo integrado de água líquida na nuvem foi observado que grande parte das diferenças observadas foram estatisticamente significativas (valor- $p < 0,05$ ). As exceções ocorreram entre as sub-regiões R2 e R4 e R1 e R5, entre estas não há diferença estatística entre o conteúdo integrado de água líquida (Tabela 5.3).

Figura 5.4. Intervalo de Confiança do conteúdo integrado de água líquida na nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB.

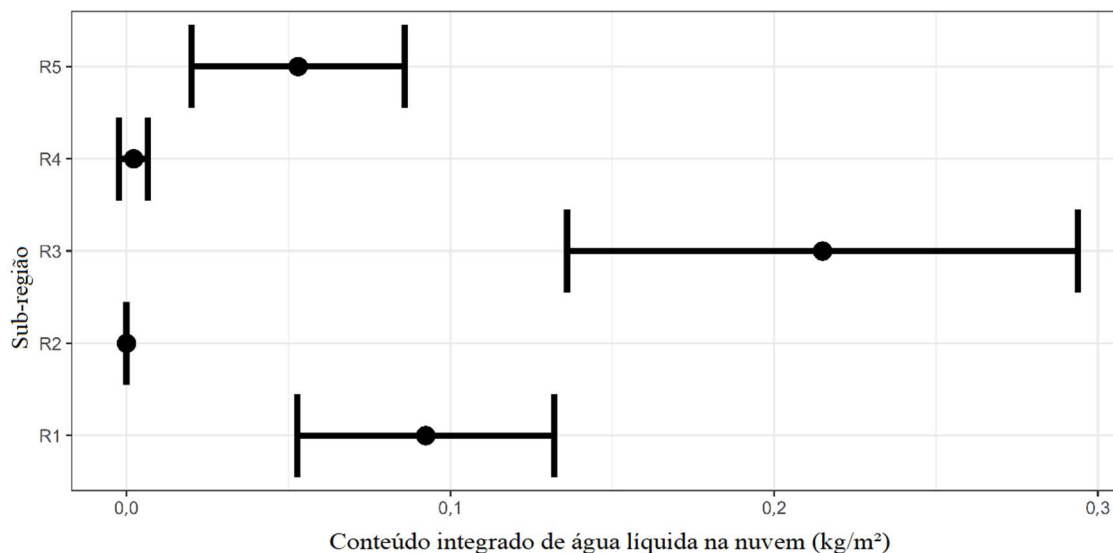
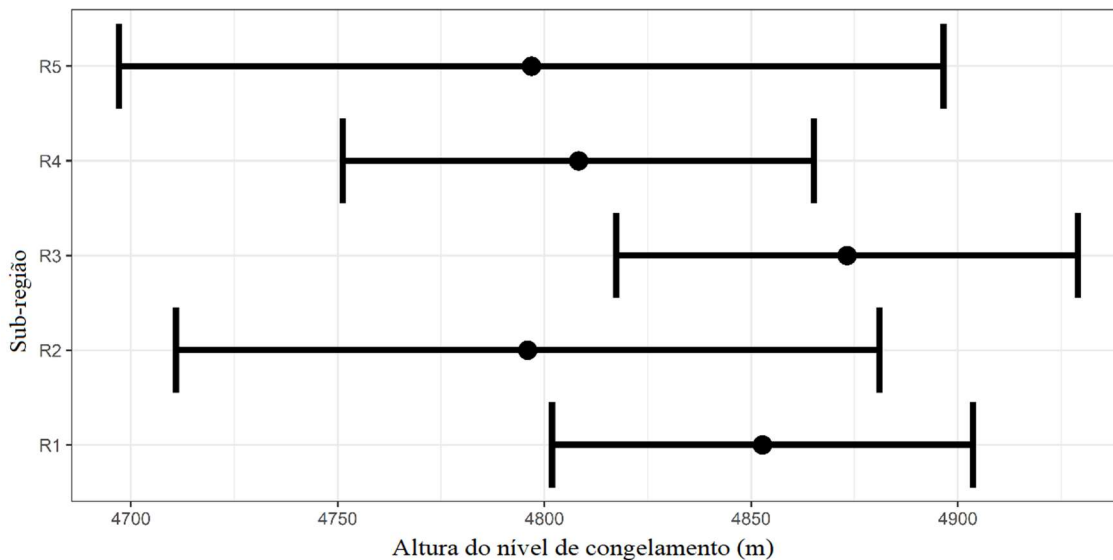


Tabela 5.3: Resultados do teste de Dunn. Estatística do teste e seus respectivos valores-p para as sub-regiões do NEB. Os valores significativos (Valor-p < 0,05) estão representados por um asterisco.

Parâmetro microfísicos	Sub-regiões	Estatística do teste	Valor-p
Conteúdo integrado de água líquida (kg/m <sup>2</sup> )	R2-R1	3,365	0,004 *
	R3-R1	-4,156	0,000 *
	R4-R1	-6,466	0,002 *
	R5-R1	3,559	1,000
	R3-R2	-0,175	0,000 *
	R4-R2	6,826	0,861
	R5-R2	0,615	0,036 *
	R4-R3	-2,513	0,000 *
	R5-R3	4,278	0,000 *
	R5-R4	-2,565	0,041 *

A altura do nível de congelamento das nuvens geradoras de precipitação extrema, relacionado à altitude da isoterma de 0° C, variaram de 4.010 a 5.205 metros em todo o NEB. A variação dos valores médios deste parâmetro entre as sub-regiões do NEB é baixa (Figura 5.5), respectivamente, 4.853, 4.796, 4.873, 4.808 e 4.797 metros para as sub-regiões R1, R2, R3, R4 e R5. Vale ressaltar, que neste caso, o resultado do teste de Kruskal-Wallis indicou que não há diferença entre estas médias (valor-p > 0,05). Estes resultados são similares aos observados por Harris et al. (2000), os autores afirmaram que as alturas do nível de congelamento da nuvem sobre os trópicos são homogêneas, com variação entre 4.500 e 5.000 metros. Abreu et al. (2018) também observaram valores similares, entre 4.000 e 5.500 metros, para nuvens precipitantes com e sem relâmpagos sobre o NEB.

Figura 5.5. Intervalo de Confiança da altura do nível de congelamento da nuvem geradora de precipitação extrema no período de 2000 a 2015, segundo as sub-regiões do NEB.



A Figura 5.6 apresenta uma representação gráfica do modelo empírico que diferencia as características do conteúdo integrado de gelo, conteúdo integrado de água líquida, altura do nível de congelamento, taxa de precipitação em superfície e tipo de chuva das nuvens que causam precipitação extrema em cada sub-região do NEB. Apesar dos resultados do Teste de Tukey (Tabela 5.2) e Dunn (Tabela 5.3) não indicarem diferença estatística (valor- $p > 0,05$ ) para todos os pares de médias dos parâmetros em relação as sub-regiões do NEB é importante destacá-las. De acordo com Heiblum et al. (2011) destacar as diferenças dos parâmetros da nuvem é extremamente importante, especialmente em regiões que apresentam grandes variações nos quantitativos de precipitação (Heiblum et al., 2011), como no NEB (Oliveira et al. 2017, Rodrigues et al. 2019).

O modelo empírico (Figura 5.6) apresenta as sub-regiões R1 e R3 com os maiores quantitativos de gelo presentes nas nuvens causadoras de precipitação extrema. Estas regiões representam, respectivamente, o norte e leste do NEB e possuem os maiores acumulados de precipitação anual (Kousky, 1979; Zhou e Lau, 2001; Rodrigues et al. 2019). Na região norte, estas chuvas estão associadas, especialmente com a ITCZ e SCM (Kousky, 1980; Utida et al., 2019) já na região leste estão associadas, principalmente, aos DOL e VCAN (Gomes et al., 2015; Fedorova et al., 2016). A nuvem geradora de precipitação extrema sobre a sub-região R5 possui a menor quantidade de gelo quando comparada com as nuvens das demais regiões, e difere


estatisticamente (Tabela 5.2) de todas as outras sub-regiões do NEB.

O mesmo acontece com a sub-região R3, que é estatisticamente (Tabela 5.3) diferente de todas as outras sub-regiões do NEB em relação ao conteúdo integrado de água líquida na nuvem geradora de precipitação extrema. Esta apresenta nuvens com maiores quantitativos de água líquida quando comparada com as nuvens das demais sub-regiões (Figura 5.6). Este resultado pode ser explicado pelo fato de a precipitação nesta sub-região ser provinda frequentemente por nuvens do tipo estratiformes e de convecção rasa (Palharini e Vila, 2017). Os autores afirmam que a nebulosidade das nuvens, especialmente da convectivas rasas, próximo à costa leste do NEB é gerada pelo DOL.

As taxas de precipitação extrema no NEB são maiores nas sub-regiões R1 e R3, estas apresentam a maior concentração de pessoas em áreas de risco a desastres naturais no NEB (IBGE, 2018). Sendo a sub-região R3 a que apresenta a maior frequência de ocorrência de desastres naturais como alagamento, deslizamento de terra, enxurrada e inundação (Capítulo 4). Dentre todas as sub-regiões do NEB a R5 é a que apresenta as menores taxas de precipitação extrema (Figura 5.6). Como visto no capítulo 3 deste trabalho a sub-região R5 apresenta o menor limiar de precipitação extrema diária quando comparada com as demais sub-regiões do NEB.

A precipitação extrema no NEB é frequentemente causada por nuvens do tipo convectiva, 74%, 64%, 78%, 78% e 74%, respectivamente, nas sub-regiões R1, R2, R3, R4 e R5 do NEB. O percentual de nuvens estratiformes causadoras de precipitação intensa foram de 26%, 36%, 22%, 22% e 26%, respectivamente, nas sub-regiões R1, R2, R3, R4 e R5 do NEB. Palharini e Vila (2017) encontraram uma maior frequência de nuvens estratiformes sobre o NEB, em média 37%, porém os autores investigaram as nuvens precipitantes como um todo, não apenas as geradoras de precipitação extrema, como as investigadas por este estudo.

Figura 5.6: Modelo empírico dos parâmetros das nuvens geradoras de precipitação extrema por sub-regiões do NEB.



#### 5.4. Conclusão

Diante dos resultados apresentados, conclui-se que é possível estudar o comportamento dos parâmetros microfísicos das nuvens responsáveis pelos eventos de precipitação extrema no NEB, por meio dos dados dos produtos 2ACLIM e 2A25 do satélite TRMM. Foi possível classificar o perfil vertical destas nuvens em relação aos parâmetros de conteúdo integrado de gelo, conteúdo integrado de água líquida na nuvem, taxa de precipitação em superfície e altura do nível de congelamento. Além disso, investigou-se a frequência de ocorrência das nuvens estratiformes e convectivas geradoras de precipitação extrema.

Este estudo proporcionou meios para criação de um modelo empírico, que caracteriza os parâmetros microfísicos da nuvem responsáveis pelos eventos de precipitação extrema em diferentes áreas do NEB. Os principais resultados apresentam o norte e o leste do NEB, como sendo as regiões com maiores concentrações de conteúdo integrado de gelo e de água líquida presentes nas nuvens geradoras de extremos de precipitação. Estas sub-regiões também apresentaram as maiores taxas de precipitação extrema diária, respectivamente, 7,4 mm/h e 7,0 mm/h. Este resultado é bastante preocupante, pois é sabido que nestas regiões, especialmente do litoral leste do NEB, se concentra a maior frequência de população em áreas de risco e ocorrências de desastres naturais no NEB.

