

UFPA

PPGEC

Universidade Federal do Pará



Mayke Feitosa Progênio

MODELAGEM ESTOCÁSTICA DE FUNÇÃO CUMULATIVA DE PROBABILIDADES DE PRECIPITAÇÃO DIÁRIA NA REGIÃO HIDROGRÁFICA TOCANTINS-ARAGUAIA (RHTA)

DISSERTAÇÃO DE MESTRADO

Instituto de Tecnologia
Programa de Pós-Graduação em Engenharia Civil

Dissertação orientada pelo Prof. Claudio José Cavalcante Blanco, Ph.D.

Belém – Pará – Brasil

2019

Mayke Feitosa Progênio

**MODELAGEM ESTOCÁSTICA DE FUNÇÃO CUMULATIVA DE
PROBABILIDADES DE PRECIPITAÇÃO DIÁRIA NA REGIÃO HIDROGRÁFICA
TOCANTINS-ARAGUAIA (RHTA)**

Dissertação apresentada ao Programa de Pós-Graduação
em Engenharia Civil da Universidade Federal do Pará.

Linha de Pesquisa: Recursos Hídricos e Saneamento.

Orientador: Prof. Claudio José Cavalcante Blanco, Ph.D.

Belém - PA

2019

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Biblioteca do ITEC/UFPA-Belém-PA**

P964 Progênio, Mayke Feitosa, 1994-
Modelagem estocástica de função cumulativa
de probabilidades de precipitação diária na região
hidrográfica Tocantins-Araguaia / Mayke Feitosa
Progênio. - 2019.


Orientador: Claudio José Cavalcante Blanco

Dissertação (Mestrado) – Universidade Federal
do Pará, Instituto de Tecnologia, Programa de Pós-
Graduação em Engenharia Civil, Belém, 2019.

1.Chuvas- Tocantins- Estatística.
2.Precipitação (Meteorologia) - Tocantins.
3.Recursos hídricos. 4.Hidrologia. I.Título.

CDD 23. ed. – 5 5 1 . 5 7 7 2 8 1 1 7

Elaborado por Kelren Cecília dos Santos Lima da Mota – CRB-2/1461



MODELAGEM ESTOCÁSTICA DE FUNÇÃO CUMULATIVA DE PROBABILIDADES DE PRECIPITAÇÃO DIÁRIA NA REGIÃO HIDROGRÁFICA TOCANTINS-ARAGUAIA (RHTA)

AUTOR:

MAYKE FEITOSA PROGÊNIO

DISSERTAÇÃO SUBMETIDA À BANCA
EXAMINADORA APROVADA PELO COLEGIADO DO
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA CIVIL DO INSTITUTO DE
TECNOLOGIA DA UNIVERSIDADE FEDERAL DO
PARÁ, COMO REQUISITO PARA OBTENÇÃO DO
GRAU DE MESTRE EM ENGENHARIA CIVIL NA
ÁREA DE RECURSOS HÍDRICOS E SANEAMENTO
AMBIENTAL.

APROVADO EM: 28 / 03 / 2019.

BANCA EXAMINADORA:

Prof. Claudio José Cavalcante Blanco, Ph.D.
Orientador (UFPA)

Prof. Dr. Augusto César de Mendonça Brasil
Membro Externo (UnB/GAMA)

Prof.ª Dra. Mariane Furtado Gonçalves
Membro Externo (UFRA)

Prof. Dr. Francisco Carlos Lira Pessoa
Membro Interno (UFPA)

Visto:

Prof. Dr. Dênio Ramam Carvalho de Oliveira
Coordenador do PPGEC / ITEC / UFPA

Dedicatória

A minha noiva Winnie e aos meus pais, Max e Jaqueline, pelo incentivo, amor e apoio incondicionais.

Agradecimentos

Agradeço a Deus por me fazer acreditar que tudo é possível, proporcionando-me perseverança, sabedoria, saúde mental e determinação na realização deste trabalho.

A minha mãe, Jaqueline Progênio, pelo incentivo, cuidado e amor incondicional em toda a trajetória da minha vida. Sendo, umas das principais incentivadoras dos meus estudos.

Ao meu Pai, Max Progênio, por seus conselhos valiosos em momentos difíceis que me ajudaram a decidir o melhor caminho a ser escolhido, além de me mostrar a importância do conhecimento, da honestidade e humildade.