É interessante ressaltar que o sudeste do NEB apresentou a menor taxa de precipitação extrema. As nuvens responsáveis pela precipitação extrema sobre esta área apresentaram também as menores quantidades de conteúdo integrado de gelo e conteúdo integrado de água líquida em comparação com as nuvens sobre as demais áreas do NEB. A maior frequência de significâncias estatísticas são apresentadas entre a comparação com esta área e as demais. O sudeste do NEB difere estatisticamente (valor- $p < 0,05$ ) das demais áreas do NEB em relação a taxa de precipitação em superfície, conteúdo integrado de gelo e conteúdo integrado de água líquida, com exceção da comparação entre o norte do NEB em relação ao conteúdo de água líquida (valor- $p > 0,05$ ).

Em todas as áreas do NEB a precipitação extrema é ocasionada com maior frequência pela nuvem do tipo convectiva, em média 74%. A altura do nível de congelamento da nuvem também é semelhante para todas as áreas do NEB, sua média varia entre 4.796,0 e 4.852,8 metros, resultados semelhantes foram encontrados pela literatura (Harris et al. 2000; Abreu et al., 2018).

Espera-se que os resultados encontrados neste trabalho auxiliem pesquisadores que desejam estudar sobre parametrizações de modelos de precipitação extrema, mudanças climáticas, disponibilidade de recursos hídricos, entre outros.



## CAPÍTULO 6

### CONSIDERAÇÕES FINAIS

Esta pesquisa consistiu em analisar os eventos de precipitação diária no NEB. Para isso se fez uso de duas fontes de dados. Uma proveniente de 94 pluviômetros distribuídas no NEB e outra derivada dos produtos 3B42, 2ACLIM e 2A12 do satélite TRMM. Inicialmente, se avaliou quatro métodos estatísticos de imputação múltipla para o preenchimento de dados faltantes em séries de dados de precipitação diária. A avaliação foi feita por meio das medidas estatísticas, como viés e coeficiente de correlação, entre as séries de dados completas e as preenchidas por cada método. Observou-se que quanto maior a quantidade de dados faltantes menor a qualidade do preenchimento do mesmo. Dentre os métodos analisados o de BootEM se destacou apresentando os melhores resultados. Portanto, este método pode ser uma ferramenta que venha a corroborar com a reconstrução de séries históricas de dados de precipitação que auxiliam no monitoramento e planejamento dos recursos hídricos.

A capacidade do produto 3B42 do satélite TRMM em estimar corretamente a presença e intensidade da precipitação diária e extrema foi avaliada em comparação com a precipitação observada por meio dos pluviômetros. Foi verificado que a qualidade das estimativas do TRMM em relação à intensidade da precipitação diária irá depender do período sazonal e local de ocorrência. Em geral, os valores estimados pelos satélite TRMM são estatisticamente iguais aos observados pelos pluviômetros, exceto no litoral leste do NEB, especialmente em JJA. Apesar deste resultado, foi observado que satélite TRMM é capaz, de pelo menos, captar a presença de precipitação nesta região. Além disso, foi observado que o satélite não apresentou boas estimativas de precipitação extrema diária. Porém, a chuva acumulada em dois dias é o suficiente para obter melhores resultados em relação a qualidade das estimativas de precipitação extremas provindas do satélite

Os resultados do modelo GPD utilizando os dados de precipitação diária extrema provenientes dos dois bancos de dados, pluviômetro e TRMM, foram estatisticamente iguais. Sendo assim, ajustou-se o modelo GPD aos dados de precipitação extrema para cada um dos 2.088 pontos de grade estimados pelo satélite TRMM. Tornando possível a construção de mapas que representam a distribuição espacial dos níveis de retorno dos eventos de precipitação extrema no NEB. Estes resultados foram associados aos desastres

naturais ocorridos nos últimos três anos, 2016, 2017 e 2018, no NEB. As regiões onde se espera os maiores acumulados de precipitação extrema são coincidentes com as regiões onde ocorreram as maiores frequências de desastres naturais, segundo a base de dados do CEMADEN.

Com base nos resultados da análise de *cluster* sobre os dados diários de precipitação observados pelos pluviômetros foi possível determinar cinco sub-regiões para o NEB. Estas estão coerentes com as condições locais e com as atuações dos principais sistemas geradores de precipitação no NEB, como ZCIT, ZCAS, DOL, VCAN, entre outros. Após a determinação das cinco sub-regiões do NEB, por meio dos dados dos produtos 2ACLIM e 2A12 do satélite TRMM, definiu-se um modelo empírico com as características microfísicas do conteúdo integrado de gelo, conteúdo integrado de água líquida na nuvem, taxa de precipitação em superfície, altura do nível de congelamento e tipo de chuva das nuvens causadoras de precipitação extrema sobre as cinco sub-regiões do NEB.

Com base no exposto pode-se destacar as seguintes conclusões:

- ✓ Os métodos estatísticos de imputação múltipla são capazes de preencher dados faltantes de precipitação diária para o NEB. Os melhores resultados foram observados para o método BootEM.
- ✓ A localização geográfica e o número de dados faltantes da série de dados influenciam na qualidade dos métodos estatísticos de imputação múltipla.
- ✓ O NEB possui cinco sub-regiões homogêneas de acordo com a precipitação diária.
- ✓ A qualidade das estimativas de precipitação diária do produto 3B42 do satélite TRMM irá depender do período sazonal e localização em que a precipitação ocorre.
- ✓ As estimativas do TRMM e as observações dos pluviômetros em relação a precipitação diária acima do percentil 95% são estatisticamente iguais.
- ✓ O nível de retorno dos eventos extremos de precipitação diária irá depender do período sazonal e localização em que o mesmo ocorre sobre o NEB.
- ✓ Os maiores níveis de retorno da precipitação extrema são esperados nos locais de maiores ocorrências de desastres naturais no NEB.
- ✓ Foi possível, por meio do produto 2ACLIM e 2A12, avaliar as diferenças entre as sub-regiões do NEB de acordo com cada parâmetro microfísico da nuvem geradora de precipitação extrema.
- ✓ Definiu-se um modelo empírico que representa as características microfísicas das

nuvens geradoras de precipitação extrema nas sub-regiões do NEB.

Os resultados obtidos nesta tese deram indícios para estudos futuros, conforme listado a seguir:

- ✓ Avaliar a qualidade do método BootEM de imputação múltipla para o preenchimento de dados faltantes de precipitação extrema.
- ✓ Analisar a capacidade das estimativas de precipitação mensal do satélite TRMM e GPM.
- ✓ Expandir a metodologia utilizada para as estimativas dos níveis de retorno de precipitação extrema para outras regiões do Brasil.
- ✓ Utilizar um modelo estatístico da TVE que permite a inclusão de outros parâmetros climáticos (covariáveis) para estimar os níveis e períodos de retorno da precipitação extrema.
- ✓ Investigar as características microfísicas das nuvens de acordo com o tipo de chuva.
- ✓ Comparar as características microfísicas das nuvens geradora de diferentes escalas de intensidade de precipitação.

## REFERÊNCIAS

ABILD, J., ANDERSEN, E.Y. AND ROSBJERG, D. (1992) The climate of extreme winds at the Great Belt, Denmark. *Journal of Wind Engineering and Industrial Aerodynamics*, 41(1-3), 521-532. doi:10.1016/0167-6105(92)90458-M.

ABIODUN, B.J, OMAR, S.B, LENNARD, C., JACK, L. (2016). “Using regional climate models to simulate extreme rainfall events in the Western Cape, South Africa.” *International Journal of Climatology* 36 (2), 689–705. <https://doi.org/10.1002/joc.4376>.

ABREU, L.P, GONÇALVES, W.A., MATTOS, E.V. (2018) Relâmpagos no nordeste do Brasil: ocorrência, variabilidade espaço-temporal e relação com a microfísica das nuvens, 131p. Universidade Federal do Rio grande do Norte, Natal, Brasil.

ACERO, F.J., PAREY, S., GARCÍA, J.A. AND DACUNHA-CASTELLE, D. (2018) Return Level Estimation of Extreme Rainfall over the Iberian Peninsula: Comparison of Methods. *Water*, 10(179), 1-16; doi:10.3390/w10020179.

ACOCK, A. C. Working with missing values. **Journal of Marriage and Family**, Wiley Online Library, v. 67, p. 1012–1028. 2005.

AIEB, A., MADANI, K., SCARPA, M., BONACORSO, B., LEFSIH, K. (2019). A new approach for processing climate missing databases applied to daily rainfall data in Soummam watershed, Algeria. *Heliyon*, 5(2), e01247.

AKBARI, A., DARYABOR, F., SAMAH, A.A., FANODI, M. (2017). “Validation of TRMM 3B42 V6 for estimation of mean annual rainfall over un gauged area in semiarid climate.” *Environmental Earth Sciences* 76 (15), 537. <https://doi.org/10.1007/s12665-017-6867-3>.

ALLISON, P.D. (2001). *Missing data*. Design and Inference. Sage University Papers Series on quantitative applications in the social sciences. Thousand Oaks (CA). Cap. 4, p.72-89.

ALVARES, C.A., STAPE, J.L., SENTELHAS, P.C., GONÇALVES, J.L.D.M., SPAROVEK, G. (2013). “Koppen’s climate classification map for Brazil.” *Meteorologische Zeitschrift* 22(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>.

AN, Y. AND PANDEY, M.D. (2005) A comparison of methods of extreme wind speed estimation. *Journal of Wind Engineering and Industrial Aerodynamics*, 93(7), 535-545. doi:10.1016/j.jweia.2005.05.003.

ANDREOLI, R.V. AND KAYANO, M.T. (2007) A importância relativa do Atlântico Tropical Sul e Pacífico leste na variabilidade de precipitação do Nordeste do Brasil. *Revista Brasileira de Meteorologia*, 22(1), 63-74, doi: 10.1590/S0102-77862007000100007.

AUMANN, H.H., BEHRANGI, A., AND WANG, Y. (2018) Increased frequency of extreme tropical deep convection: AIRS observations and climate model predictions. *Geophysical Research Letters*, 45(24), 13-530, doi: 10.1029/2018GL079423.

AWAKA, J.; IGUCHI, T.; KUMAGAI, H.; OKAMOTO, K. Rain type classification algorithm for trmm precipitation radar. *Geoscience and Remote Sensing Symposium*, v. p. 1633–1635, 1997.

BANZE B.E. (2016) Avaliação dos modelos de estimativa de precipitação do TRMM em Moçambique, Universidade de São Paulo, Brasil.

BARBOSA, H.A., HUETE, A.R., BAETHGEN, W.E. (2006). “A 20-year study of NDVI variability over the Northeast Region of Brazil.” *Journal of Arid Environments* 67 (2), 288-307. <https://doi.org/10.1016/j.jaridenv.2006.02.022>.

BAUTISTA, E. A. L.; ZOCCHI, S. S.; ANGELOCCI, L. R. A distribuição generalizada de valores extremos aplicada ao ajuste dos dados de velocidade máxima do vento em Piracicaba, São Paulo, Brasil. *Revista Matemática e Estatística*, v. 22, p. 95 - 111, 2004.

BEAUFORT, A., GIBIER, F., PALANY, P. (2019). “Assessment and correction of three satellite rainfall estimate products for improving flood prevention in French Guiana.” *International Journal of Remote Sensing* 40(1), 171-196. DOI: 10.1080/01431161.2018.1511934

BEHRANGI, A., KHAKBAZ, B., JAW, T.C., AGHAKOUCHAK, A., HSU, K. AND SOROOSHIAN, S. (2011) Hydro-logic evaluation of satellite precipitation products over a mid-size basin. *Journal of Hydrology*, 397(3), 225–237, doi: 10.1016/j.jhydrol.2010.11.043.

BEHRENS, C., GAMERMAN, D. e LOPES, H. F. Bayesian analysis of extreme events with threshold estimation. *Statistical Modelling*, v. 4, p. 227-244. 2004.

BERTOLDO, S.; LUCIANAZ, C.; ALLEGRETTI, M. Gauges in a Variety of Geographical Situations. *Atmospheric and Climate Sciences*, v. 5, p. 82 - 90 2015.

BEZERRA, B.G., SILVA, L., SANTOS E SILVA, C.M., CARVALHO, G.G. (2012). “Changes of precipitation extremes indices in São Francisco River Basin, Brazil from 1947 to 2012.” *Theoretical and Applied Climatology* 1-12. <https://doi.org/10.1007/s00704-018-2396-6>.

BOMBARDI, R.J., CARVALHO, L.M.V. AND JONES, C. (2014) Simulating the influence of the South Atlantic dipole on the South Atlantic convergence zone during neutral ENSO. *Theoretical and Applied Climatology*, 118(1-2), 251-269, doi: 10.1007/s00704-013-1056-0.

BOMBARDI, R.J., TRENARY, L., PEGION, K., BENJAMIN, C., DELSOLE, T., KINTER III, J.L. (2018). “Seasonal Predictability of Summer Rainfall over South America.” *Journal of Climate* 31(20), 8181-8195. <https://doi.org/10.1175/JCLI-D-18-0191.1>.

- BORZOOEI, S., MIRANDA, G. H., TEEGAVARAPU, R., SCIBILIA, G., MEUCCI, L., ZANETTI, M. C. (2019). Assessment of weather-based influent scenarios for a WWTP: Application of a pattern recognition technique. *Journal of environmental management*, 242, 450-456.
- BOX, G.E.P. AND COX, D.R. (1964) An analysis of transformations (with discussion). *Journal of the Royal Statistical Society B*, 26, 211–252.
- BRAGA, R.C. (2013) *Estudo do conteúdo de gelo das nuvens em função do ciclo de vida utilizando sensores em micro-ondas passivos*. Instituto Nacional de Pesquisas Espaciais (INPE), São José Dos Campos, Brazil.
- BRITO, B.M., LEVIT, V., FEDOROVA, N., MOLION, L.C.B. (2011) Análise do comportamento das trovoadas no estado de Alagoas, previsão, Revista Brasileira de Meteorologia, 26(2), 243 - 256, doi: 10.1590/S0102-77862011000200009.
- BROWN, M.B., AND FORSYTHE, A.B. (1974) Robust tests for the equality of variances. *Journal of the American Statistical Association*, 69(346), 364-367.
- BUHI, E. R.; GOODSON, P.; NEILANDS, T. B. Out of sight, not out of mind: strategies for handling missing data. *American journal of health behavior*, PNG Publications, v.32, p. 83–92. 2008.
- BURHANUDDIN, S. N. Z. A., DENI, S. M., RAMLI, N. M. (2017). Normal ratio in multiple imputation based on bootstrapped sample for rainfall data with missingness. *International Journal of GEOMATE*, 13(36), 131-137.
- BURKE, S. (1998). Missing values, outliers, robust statistics & non-parametric methods. *Scientific Data Management*, 1, 32-38.
- BUUREN, S. V.; GROOTHUIS OUDSHOORN, K. Mice: Multivariate imputation by chained equations in R. *Journal of statistical software*, American Statistical Association, Vol. 45, p. 18-31. 2011.
- CAI, Y., JIN, C., WANG, A., GUAN, D., WU, J., YUAN, F., XU, L. (2015). “Comprehensive precipitation evaluation of TRMM 3B42 with dense rain gauge networks in a mid-latitude basin, northeast, China.” *Theoretical and Applied Climatology* 126(3-4), 659-671. <https://doi.org/10.1007/s00704-015-1598-4>.
- CARVALHO, L. M. V.; JONES C.; LIEBMANN. B. Extreme Precipitation Events in Southeastern South America and Large-Scale Convective patterns in the South Atlantic Convergence Zone. *Journal of Climate*, v. 15, p. 2377-2394. 2002.
- CARVALHO, L. M. V.; JONES, C.; LIEBMANN, B. The South Atlantic Convergence Zone: intensity, form, persistence, and relationships with intraseasonal to interannual activity and extreme rainfall. *Journal of Climate*, v. 17, p. 88-108, 2004.
- CAVALCANTI, I. F. A.; FERREIRA, N. J.; JUSTI DA SILVA; M. G. A., SILVA DIAS; M. A. F. Tempo e Clima no Brasil. *Oficina de Textos*, São Paulo, Brasil, 197-212, 2009.

CAVALCANTI, I.F.A. Large scale and synoptic features associated with extreme precipitation over South America: a review and case studies for the first decade of the 21st century. *Atmospheric Research*, v. 118, p. 27–40. 2012.

CHAKRAVARTY, K., RAJ, P.E., BHATTACHARYA, A. AND MAITRA, A. (2013) Microphysical characteristics of clouds and precipitation during pre-monsoon and monsoon period over a tropical Indian station. *Journal of Atmospheric and Solar-Terrestrial Physics*, 94, 28-33.

CHAMBERS, J.M., FREENY, A. AND HEIBERGER, R.M. (1992) Analysis of variance; designed experiments. Chapter 5 of *Statistical Models in S*. Wadsworth and Brooks/Cole Advanced Books and Software, Pacific Grove, CA, USA, p. 145-193.

CHEN, S., LI, Y., KIM, J., AND KIM, S.W. (2016) Bayesian change point analysis for extreme daily precipitation. *International Journal of Climatology*, 37(7), 3123-3137, doi: 10.1002/joc.4904.

CHEN, S., Y. HONG, J. J. GOURLEY, G. J. HUFFMAN, Y. TIAN, Q. CAO, B. YONG, P. E. KIRSTETTER, J. HU, J. HARDY, Z. LI, S. I. KHAN, AND X. XUE. 2013. “Evaluation of the Successive V6 and V7 TRMM Multisatellite Precipitation Analysis over the Continental United States. *Water Resources Research* 49 (12), 8174–86. doi: <https://doi.org/10.1002/2012WR012795>.

COELHO, A.E., ADAIR, J.G., MOCELLIN, J.S.P. 2004. “Psychological responses to drought in Northeastern Brazil.” *Interamerican Journal of Psychology* 38(1), 95-103.

COHEN, J. C. P.; SILVA DIAS, M. A. F.; NOBRE, C. A. Environmental conditions associated with Amazonian squall lines: A case study. **Monthly Weather Review**, v. 123, p. 3163-3174, 1995.

COLES, S.G. **An Introduction to Statistical Modeling of Extreme Values**. Springer Verlag, London, 2001.

COSTA, M.S. , LIMA, K.C., ANDRADE, M.M., GONÇALVES, W.A. (2015) Trends observed in precipitation extremes over the semiarid region of Northeast Brazil. *Revista Brasileira de Geografia Física*, 8, 1321-1334, doi: 10.5935/1984-2295.20150071.

CURTARELLI, M.P., RENNO, C.D., 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, 1-14. <https://doi.org/10.1117/1.JRS.8.083589>.

DA SILVA, P.E., SANTOS E SILVA, C.M., SPYRIDES, M.H.C., AND ANDRADE, L.D.M.B. (2019). Precipitation and air temperature extremes in the Amazon and northeast Brazil. *International Journal of Climatology*, 39(2), 579-595, doi: 10.1002/joc.5829.

DARAND M., AMANOLLAHI J., ZANDKARIMI, S. 2017. “Evaluation of the performance of TRMM Multi-satellite Precipitation Analysis (TMPA) estimation over Iran.” *Atmospheric Research* 190, 121–127.

DEGAETANO, A. T. Time-Dependent Changes in Extreme-Precipitation Return-Period Amounts in the Continental United States. *Journal of Applied Meteorology and Climatology*, v.48, p. 2086-2099. 2009.

DELLA-MARTA, P.M., MATHIS, H., FREI, C., LINIGER, M.A., KLEINN, J. AND APPENZELLER, C. (2009) The return period of wind storms over Europe. *International Journal of Climatology*, 29(3), 437-459, doi:10.1002/joc.1794.

DEMIRDJIAN, L., ZHOU, Y. AND HUFFMAN, G.J. (2018) Statistical modeling of extreme precipitation with TRMM data. *Journal of applied meteorology and climatology*, 57(1), 15-30, 10.1175/JAMC-D-17-0023.1.

DI ZIO, M; GUARNERA, U. Semiparametric Predictive Mean Matching. *AStA Advances in Statistical Analysis*, v.93, p. 175-186. 2009.

DIKBAS, F. Frequency based imputation of precipitation. *Stochastic Environmental Research and Risk Assessment*, p. 1-20. 2016.

DONAT, M. G., LOWRY, A. L., ALEXANDER, L. V., O'GORMAN, P. A., AND MAHER, N. (2016) More extreme precipitation in the world's dry and wet regions. *Nature Climate Change*, 6(5), 508, doi: 10.1038/nclimate2941.

DOS SANTOS, C.A.C., DE BRITO, J.I., JÚNIOR, C.H.D.S., AND DANTAS, L.G. (2012) Trends in precipitation extremes over the northern part of Brazil from Era40 dataset. *Revista Brasileira de Geografia Física*, 5(4), 836-851.

DRISCOLL, W. C. (1996) Robustness of the ANOVA and Tukey-Kramer statistical tests. *Computers & Industrial Engineering*, 31(1-2), 265-268.

DU, H., ALEXANDER, L.V., DONAT, M.G., LIPPMANN, T., SRIVASTAVA, A., SALINGER, J., KRUGER, A., CHOI, G., HE, H., FUJIBE, F., RUSTICUCCI, M., NANDINTSETSEG, B., MANZANAS, R., REHMAN, S., ABBAS, F., ZHAI, P., YABI, I., STAMBAUGH, M., WANG, S., BATBOLD, A., OLIVEIRA, P. T., ADREES, M., HOU, W., ZONG, S., E SILVA, C.M.S., LUCIO, P. AND WU, Z. (2019) Precipitation from Persistent Extremes is Increasing in Most Regions and Globally. *Geophysical Research Letters*, 46(11), 6041-6049, doi: 10.1029/2019GL081898.

DUNN, O.J. (1964). Multiple comparisons using rank sums. *Technometrics*, 6(3), 241-252.

EFRON, B. 1994. Missing Data, Imputation, and the Bootstrap. *Journal of the American Statistical Association* 89(426), 475–478. <https://doi.org/10.2307/2290846>.

EFRON, B. Missing data, imputation, and the bootstrap, *Journal of the American Statistical Association*, v.89, p. 463– 478. 1994.

ENGEL, T., FINK, A.H., KNIPPERTZ, P., PANTE, G. AND BLIEFERNICHT, J. (2017) Extreme precipitation in the West African cities of Dakar and Ouagadougou: Atmospheric dynamics and implications for flood risk assessments. *Journal of Hydrometeorology*, 18(11), 2937-2957, doi: 10.1175/JHM-D-16-0218.1.



ENGELS, J. M; DIEHR, P. Imputation of missing longitudinal data: a comparison of methods, *Journal of Clinical Epidemiology*, 2003; 56(10):968-76.

FANG, J., YANG, W., LUAN, Y., DU, J., LIN, A. AND ZHAO, L. (2019) Evaluation of the TRMM 3B42 and GPM IMERG products for extreme precipitation analysis over China. *Atmospheric Research*, 223, 24-38, doi: 10.1016/j.atmosres.2019.03.001.

FEDOROVA, N., DOS SANTOS, D.M.B., SEGUNDO, M.M.L. AND LEVIT, V. (2016) Middle Tropospheric Cyclonic Vortex in Northeastern Brazil and the Tropical Atlantic. *Pure And Applied Geophysics*, 174(1), 397-411, doi: 10.1007/s00024-016-1381-1.

FEDOROVA, N., LEVITE, V., CAMPOS, A.M.V. (2018). “Brazilian Northeast Jet stream: association with synoptic-scale systems.” *Meteorological Applications* 25(2), 261-268. <https://doi.org/10.1002/met.1693>.

FERNANDEZ, J. P., FRANCHITO, S. H., RAO, V. B., & LLOPART, M. (2017). Changes in Koppen–Trewartha climate classification over South America from RegCM4 projections. *Atmospheric Science Letters*, 18(11), 427-434, doi: 10.1002/asl.785.

FERNANDES, R. C., LUCIO, P. S., FERNANDEZ, J. H. (2017). Data imputation analysis for Cosmic Rays time series. *Advances in Space Research*, 59(9), 2442-2457.

FERREIRA, A. G; MELLO, G da S. Principais sistemas atmosféricos atuantes sobre a região nordeste do brasil e a influência dos oceanos Pacífico e atlântico no clima da região. *Revista Brasileira de Climatologia*, v.1, p. 15-28. 2005.

FIELD, C. B., BARROS, V., STOCKER, T. F., AND DAHE, Q. (2012) *Managing the risks of extreme events and disasters to advance climate change adaptation: special report of the intergovernmental panel on climate change*. Cambridge, UK, and New York, NY, USA: Cambridge University Press, p. 3-21.

FIGUEROA, S.N.; SATYAMURTY, P.; SILVA DIAS, P.L. Simulations of the summer circulation over the South American region with an Eta coordinate model. *J. Atmos. Physics.*, v. 52, p. 1573-1584. 1995.

FISHER, B. AND WOLFF, D.B. (2010) Satellite Sampling and Retrieval Errors in Regional Monthly Rain Estimates from TMI, AMSR-E, SSM/I, AMSU-B, and the TRMM PR, *Journal of Applied Meteorology and Climatology*, 50(5), 994–1023, doi:10.1175/2010jamc2487.1, 2010.

FISHER, R. A., AND TIPPETT, L. H. C. (1928) Limiting forms of the frequency distribution of the largest or smallest member of a sample. *Mathematical Proceedings of the Cambridge Philosophical Society*. Cambridge University Press, 24(2), 180-190, doi:10.1017/S0305004100015681.

FIRAT, M., DIKBAS, F., KOÇ, A. C., GUNGOR, M. (2010). Missing data analysis and homogeneity test for Turkish precipitation series. *Sadhana*, 35(6), 707.

FRANCHITO, S.H., RAO, V.B., VASQUES, A.C., SANTO, C.M.E., CONFORTE, J.C. 2009. Validation of TRMM precipitation radar monthly rainfall estimates over Brazil. *Journal of Geophysical Research* 114(D2), 1-9. <https://doi.org/10.1029/2007JD009580>.

FRANK, N.L. On the energetics of the cold lows. *Proceedings of the Symposium on Tropical Meteorology, American Meteorological Society, EIV I-EIV 6, Boston, USA. 1970.*

FU, G.B., YU, et al. Temporal variation of extreme rainfall events in China, 1961–2009. *Journal of Hydrology*. v. 487, p. 48–59. 2013.

FU, Y. (2014) Cloud parameters retrieved by the bispectral reflectance algorithm and associated applications. *Journal of Meteorological Research*, 28(5), 965–982, doi: 10.1007/s13351-014-3292-3.

FU, Y., PAN, X., YANG, Y., CHEN, F. AND LIU, P. (2017) Climatological characteristics of summer precipitation over East Asia measured by TRMM PR: A review. *Journal of Meteorological Research*, 31(1), 142-159, doi: 10.1007/s13351-017-6156-9.

GAMERMAN, D; LOPES, H. F. Markov chain Monte Carlo: Stochastic Simulation (orminimum) values of meteorological events. *Quarterly Journal of the Royal Meteorology Society*, v. 81, p. 158-171, 2006.

GAN, M.A., KOUSKY, V.E. Vórtices ciclônicos da alta troposfera no oceano Atlântico Sul. *Revista Brasileira de Meteorologia*, v. 1, p. 19-28.1986.

GAONA, R. M. F., A. OVEREEM, H. LEIJNSE, AND R. UIJLENHOET. 2016. “First-Year Evaluation of GPM Rainfall over the Netherlands: IMERG Day 1 Final Run (V03D).” *Journal of Hydrometeorology* 17 (11): 2799–2814. doi:10.1175/JHM-D-16-0087.1.

GARCÍA CUETO, O. R.; SANTILLÁN SOTO, N.; QUINTERO NUÑEZ, M.; OJEDA BENITEZ, S.; VELÁZQUEZ LIMÓN, N. Extreme temperature scenarios in Mexicali, Mexico under climate change conditions. *Atmósfera*, v.26, p. 509-520. 2013.

GILMORE, M.S., STRAKA, J.M. AND RASMUSSEN, E.N. (2004) Precipitation uncertainty due to variations in precipitation particle parameters within a simple microphysics scheme. *Monthly weather review*, 132(11), 2610-2627, doi: 10.1175/MWR2810.1.

GOBIN, A., NGUYEN, H.T., PHAM, V.Q., AND PHAM, H.T.T. (2016) Heavy rainfall patterns in Vietnam and their relation with ENSO cycles. *International Journal of Climatology*, 36(4), 1686-1699, doi: 10.1002/joc.4451.

GOMES, H.B., AMBRIZZI, T., DA SILVA, B.F.P., HODGES, K., DIAS, P.L.S., HERDIES, D.L., SILVA, M.C.L. AND GOMES, H.B. (2019) Climatology of easterly wave disturbances over the tropical South Atlantic. *Climate Dynamics*, 51(3-4), 1393-1411, doi: 10.1007/s00382-019-04667-7.

GOMES, H.B., TÉRCIO, A., HERDIES, D.L., HODGES, K. AND DA SILVA, B.F.P. (2015) Easterly wave disturbances over Northeast Brazil: an observational analysis. *Advances in Meteorology*, 2015, 1-20, doi: 10.1155/2015/176238.

GREENWALD, T.J., STEPHENS, G.L., VONDER HAAR, T.H. AND JACKSON, D.L. (1993) A physical retrieval of cloud liquid water over the global oceans using Special Sensor Microwave/Imager (SSM/I) observations. *Journal of Geophysical Research: Atmospheres*, 98(D10), 18471-18488, doi: 10.1029/93JD00339.

GRIMM, A.M., TEDESCHI, R.G. ENSO and extreme rainfall events in South America. *Journal of Climate*, v. 22, p. 1589–1609. 2009.

GROISMAN, P. Y.; KNIGHT, R. W.; EASTERLING, D. R; KARL, T. R; HEGERL, G. C.; RAZUVAEV, V. N. Trends in intense precipitation in the climate record. *Journal of Climate*, v. 18, p. 1326-1350, 2005.

GUO, H., CHEN, SH., BAO, A., HU, J., YANG, B., STEPANIAN, P.M. 2016. “Comprehensive evaluation of high-resolution satellite-based precipitation products over China.” *Atmosphere* 7(1), 1-25. <https://doi.org/10.3390/atmos7010006>.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. *Análise multivariada de dados*. Trad. Adonai S. Sant’Anna e Anselmo C. Neto. 5 ed. Porto Alegre: Bookman, 2006.

HAN, M., BRAUN, S. A., OLSON, W. S., PERSSON, P. O. G. AND BAO, J. W. (2010) Application of TRMM PR and TMI measurements to assess cloud microphysical schemes in the MM5 for a winter storm. *Journal of Applied Meteorology and Climatology*, 49(6), 1129-1148.

HANN, Z. *Actuarial Modelling of Extremal Events Using Transformed Generalized Extreme Value Distributions and Generalized Pareto Distributions.*, Tese 91f. Universidade do Estado de Ohio, 2003.

HASTENRATH, S. AND HELLER, L. (1977) Dynamics of climatic hazards in Northeast Brazil. *Quarterly Journal of the Royal Meteorological Society*, 103(435), 77-92.1977, doi: 10.1002/qj.49710343505.

HASTENRATH, S. Interannual variability and annual cycle: mechanisms of circulation and climate in the tropical Atlantic sector. *Monthly Weather Review*, 112, p. 1097–1107. 1984.

HASTENRATH, S.; GREISCHAR, L. Circulation mechanisms related to northeast Brazil rainfall anomalies. *Journal of Geophysical Research*, v. 98, p. 0148-0227. 1993.

HAYLOCK, M. R.; PETERSON, T.; ABREU DE SOUSA, J. J.; ALVES, L. M.; AMBRIZZI, T.; BAEZ, R.; BARBOSA DE BRITO, J. I.; BARROS, V. G.; BERLATO, M. A.; BIDEGAIN, M.; CORONEL, G. C. V.; GARCIA V. J. D.; JAILDO DOS ANJOS, R.; KAROLY, M. J. A. C.; MARINO, M. B.; MEIRA, P. R.; MIRANDA, G. D.; MOLION, L.; MUNCUNIL, D. F.; NECHET, E.; ONTANEDA, G.; QUINTANA, J.; RAMIREZ, L.; REBELLO, E.; RUSTICUCCI, M.; SANTOS, J. M.; VARILLAS, I. T.; VINCENT, L.; YUMIKO, M. Trends in total and extreme South American rainfall in

1960-2000 and links with sea surface temperature. *Journal of Climate*, v.19, p. 1490 – 1512. 2006.

HEATON, M.J., KATZFUSS, M., RAMACHANDAR, S., PEDINGS, K., GILLELAND, E., MANNSHARDT-SHAMSELDIN, E., AND SMITH, R.L. (2011) Spatio-temporal models for large-scale indicators of extreme weather. *Environmetrics*, 22(3), 294-303, doi: 10.1002/env.1050.

HEIBLUM, R. H., KOREN, I. AND ALTARATZ, O. (2011) Analyzing coastal precipitation using TRMM observations. *Atmospheric Chemistry and Physics*, 11(24), 13201-13217.

HERMANCE, J.F., SULIEMAN, H.M. 2018. “Adequacy of the daily TMPA 3B42 high-resolution satellite precipitation product for monitoring hydro meteorological hazards in the Southeast Sahel of Africa.” *International Journal of Remote Sensing* 39(8), 2579-2596. <https://doi.org/10.1080/01431161.2018.1430405>.

HOBOUCHIAN, M.P., SALIO, P., SKABAR, Y.G., VILA, D. AND GARREAUD, R. (2017) Assessment of satellite precipitation estimates over the slopes of the subtropical Andes. *Atmospheric Research*, 190, 43–54, doi: 10.1016/j.atmosres.2017.02.006.

HONAKER, J., KING, G., BLACKWELL, M. 2011. “Amelia II: A Program for Missing Data.” *Journal of Statistical Software* 45(7), 1–47. <https://doi.org/10.18637/jss.v045.i07>.

HONAKER, J.; KING, G.; BLACKWELL, M. Amelia II: A Program for Missing Data. *Journal of Statistical Software*, v.45, p. 1–47. 2011.

HORTON, N. J.; KLEINMAN, K. P. Much ado about nothing: a comparison of missing data methods and software to fit incomplete data regression models. *The American Statistician*, v. 61, p. 79-90.2007.

HORTON, N. J.; LIPSITZ, S. R. Multiple imputation in practice: comparison of software packages for regression models with missing variables. *The American Statistician* v. 55, p. 244-54. 2001.

HOUZE, R. Mesoscale convective systems. *Reviews of Geophysics*, v. 42, p. 1–43. 2004.

HU, Q., D. YANG, Y. WANG, AND H. YANG. 2013. “Accuracy and Spatio-Temporal Variation of High Resolution Satellite Rainfall Estimate over the Ganjiang River Basin.” *Science China Technological Sciences* 56 (4): 853–865. doi:10.1007/s11431-013-5176-7

HUANG, J., MINNIS, P., LIN, B., YI, Y., KHAIYER, M. M., ARDUINI, R. F., FAN A. AND MACE, G. G. (2005) Advanced retrievals of multilayered cloud properties using multispectral measurements. *Journal of Geophysical Research: Atmospheres*, 110 (D15).

HUFFMAN, G.J., ADLER, R.F., ARKIN, P., CHANG, A., FERRARO, R., GRUBER, A., JANOWIAK, J., MCNAB, A., RUDOLF, B., SCHNEIDER, U. 1997. “The Global Precipitation Climatology Project (GPCP) Combined Precipitation Dataset.” *Bulletin of the American Meteorological Society* 78(1): 5-20. <https://doi.org/10.1175/15200477>.

HUFFMAN, G.J., ADLER, R.F., BOLVIN, D.T., GU, G., NELKIN, E.J., BOWMAN, K.P., HONG, Y., STOCKER, E.F., WOLFF, D.B. 2007. “The TRMM Multisatellite Precipitation Analysis (TMPA): quasi-global, multiyear, combined-sensor precipitation estimates at fine scales.” *Journal of Hydrometeorology* 8 (1), 38–55. <https://doi.org/10.1175/JHM560.1>.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. *Sinopse do Censo Demográfico 2010*. Disponível em: [www.censo2010.ibge.gov.br](http://www.censo2010.ibge.gov.br). Acesso em: 5 set. 2016.

IMAN, R.L. AND CONOVER, W.J. (1978) Approximations of the critical region for spearman’s rho with and without ties present. *Communications in Statistics-Simulation and Computation*, 7(3), 269-282, doi: 10.1080/03610917808812076.

INMET – Instituto Nacional de Meteorologia. *Banco de Dados Meteorológicos para Ensino e Pesquisa*. Disponível em: <[www.inmet.gov.br](http://www.inmet.gov.br)>. Acesso em: 20/06/2015.

INMET – Instituto Nacional de Meteorologia. *Normais Climatológicas do Brasil 1961-1990*. Disponível em: <[www.inmet.gov.br](http://www.inmet.gov.br)>. Acesso em: 23/06/2015.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2010) *Sinopse do Censo Demográfico 2010*. [Cited 2018 Set 5]. Available from: <http://www.censo2010.ibge.gov.br>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2018) *População em áreas de risco no Brasil*. Coordenação de Geografia, IBGE, Rio de Janeiro, Brasil. p. 90.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE - IPCC (2001) *Climate Change 2001: The Scientific Basis*. Cambridge: Cambridge University Press.

IPCC – Intergovernmental Panel in Climate Change. *Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation*. Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change. Edited by C. B. Field et al. Cambridge/New York, Cambridge University Press/IPCC, 2012.

IPCC - Intergovernmental Panel on Climate Change. *Climate Change 2007: The Physical Science Basis, Summary for Policy Makers*. IPCC Geneva, 2007.

ISLAM, M. A. 2018. “Statistical comparison of satellite-retrieved precipitation products with rain gauge observations over Bangladesh.” *International Journal of Remote Sensing* 39(9), 2906-2936. DOI: 10.1080/01431161.2018.1433890

ISLAM, M.N., UYEDA, H. 2008. “Vertical variations of rain intensity in different rainy periods in and around Bangladesh derived from TRMM observations.” *International Journal of Climatology* 28(2), 273-279. <https://doi.org/10.1002/joc.1585>.

JENKINSON, A.F. The frequency distribution of the annual maximum (or minimum) of meteorological elements. *Quarterly Journal of the Royal Meteorological Society*, v. 81.p. 158-171. 1955.

JIANG, C., RYU, Y., FANG, H., MYNENI, R., CLAVERIE, M., AND ZHU, Z. 2017. "Inconsistencies of interannual variability and trends in 5 long-term satellite leaf area index products." *Global Change Biology* 23(10), 4133-4146. <https://doi.org/10.1111/gcb.13787>.

JIANG, D.; WANG, K.; LI, Z.; WANG, Q. Variability of extreme summer precipitation over Circum-Bohai-Sea region during 1961-2008. *Theoretical and Applied Climatology*, v.104, p.501-509, 2011.

JUNQUEIRA JÚNIOR, J. A; MELLO, C. R.; ALVES, G. J. Eventos extremos de precipitação no Alto Rio Grande, MG: Análise probabilística. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 19, p.301 - 308, 2015.

KATES, R.W. (2000) Cautionary tales: adaptation and the global poor. *Climatic Change*, 45(1), 5-17, doi: 10.1023/A:1005672413880.

KATIRAIE-BOROUJERDY, P.S., NASROLLAHI, N., HSU, K.L. AND SOROOSHIAN, S. (2013) Evaluation of satellite - based precipitation estimation over Iran. *Journal of Arid Environments*, 97, 205–219, doi: 10.1016/j.jaridenv.2013.05.013.

KAYANO, M. T.; ANDREOLI, R. V. Clima da região Nordeste do Brasil. In: Iracema F. A. Cavalcanti et al. (orgs). *Tempo e Clima no Brasil*, São Paulo: Oficina dos Textos, p. 213-233, 2009.

KHAIN, P., HEIBLUM, R., BLAHAK, U., LEVI, Y., MUSKATEL, H., VADISLAVSKY, E., ALTARATZ, O., KOREN, I. SHPUND, J. AND KHAIN, A. (2019) Parameterization of vertical profiles of governing microphysical parameters of shallow cumulus cloud ensembles using LES with bin microphysics. *Journal of the Atmospheric Sciences*, 76(2), 533-560, doi: 10.1175/JAS-D-18-0046.1.

KOBIYAMA, M., MENDONÇA, M., MORENO, D.A., MARCELINO, I.P.V.O., MARCELINO, E.V., GONÇALVES, E.F., BRAZETTI, L.L.P., GOERL, R.F., MOLLERI, G.S.F. AND RUDORFF, F.D.M. (2006) *Prevenção de desastres naturais: conceitos básicos*. Curitiba, Brazil. Organic Trading.

KODAMA, Y. (1992) Large-scale common features of subtropical precipitation zones (the Baiu frontal zone, the SPCZ, and the SACZ) Part I: Characteristics of subtropical frontal zones. *Journal of the Meteorological Society of Japan*, 70(4), 813-836, doi: 10.2151/jmsj1965.70.4\_813.

KOLMOGOROV, A. (1933) Sulla determinazione empirica di una legge di distribuzione. *Inst. Ital. Attuari, Giorn.*, 4, 83-91.

KOUSKY V.E., GAN, M.A. (1981) Upper tropospheric cyclonic vortices in the tropical South Atlantic. *Tellus*, 33(6), 538–551, doi: 10.1111/j.2153-3490.1981.tb01780.x.

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.

KOUSKY, V.E. (1980) Diurnal rainfall variation in northeast Brazil. *Monthly Weather Review*, 108(4), 488-498, doi: 10.1175/1520-0493(1980)108<0488:DRVINB>2.0.CO;2.

KOUSKY, V.E. AND CHUG, P.S. (1978) Fluctuations in Annual Rainfall for Northeast Brazil. *Journal of the Meteorological Society of Japan*. 56(5), 457-465, doi: 10.2151/jmsj1965.56.5\_457.

KROODSMA, R., BILANOW, S. AND MCKAGUE, D. (2018) TRMM Microwave Imager (TMI) Alignment and Along-Scan Bias Corrections, *Journal of Atmospheric and Oceanic Technology*, 35(7), 1520-0426, doi: 10.1175/JTECH-D-17-0221.1.

KUCERA, P.A., EBERT, E.E., TURK, F.J., LEVIZZANI, V., KIRSCHBAUM, D., TAPIADOR, F.J., LOEW, A. AND BORSCHKE, M. (2013) Precipitation from Space: Advancing Earth System Science. *Bulletin of the American Meteorological Society*, 94(3), 365–375, doi: 10.1175/BAMS-D-11-00171.1.

KUMMEROW, C., BARNES, W., KOZU, T., SHIUE, J. AND 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.C);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., NAKAMURA, K. 2000. “The status of the tropical rainfall measuring mission (TRMM) after two years in orbit.” *Journal of Applied Meteorology* 39, 1965–1982. <https://doi.org/10.1175/1520-0450>.

KUMMEROW, C., W.BARNES, KOZU, T., SHIUE, J., SIMPSON, J. 1998. “The Tropical Rainfall Measuring Mission (TRMM) sensor package.” *Journal of Atmospheric and Oceanic Technology* 15(3), 809–816. <https://doi.org/10.1175/1520-0426>.

LI, K. H.; RAGHUNATHAN, T. E.; RUBIN, D. B. Large-Sample Significance Levels from Multiply Imputed Data Using Moment-Based Statistics and an F Reference Distribution. *Journal of the American Statistical Association*, v.86, p. 1065-1073. 1991.

LIAO, L. AND MENEGHINI, R. (2009) Validation of TRMM precipitation radar through comparison of its multiyear measurements with ground-based radar, *Journal of Applied Meteorology and Climatology*, 48(4), 804-817, doi:10.1175/2008jamc1974.1.

LITTLE, R. J.; RUBIN, D. B. *Statistical analysis with missing data*. John Wiley & Sons 2014.

LIU, C., ZIPSER, E. J., CECIL, D. J., NESBITT, S. W. AND SHERWOOD, S. (2008) A cloud and precipitation feature database from nine years of TRMM observations. *Journal of Applied Meteorology and Climatology*, 47(10), 2712-2728.

LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. *Biometrika*, v.65, p 297–303, 1978.

LO PRESTI, R.; BARCA, E.; PASSARELLA, G. A methodology for treating missing data applied to daily rainfall data in the Candelaro River Basin (Italy). *Environmental Monitoring and Assessment*, v.160, p.1–22. 2010.

LYRA, G.B., OLIVEIRA-JÚNIOR, J.F., 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. <https://doi.org/10.1002/joc.3926>.

MADDOX, R.A., Mesoscale convective complexes. *Bull. Am. Meteorol. Soc.*, v. 61, p.1374-1387, 1980.

MAGGIONI, V., MEYERS, P.C., ROBINSON, M.D. 2016. “A Review of Merged High-Resolution Satellite Precipitation Product Accuracy during the Tropical Rainfall Measuring Mission (TRMM) Era.” *Journal of Hydrometeorology* 17(4), 1101–1117. <https://doi.org/10.1175/JHM-D-15-0190.1>.

MARENGO, J. A. Long-term trends and cycles in the hydrometeorology of the Amazon basin since the late 1920s. *Hydrological Processes*, n. 23, p. 3236-3244, 2009.

MARENGO, J. A. *Mudanças climáticas globais e seus efeitos sobre a biodiversidade - caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do século XXI*. 2. ed. Brasília: *Ministério do Meio Ambiente*, 2007. v.1, p.214.

MARENGO, J. A.; NOBRE, C. Clima da Região Amazônica. In: CAVALCANTI, N. J. et al. (Org.). *Tempo e clima no Brasil*. 1. ed. São Paulo: Oficina de Textos, 2009. p. 198-212.

MARENGO, J.A. AND ESPINOZA, J.C. (2016) Extreme seasonal droughts and floods in Amazonia: causes, trends and impacts. *International Journal of Climatology*, 36(3), 1033–1050, doi: 10.1002/joc.4420.

MARENGO, J.A. AND VALVERDE, M.C. (2007) Caracterização do clima no Século XX e Cenário de Mudanças de clima para o Brasil no Século XXI usando os modelos do IPCC-AR4. *Revista Multiciência*, 8, 5-28.

MARENGO, J.A., ALVES, L.M., SOARES, W.R., RODRIGUEZ, D.A., CAMARGO, H., RIVEROS, M.P., PABLO, A.D. 2013. “Two Contrasting Severe Seasonal Extremes in Tropical South America in 2012: Flood in Amazonia and Drought in Northeast Brazil.” *Journal of Climate* 31(22), 9137-9154. <https://doi.org/10.1175/JCLI-D-12-00642.1>.

MARENGO, J.A., JONES, R., ALVES, L.M., AND VALVERDE, M.C. (2009) Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 29(15), 2241-2255.



MARENGO, J.A., TOMASELLA, J., SOARES, W.R., ALVES, L.M., NOBRE, C.A. (2012) Extreme climatic events in the Amazon basin. *Theoretical and Applied Climatology*, v. 107, p. 73-85.

MARENGO, J.A., TORRES, R.R. AND 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.

MARSAGLIA, G., TSANG, W.W. AND WANG, J. (2003) Evaluating Kolmogorov's distribution. *Journal of Statistical Software*, 8(18), 1-4.

MATSUI, T., CHERN, J.D., TAO, W.K., LANG, S., SATOH, M., HASHINO, T. AND KUBOTA, T. (2016) On the land–ocean contrast of tropical convection and microphysics statistics derived from TRMM satellite signals and global storm-resolving models. *Journal of Hydrometeorology*, 17(5), 1425-1445, doi: 10.1175/JHM-D-15-0111.1.

MCFARQUHAR, G.M., ZHANG, H., HEYMSFIELD, G., HALVERSON, J.B., HOOD, R., DUDHIA, J. AND MARKS JR, F. (2006) Factors affecting the evolution of Hurricane Erin (2001) and the distributions of hydrometeors: Role of microphysical processes. *Journal of the atmospheric sciences*, 63(1), 127-150, doi: 10.1175/JAS3590.1.

MCKNIGHT, P. E; MCKNIGHT, K. M; SIDANI, S; FIGUEREDO, A. J. *Missing data: a gentle introduction*. New York: The Guilford Press, 2007.

MELO, A. B. C.; CAVALCANTI, I. F. A., SOUZA, P. P. *Zona de convergência intertropical do Atlântico*. In: CAVALCANTI, I. F. A.; FERREIRA, N. J., SILVA, M. G. A. J.; DIAS, M. A. F. S. *Tempo e clima no Brasil*. São Paulo: Oficina de Textos, cap. 2, p. 25-41. 2009.

MELO, C.D., XAVIER, A.C., BIANCHI, T., OLIVEIRA, P.T.S., SCANLON, B.R., LUCAS, M.C., MENDES, B. V. M. *Introdução a análise de eventos extremos*. Rio de Janeiro, E-papers. 2004.

MIMMACK, G. M.; MASON, S. J.; GALPIN, J. S. Choice of distance matrices in cluster analysis: defining regions. *Journal of Climate*, v. 14, p. 2790-2797, 2001.

MIN, Q., LI, R., LIN, B., JOSEPH, E., WANG, S., HU, Y., MORRIS, V. AND CHANG, F. (2009) Evidence of mineral dust altering cloud microphysics and precipitation. *Atmospheric Chemistry and Physics*, 9(9), 3223–3231, doi: 10.5194/acp-9-3223-2009.

MIN, S. K., ZHANG, X., ZWIERS, F. W., & HEGERL, G. C. (2011) Human contribution to more-intense precipitation extremes. *Nature*, 470(7334), 378, doi: 10.1038/nature09763.

MINGOTI, S. A. *Análise de Dados Através de Métodos de Estatística - Multivariada - Uma Abordagem Aplicada*. UFMG, 2005.

MINGOTI, S.A. 2005. *Análise de Dados Através de Métodos de Estatística - Multivariada - Uma Abordagem Aplicada*. UFMG.

MO, C., RUAN, Y., HE, J., JIN, J., LIU, P., AND SUN, G. (2018) Frequency analysis of precipitation extremes under climate change. *International Journal of Climatology*, 39(3), 1373-1387, doi: 10.1002/joc.5887.

MOLENBERGHS, G., THIJS, H., JANSEN, I., BEUNCKENS, C., KENWARD, M. G., MALLINCKRODT, C., CARROLL, R. J. (2004). Analyzing incomplete longitudinal clinical trial data. *Biostatistics*, 5(3), 445-464.

MOURA, A.D., SHUKLA, J. 1981. "On the dynamics of droughts in northeast Brazil: observations, theory and numerical experiments with a general circulation model." *Journal of the Atmospheric Sciences* 38(12), 2653-2675. <https://doi.org/10.1175/1520-0469>.

MOURA, G.B.A., ARAGÃO, J.O.R., MELO, J.S.P., SILVA, A.P.N., GIONGO, P.R. AND LACERDA, F.F. (2009) Relação entre a precipitação do leste do Nordeste do Brasil e a temperatura dos oceanos. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 13(4), 462-469, doi: 10.1590/S1415-43662009000400014.

MYLES H. AND DOUGLAS A.W. (1973) *Nonparametric Statistical Methods*. New York: John Wiley & Sons, p. 115–120.

NASA. (2015) Tropical Rainfall Measuring Mission Precipitation Processing System: File Specification 2A25.

NASA. (2017) Global Precipitation Measurement Precipitation Processing System: File Specification 2AGPROFTMI. 2017.

NASCIMENTO, F.F., GAMERMAN, D. AND LOPES, H.F. (2012) A Semiparametric Bayesian approach to extreme value estimation. *Statistics and Computing*, 22(2), 661–675, doi: 10.1007/s11222-011-9270-z.

NOBRE, P.; SHUKLA, J. Variations of sea surface temperature, wind stress, and rainfall over the tropical Atlantic and South America. *Journal of Climate*, in press. 1996.

NUNES, L. N.; KLÜCK, M.M.; FACHEL, J. M. G. Uso da imputação múltipla de dados faltantes: uma simulação utilizando dados epidemiológicos. *Caderno de Saúde Pública*, v.25, p. 268-78. 2009.

OLIVEIRA, F.P. AND OYAMA, M.D. (2019) Squall Line Initiation over the Northern Coast of Brazil in March: Observational Features. *Meteorological Applications*, 1-14, doi: 10.1002/met.1799.

OLIVEIRA, P.T., E SILVA, C.S., AND LIMA, K.C. (2017) Climatology and trend analysis of extreme precipitation in subregions of Northeast Brazil. *Theoretical and applied climatology*, 130(1-2), 77-90, doi: 10.1007/s00704-016-1865-z.

OLIVEIRA, P.T., LIMA, K.C. AND E SILVA, C.M.S. (2013) Synoptic environment associated with heavy rainfall events on the coastland of Northeast Brazil. *Advances in Geosciences*, 35, 73-78, doi: 10.5194/adgeo-35-73-2013.

OLIVEIRA, P.T., SANTOS E SILVA, C.M., LIMA, K.C. 2014. “Linear trend of occurrence and intensity of heavy rainfall events on Northeast Brazil.” *Atmospheric Science Letters* 15(3), 172-177. <https://doi.org/10.1002/asl2.484>.

PAINEL BRASILEIRO DE MUDANÇAS CLIMÁTICAS - PBMC (2013) *Contribuição do Grupo de Trabalho 1 ao Primeiro Relatório de Avaliação Nacional do Painel Brasileiro de Mudanças Climáticas*. Sumário Executivo GT1. PBMC, Rio de Janeiro, Brazil, 24 p. ISBN: 978-85-285-0208-4.

PALHARINI, R.S.A. AND VILA, D.A. (2017) Climatological Behavior of Precipitating Clouds in the Northeast Region of Brazil. *Advances in Meteorology*, 2017, 1-12, doi: 10.1155/2017/5916150.

PALUTIKOF, J.P., BRABSON, B.B., LISTER, D.H. AND ADCOCK, S.T. (1999) A review of methods to calculate extreme wind speeds. *Meteorological applications*, 6(2), 119-132. doi: 10.1017/S1350482799001103.

PAREDES, F.J., BARBOSA, H., GUEVARA, E. 2015. “Análisis espacial y temporal de las sequias en el nordeste de Brasil.” *Agriscientia* 32 (1), 1-14.

PAREDES-TREJO, F. J., BARBOSA, H. A., KUMAR, T. L. 2017. “Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil.” *Journal of arid environments* 139, 26-40.

PATRICK ROYSTON (1982). An extension of Shapiro and Wilk's W test for normality to large samples. *Applied Statistics*, 31, 115–124, doi: 10.2307/2347973.

PEDRETTI, D., AND IRANNEZHAD, M. (2018) Non-stationary peaks-over-threshold analysis of extreme precipitation events in Finland, 1961–2016. *International Journal of Climatology*, 39(2), 1128-1143. <https://doi.org/10.1002/joc.5867>

PEDRON, I.T., SILVA DIAS, M.A., DE PAULA DIAS, S., CARVALHO, L.M., AND FREITAS, E.D. (2016) Trends and variability in extremes of precipitation in Curitiba–Southern Brazil. *International Journal of Climatology*, 37(3), 1250-1264, doi: 10.1002/joc.4773.

PENG, B., SHI, J.C., NI-MEISTER, W., ZHAO, T.J., JI, D. 2014. “Evaluation of TRMM Multisatellite Precipitation Analysis (TMPA) products and their potential and semiarid basin in China.” *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7(9), 3915-3930. <https://doi.org/10.1109/JSTARS.2014.2320756>.

PEREIRA FILHO, A. J.; BARROS, M. T. L. Flood warning system for megacities: a Brazilian perspective. *International Conference on Hydrology in a changing environment, British Hydrological Society*. 1998.

PETERSEN, W.A., RUTLEDGE, S.A. (2001) Regional Variability in Tropical Convection: Observations from TRMM. *Journal of Climate*, 14(17), 3566–3586, doi: 10.1175/1520-0442%282001%29014%3C3566%3ARVITCO%3E2.0.CO%3B2>.

PICKANDS III, J. (1975) Statistical inference using extreme order statistics. *The Annals of Statistics*, 3(1), 119-131, doi:10.1214/aos/1176343003.

PNA - Plano Nacional de Adaptação à Mudança do Clima. Grupo Executivo do Comitê Interministerial de Mudança do Clima – GEx-CIM *Ministério do Meio Ambiente Brasília*, Volume I: Estratégia Geral. 2015.

POLLACK, M.M., KOCH, M.A.BARTEL, D.A., RAPOPORT, I., DHANIREDDY, R., EL-MOHANDES, A.A., HARKAVY, K., SUBRAMANIAN, K.N. 2000. “A Comparison of Neonatal Mortality Risk Prediction Models in Very Low Birth Weight Infants.” *Pediatrics* 105(5), 1051–1057. <https://doi.org/10.1542/peds.105.5.1051>.

POLZIN, D.H.S. Climate of Brazil’s nordeste and tropical atlantic sector: Preferred time scales of variability. *Rev. Bras. Meteorol*, v. 29, p. 153–160. 2014.

QIN, F., XIAN, T. AND FU, Y. (2018) Cloud-Precipitation Parameters and Radiative Forcing of Warm Precipitating Cloud over the Tropical Pacific Ocean Based on TRMM Datasets and Radiative Transfer Model. *Atmosphere*, 9(6), 206, doi: 10.3390/atmos9060206.

QUADRO, M. F. L. et al. Climatologia e precipitação e temperatura no período de 1986 a 1996. *Revista Climanalise*, São José dos Campos, v. 1, p. 90, 1996.

R DEVELOPMENT CORE TEAM. R: a language and environment for statistical computing. Vienna: R Foundation for Statistical Computing. Versão: 3.2.1. 2015.

RAO, V. B.; LIMA, M. C. D.; FRANCHITO, S. H. Seasonal and interannual variations of rainfall over eastern Northeast Brazil. *Journal of Climate*, v. 6, p. 1754-1763. 1993.

RAO, V.B., FRANCHITO, S.H., SANTO, C.M. AND GAN, M.A. (2016) 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., KRUSCHE, N., AMBRIZZI, T. AND ROCHA, R.P.D. (2012) Entendendo o Tempo e o Clima na América do Sul. *Terra e Didática*, 8(1), 34-50.

RODRIGUES, D.T., GONÇALVES, W.A., SPYRIDES, M.H.C. AND E SILVA, C.M.S. (2019) Spatial and temporal assessment of the extreme and daily precipitation of the Tropical Rainfall Measuring Mission satellite in Northeast Brazil, *International Journal of Remote Sensing*, 1-24, doi: 10.1080/01431161.2019.1643940.

RODRIGUES, R.R., CAMPOS, E.J. AND HAARSMA, R. (2015) The Impact of ENSO on the South Atlantic Subtropical Dipole Mode. *Journal of Climate*, 28(7), 2691–2705, doi: 10.1175/JCLI-D-14-00483.1.

ROPELEWSKI, C.F. AND HALPERT, M.S. (1987) Global and regional scale precipitation patterns associated with the El Niño/Southern Oscillation. *Monthly weather review*, 115(8), 1606-1626, doi: 10.1175/1520-0493(1987)115<1606:GARSPP>2.0.CO;2.

ROSENFELD, D. AND LENSKY, I.M. (1998) Satellite-based insights into precipitation formation processes in continental and maritime convective clouds. *Bulletin of the American Meteorological Society*, 79(11), 2457-2476, doi: 10.1175/1520-0477(1998)079<2457:SBIIPF>2.0.CO;2.

ROSENFELD, D., WOODLEY, W.L., KHAIN, A., COTTON, W.R., CARRIÓ, G., GINIS, I. AND GOLDEN, J.H. (2012) Aerosol effects on microstructure and intensity of tropical cyclones. *Bulletin of the American meteorological Society*, 93(7), 987-1001, doi: 10.1175/BAMS-D-11-00147.1.

ROZANTE, J.R., MOREIRA, D.S., DE GONCALVES, L.G.G., VILA, D.A. 2010. "Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America." *Weather and Forecasting* 25(3), 885-894. <https://doi.org/10.1175/2010WAF2222325.1>.

RUBIN, D. B. Comment on "Missing Data, Imputation, and the Bootstrap" by Bradley Efron, *J. Am. Statist. Assoc*, v.89, p. 475-478. 1994.

RUBIN, D. B. Inference and missing data. *Biometrika*, v.63, p.581-90. 1976.

RUBIN, D. B. Multiple imputation after 18+ years. *JASA*, v.91, p. 473-89. 1996.

RUBIN, D. B. *Multiple Imputation for Nonresponse in Surveys*. New York: John Wiley & Sons, 1987.

SALIO, P., HOBOUCHIAN, M.P., SKABAR, G., YANINA AND VILA, D. (2015) Evaluation of high-resolution satellite precipitation estimates over southern South America using a dense rain gauge network. *Atmospheric Research*, 163, 146-146, doi: 10.1016/j.atmosres.2014.11.017.

SALIO, P., HOBOUCHIAN, M.P., SKABAR, G., YANINA, VILA, D. 2015. "Evaluation of high-resolution satellite precipitation estimates over southern South America using a dense rain gauge network." *Atmospheric Research* 163, 146-146. <https://doi.org/10.1016/j.atmosres.2014.11.017>.

SANTOS E SILVA, C. M.; LUCIO, P.; SPYRIDES, M. H. C. Distribuição espacial da precipitação sobre o Rio Grande do Norte: estimativas via satélites e medidas por pluviômetros. *Revista Brasileira de Meteorologia (Impresso)*, v. 27, p. 337-346, 2012.

SANTOS, C. A. C., BRITO, J. I. B. Análise dos índices de extremos para o semi-árido do Brasil e suas relações com TSM e IVDN. *Revista Brasileira de Meteorologia*, v. 22, n. 3, p. 303-312, 2007.

SANTOS, C.A.G., BRASIL NETO, R.M., DA SILVA, R.M. AND COSTA, S.G.F. (2019) 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., DA SILVA, R.M. AND 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, doi: 10.1007/s10661-018-6536-3.

SANTOS, C.A.G., BRASIL NETO, R.M., PASSOS, J.S.A. AND DA SILVA, R.M. (2017B) Drought assessment using a TRMM-derived standardized precipitation index for the upper São Francisco River basin, Brazil. *Environmental monitoring and assessment*, 189(6), 250, doi: 10.1007/s10661-017-5948-9.

SANTOS, E.B., LUCIO, P. AND E SILVA, C.M.S. (2015) Seasonal analysis of return periods for maximum daily precipitation in the Brazilian Amazon. *Journal of Hydrometeorology*, v. 16(3), 973-984, doi: 10.1175/JHM-D-14-0201.1.

SANTOS, E.B., LUCIO, P.S., AND E SILVA, C.M.S. (2016) Estimating return periods for daily precipitation extreme events over the Brazilian Amazon. *Theoretical and Applied Climatology*, 126(3-4), 585-595, doi: /10.1007/s00704-015-1605-9.

SANTOS, M., FRAGOSO, M., AND SANTOS, J.A. (2017a) Regionalization and susceptibility assessment to daily precipitation extremes in mainland Portugal. *Applied Geography*, 86, 128-138.

SCHAEFFER, R.; SZKLO, A. S.; LUCENA, A. F. P. Climate Change and Energy Security. *Technical Report*. PPE/COPPE/UFRJ. 2008.

SCHAFER, J. L. *Analysis of Incomplete Multivariate Data*. Chapman & Hall. 1997.

SCHAFER, J. L.; GRAHAM, J. W. Missing data: our view of the state of the art. Psychological methods, *American Psychological Association*, Vol. 7, p. 147-177. 2002.

SEKARANOM, A.B., MASUNAGA, H. 2017. "Comparison of TRMM-derived rainfall products for general and extreme rains over the maritime continent." *Journal of Applied Meteorology and Climatology* 56(7), 1867-1881. [https://doi.org/ 10.1175/JAMC-D-16-0272.1](https://doi.org/10.1175/JAMC-D-16-0272.1).

SERINALDI, F. AND KILSBY, C.G. (2014) Rainfall extremes: Toward reconciliation after the battle of distributions. *Water Resources Research*, 50(1), 336–352, doi: 10.1002/2013WR014211.

SILVA DIAS, M. A. F. Sistemas de Mesoescala e Previsão de Tempo a Curto Prazo. *Revista Brasileira de Meteorologia*, v. 2, p. 133-150. 1987.

SILVA DIAS, M. A. F.; DIAS, J.; CARVALHO, L. M. V.; FREITAS, E. D.; SILVA DIAS, P. L. Changes in extreme daily rainfall for São Paulo, Brazil. *Climatic Change*, v. 116, p. 705-722, 2013.

SILVA, B. C.; CLARKE, R. Análise estatística de chuvas intensas na bacia do rio são francisco. *Revista Brasileira de Meteorologia*, v. 19, p. 265 - 272, 2004.

SILVA, B.K.N., AMORIM, A.C.B., SILVA, C.M.S., LUCIO, P.L. AND BARBOSA, L.M. (2019) Rainfall-related natural disasters in the Northeast of Brazil as a response to ocean-atmosphere interaction. *Theoretical and Applied Climatology*, 1-9, doi: 10.1007/s00704-019-02930-9.

SILVA, C.M.S., LÚCIO, P.S. AND SPYRIDES, M.H.C. (2012) Distribuição espacial da precipitação sobre o Rio Grande do Norte: estimativas via satélites e medidas por pluviômetros. *Revista Brasileira de Meteorologia*, 27(3).

SILVA, M.T., ALCÂNTARA, C.R., DE SOUZA, E.P., DE OLINDA, R.A., GONÇALVES, W.A. 2017. “Influência da TSM na ocorrência de Linhas de Instabilidade na Costa Norte e Nordeste do Brasil.” *Revista brasileira de Meteorologia* 32(2), 260-268. <http://dx.doi.org/10.1590/0102-77863220003>.

SÍNTESE DE INDICADORES SOCIAIS – SIS. (2018) *Uma análise das condições de vida da população brasileira 2018*. Coordenação de População e Indicadores Sociais. IBGE, Rio de Janeiro, Brazil, p. 151.

SISWANTO, S., VAN OLDENBORGH, G.J., VAN DER SCHRIER, G., JILDERDA, R. AND VAN DEN HURK, B. (2016) Temperature, extreme precipitation, and diurnal rainfall changes in the urbanized Jakarta city during the past 130 years. *International Journal of Climatology*, 36(9), 3207-3225, doi: 10.1002/joc.4548.

SMITH, R.L. (1985) Maximum likelihood estimation in a class of nonregular cases. *Biometrika*, 72(1), 67–90, doi:10.1093/biomet/72.1.67.

SONG et al. Recent changes in extreme precipitation and drought over the Songhua River Basin, China, during 1960– 2013. *Elsevier Atmospheric Research*. v. 157, p. 137–152. 2015.

SOROOSHIAN, S., LAWFORD, R., TRY, P., ROSSOW, W., ROADS, J., POLCHER, J., SOMMERIA, W. AND SCHIFFER, R. (2005) Water and energy cycles: Investigating the links. *World Meteorological Organization Bulletin*, 54(2), 58-64.

STEPHENS, G.L. (2005) Cloud feedbacks in the climate system: A critical review. *Journal of climate*, 18(2), 237-273, doi: 10.1175/JCLI-3243.1.

STRETEN, N. A., Some characteristic of satellite observed bands of persistent cloudiness over the Southern Hemisphere. *Monthly Weather Review*, v. 101, p. 486- 495. 1973.

SU, F., HONG, Y. AND LETTENMAIER, D.P. (2008) Evaluation of TRMM Multisatellite Precipitation Analysis (TMPA) and Its Utility in Hydrologic Prediction in the La Plata Basin. *Journal of Hydrometeorology*, 9(4), 622–640, doi: 10.1175/2007JHM944.1.

SUGAHARA, S., DA ROCHA, R.P. AND SILVEIRA, R. (2008) Non-stationary frequency analysis of extreme daily rainfall in Sao Paulo, Brazil. *International Journal of Climatology*, 29(9), 1339-1349. <https://doi.org/10.1002/joc.1760>.

SYLLA, M.B., GIORGI, F., COPPOLA, E., MARIOTTI, L. 2013. “Uncertainties in daily rainfall over Africa: assessment of gridded observation products and evaluation of a regional climate model simulation.” *International Journal of Climatology*, 33(7) 1805–1817. <https://doi.org/10.1002/joc.3551>.

TAN, I. AND STORELVMO, T. (2019) Evidence of Strong Contributions From Mixed-Phase Clouds to Arctic Climate Change. *Geophysical Research Letters*, 46(5), 2894-2902, doi: <https://doi.org/10.1029/2018GL081871>.

TAPIADOR, F.J., TURK, F., PETERSEN, W., HOU, A.Y., GARCÍA-ORTEGA, E., MACHADO, L.A., ANGELIS, C.F., SALIO, P., KIDD, C., HUFFMAN, G.J., DE CASTRO, M. 2012. "Global precipitation measurement: Methods, datasets and applications." *Atmospheric Research* 104-105, 70-97. <https://doi.org/10.1016/j.atmosres.2011.10.021>.

TEDESCHI, R. G.; GRIMM, A. M.; CAVALCANTI, I.F.A. Influence of Central and East ENSO on extreme events of precipitation in South America during austral spring and summer. *International Journal of Climatology*. v. 35, p. 2045 -2064. 2015.

TEEGAVARAPU, R. S. V.; CHANDRAMOULI V. Improved weighting methods, deterministic and stochastic data-driven models for estimation of missing precipitation records. *Journal of Hydrology*, v.312, p.191–206. 2005.

TEIXEIRA, M.S., SATYAMURTY, P. Trends in the frequency of intense precipitation events in southern and southeastern Brazil during 1960-2004. *Journal of Climate*, v. 24, p. 1913-1921. 2011.

THIOMBIANO, A.N., ST-HILAIRE, A., EL ADLOUNI, S.E. AND OUARDA, T.B. (2018) Nonlinear response of precipitation to climate indices using a non-stationary Poisson-generalized Pareto model: case study of southeastern Canada. *International Journal of Climatology*, 38(S1), 875-888, doi: 10.1002/joc.5415.

TIMM, N. H. *Applied Multivariate Analysis*. New York: Springer Verlag, 2002.

TIMMERMANS, B., WEHNER, M., COOLEY, D., O'BRIEN, T., & KRISHNAN, H. 2019. An evaluation of the consistency of extremes in gridded precipitation data sets. *Climate Dynamics* 1-20. DOI: 10.1007/s00382-018-4537-0

TORRES, R.R. AND FERREIRA, N.J. (2011) Case studies of easterly wave disturbances over Northeast Brazil using the Eta Model. *Weather and Forecasting*, 26(2), 225-235, doi: 10.1175/2010WAF2222425.1.

TRENBERTH, K. E., FASULLO, J. T. AND KIEHL, J. (2009) Earth's global energy budget. *Bulletin of the American Meteorological Society*, 90(3), 311-324, doi: 10.1175/2008bams2634.1.

TRMM (*Tropical Rainfall Mission Mission*). Disponível em: <<http://trmm.gsfc.nasa.gov>>. Acesso em: 22/01/2016.

TROPICAL RAINFALL MISSION MISSION – TRMM (2015). Reentry and Risk Assessment for the Tropical Rainfall Mission Mission, Disponível em: <<http://trmm.gsfc.nasa.gov>>. Acesso em: 22/01/2018.



TU, X., DU, Y., SINGH, V. P. AND CHEN, X. (2017) Joint distribution of design precipitation and tide and impact of sampling in a coastal area. *International Journal of Climatology*, 38(S1), 290-302, doi:10.1002/joc.5368.

TUKEY, J.W. (1949) Comparing individual means in the analysis of variance. *Biometrics*, 5(2), 99-114.

UFSC – CEPED. *Atlas brasileiro de desastres naturais 1991 a 2012: volume Brasil*. 5531 Florianópolis: CEPED UFSC, 2013.

ULABY, F.T., MOORE, R.K. AND FUNG, A.K. (1981) *Microwave remote sensing: Active and passive*. Microwave remote sensing fundamentals and radiometry. Addison-Wesley Publishing Co, United States, 470p.

UTIDA, G., CRUZ, F.W., ETOURNEAU, J., BOULOUBASSI, I., SCHEFUß, E., VUILLE, M., NOVELLO, V.F., PRADO, L.F., SIFEDDINE, A., KLEIN, V., ZULAR, A., VIANA, J.C.C. AND TURCQ, B.J. (2019) Tropical South Atlantic influence on Northeastern Brazil precipitation and ITCZ displacement during the past 2300 years. *Scientific reports*, 9(1), 1698, doi: 10.1038/s41598-018-38003-6.

UVO, C. R. B.; REPELLI, C. A.; ZEBIAK, S.; KUSHNIR, Y. The relationship between tropical Pacific and Atlantic SST and Northeast Brazil monthly precipitation. *Journal of Climate*, v. 11, p. 551-562. 1998.

UVO, C.R.B. (1989) *A Zona de Convergência Intertropical (ZCIT) e sua relação com a precipitação da Região Norte do Nordeste Brasileiro*. 1989. 99f. Dissertação (Mestrado em meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Brazil.

VALADÃO, C.E., CARVALHO, L.M., LUCIO, P.S. AND CHAVES, R.R. (2017) Impacts of the Madden-Julian oscillation on intraseasonal precipitation over Northeast Brazil. *International Journal of Climatology*, 37(4), 1859-1884. doi:10.1002/joc.4818

VAN BUUREN, S.; GROOTHUIS OUDSHOORN, K. Mice: Multivariate Imputation by Chained Equations in R. *Journal of Statistical Software*, Vol. 45, p. 1-67. 2011.

VESTENA, L.R. (2008) A importância da hidrologia na prevenção e mitigação de desastres naturais The importance of hydrology in the prevention and mitigation of natural disasters. *Ambiência*, 4(1), 151-162.

VILA, D.A, DE GONCALVES, L.G.G., TOLL, D.L, ROZANTE, J.R. 2009. Statistical Evaluation of Combined Daily Gauge Observations and Rainfall Satellite Estimates over Continental South America. *Bulletin of the American Meteorological Society* 10(2), 533-543. <https://doi.org/10.1175/2008JHM1048.1>.

VINCENT, L.; YUMIKO, M. Trends in total and extreme South American rainfall 1960-2000 and links with sea surface temperature. *Journal of Climate*. 19, 1490-1512. 2006.

WALD, A. AND WOLFOWITZ, J. (1940) On a test whether two samples are from the same population. *The Annals of Mathematical Statistics*, 11(2), 147-162.

WANG, J. AND WOLFF, D.B. (2009) Comparisons of reflectivities from the TRMM precipitation radar and groundbased radars, *Journal of Atmospheric and Oceanic Technology*, 26(5), 857-875, doi:10.1175/2008jtecha1175.1, 2009.

WANG, W.C., GONG, W., KAU, W.S., CHEN, C.T., HSU, H.H., AND TU, C.H. (2004) Characteristics of cloud radiation forcing over East China. *Journal of climate*, 17(4), 845-853, doi: 10.1175/1520-0442(2004)017<0845:COCRFO>2.0.CO;2.

WARD JR., J.H. 1963. "Hierarchical Grouping to Optimize an Objective Function." *Journal of the American Statistical Association*, 58(301), 236-244.

WENDLAND, E. 2015. "Performance evaluation of rain fall estimates by TRMM Multi-satellite Precipitation Analysis 3B42V6 and V7 over Brazil." *Journal of Geophysical Research Atmospheres* 120(18), 9426–9436. <https://doi.org/10.1002/2015JD023797>.

WESONGA, R. (2015). On multivariate imputation and forecasting of decadal wind speed missing data. *SpringerPlus*, 4(1), 12.

WI, S.; VALDÉS, J.B.; STEINSCHNEIDER, S.; KIM, T. W. Non-stationary frequency analysis of extreme precipitation in South Korea using peaks-over-threshold and annual maxima. *Stochastic Environmental Research and Risk Assessment*, 30, 583-606. 2016.

WU, Y., WU, S.Y., WEN, J., XU, M. AND TAN, J. (2015) Changing characteristics of precipitation in China during 1960–2012. *International Journal of Climatology*, 36 (3), 1387–1402, doi: 10.1002/joc.4432.

XAVIER, T. M. B. S., XAVIER, A. F. S., DIAS, M A F S., DIAS, P. L. S. Interrelações entre eventos ENOS (ENSO), a ZCIT (ITCZ) no Atlântico e a chuva nas bacias hidrográficas do Ceará. *Revista Brasileira de Recursos Hídricos*, v. 8, p. 111-126, 2003.

YAMAZAKI, Y., RAO, V.B. 1977. Tropical cloudiness over the South Atlantic Ocean. *Journal of the Meteorological Society of Japan*, 55(2), 205-207.

YANG, Y., TANG, J., XIONG, Z. AND DONG, X. (2017) Evaluation of high-resolution gridded precipitation data in arid and semiarid regions: Heihe River Basin, Northwest China. *Journal of Hydrometeorology*, 18(12), 3075-3101, doi: 10.1175/JHM-D-16-0252.1.

YANG, Y.J., WANG, H., CHEN, F., ZHENG, X., FU, Y. AND ZHOU, S. (2019) TRMM-Based Optical and Microphysical Features of Precipitating Clouds in Summer Over the Yangtze–Huaihe River Valley, China. *Pure and Applied Geophysics*, 176(1), 357-370, doi: 10.1007/s00024-018-1940-8.

YENDRA, R.; JEMAIN, A. A.; ZAHARI, M.; WAN ZIN, W. Z. Methods on handling missing rainfall data with Neyman-Scott rectangular pulse modeling. *AIP Conference Proceedings*, v. 1522, p. 1213-1220. 2013.

YIN, Z.-Y., X. ZHANG, X. LIU, M. COLELLA, AND X. CHEN. 2008. An Assessment of the Biases of Satellite Rainfall Estimates over the Tibetan Plateau and Correction

Methods Based on Topographic Analysis. *Journal of Hydrometeorology* 9 (3): 301–326. doi:10.1175/2007JHM903.1

YONG, B., REN, L.L., HONG, Y., WANG, J.H., GOURLEY, J.J., JIANG, S.H., CHEN, X. AND WANG, W. (2010) Hydrologic evaluation of multisatellite precipitation analysis standard precipitation products in basins beyond its inclined latitude band: a case study in Laohahe basin, China. *Water Resources Research*, 46(7), 759-768, doi: 10.1029/2009WR008965.

YOZGATLIGIL, C.; ASLAN, S.; IYIGUN, C.; BATMAZ I. Comparison of missing value imputation methods in time series: the case of Turkish meteorological data. *Theoretical and Applied Climatology*, v. 112, p. 143–167. 2013.

ZANDONADI, L.; ACQUAOTTA, F.; FRATIANNI, S.; ZAVATTINI, J.A. Changes in precipitation extremes in Brazil (Paraná River Basin). *Theoretical and Applied Climatology*, 123, p. 741-756. 2016.

ZHAO, T., YATAGAI, A. 2014. Evaluation of TRMM 3B42 product using a new gauge-based analysis of daily precipitation over China. *International Journal of Climatology* 34(8), <https://doi.org/2749-2762>. 10.1002/joc.3872.

ZHOU, J. AND LAU, K.M. (2001) Principal modes of interannual and decadal variability of summer rainfall over South America. *International Journal of Climatology*, 21(13), 1623-1644, doi: 10.1002/joc.700.

ZHOU, X. H.; ECKERT, G.J.; TIERNEY, W. M. Multiple imputation in public health research. *Statistics in Medicine*, v. 20, p. 1541–1549. 2001.

ZILLI, M.T., CARVALHO, L.M. AND LINTNER, B.R. (2019) The poleward shift of South Atlantic Convergence Zone in recent decades. *Climate Dynamics*, 52(5-6), 2545-2563, doi: 10.1007/s00382-018-4277-1.

ZUBIETA, R., SAAVEDRA, M., ESPINOZA, J.C., RONCHAIL, J., SULCA, J., DRAPEAU, G. AND MARTIN-VIDE, J. (2019) Assessing precipitation concentration in the Amazon basin from different satellite-based data sets. *International Journal of Climatology*, 39(7), 3171-3187, doi: 10.1002/joc.6009.