A meu irmão, Felipe Progênio, por toda a paciência e compreensão sobre a minha ausência em seu crescimento, perdendo muitas vezes datas importantes como o seu aniversário.

A minha vó, Maria Oliveira, por sua ajuda e incentivo desde o início da minha vida acadêmica.

A minha noiva, Winnie Macedo, por todo amor, apoio nas horas difíceis, incentivos e compreensão em todos os momentos no desenvolvimento deste trabalho. Obrigado por nunca ter me deixado desistir dos meus sonhos e por ter acreditado que eu seria capaz de concluir essa etapa na minha vida.

Ao meu orientador prof. Claudio José Cavalcante Blanco, Ph.D. pela orientação, esclarecimentos, dedicação e apoio oferecidos ao longo do desenvolvimento deste trabalho. Obrigado pela sugestão deste tema tão interessante e agradável de trabalhar. Para mim é uma honra ter sido seu orientado.

Ao prof. Marcelo Raiol, que sempre me incentivou buscar esta qualificação acadêmica.

Ao prof. Daniel Detzel, por ser solícito em esclarecimentos que me ajudaram no desenvolvimento deste trabalho.

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

Aos amigos do Grupo de Pesquisa em Água, Energia e Sustentabilidade da Amazônia (GAES) da Universidade Federal do Pará (UFPA) pelo apoio e pelos momentos de descontração, em especial Eduardo Aguiar, Laila Rover, Evanice Gomes, Adry Lima, Vanessa Watrin, Vanessa Santos e Josias Cruz.

Resumo

Conhecer o comportamento temporal e espacial da probabilidade de ocorrência de precipitação pluviométrica é indispensável para o planejamento e gestão das atividades agrícolas e agroindustriais. Entretanto, em algumas bacias hidrográficas as séries históricas de precipitação disponíveis são geralmente curtas e com grande número de falhas, o que dificulta as análises estatísticas. Assim, o objetivo do trabalho foi desenvolver um modelo estocástico de função cumulativa de probabilidades de precipitação diária na região hidrográfica Tocantins Araguaia-RHTA. O modelo é do tipo paramétrico, no qual as ocorrências das precipitações foram determinadas através da cadeia de Markov (CM) de 1ª ordem e as quantidades de precipitação foram estimadas por 4 funções cumulativas de probabilidade (FCPs) sendo elas: exponencial simples, exponencial a dois parâmetros, exponencial mista e gama. Os parâmetros das FCPs foram estimados pelo Método da Máxima Verossimilhança. O processo de simulação foi realizado separadamente para cada estação pluviométrica, sem considerar a correlação espacial entre elas. O modelo desenvolvido foi aplicado em 196 estações pluviométricas distribuídas em 3 regiões homogêneas (RH) de precipitação na RHTA. Os resultados mostraram que a CM de 1ª ordem foi capaz de reproduzir de forma satisfatória a quantidade de dias secos e chuvosos. No entanto, nas áreas fortemente influenciadas por longas séries de estiagem, os resultados não foram satisfatórios. Em relação à estimativa das quantidades precipitadas, o teste Kolmogorov-Smirnov (KS) e o gráfico de probabilidade-probabilidade (P-P) mostraram que a exponencial mista foi a que apresentou melhores aderências aos dados observados para a maioria dos meses do ano, com exceção dos meses menos chuvosos de junho, julho e agosto na *RH II* e *RH III*, e nos meses de setembro, outubro e novembro para a *RH I*, para os quais a função gama se mostrou mais eficiente, estes resultados também foram confirmados pelos baixos valores de *Root Mean Square Error* (RMSE) e *Mean absolute Error* (MAE). Assim, o modelo desenvolvido mostrou-se eficiente na estimativa de precipitações médias diárias na *RHTA*, além disso, o uso de mais de uma FCP proporcionou ao modelo maior capacidade de estimar as precipitações em diferentes locais e estações do ano.

Palavras-chave: Precipitações diárias, Recursos Hídricos e Funções cumulativas de probabilidades.

Abstract

Knowing the temporal and spatial behavior of the probability of occurrence of rainfall is indispensable for the planning and management of agricultural and agroindustrial activities. However, in some river basins the available historical precipitation series are generally short and with a large number of faults, which makes statistical analyzes difficult. Thus, the objective of the work was to develop a stochastic model of cumulative function of daily precipitation probabilities in the Tocantins Araguaia hydrographic region (TAHR). The model is of the parametric type, in which precipitation occurrences were determined through the first-order Markov chain (MC) and the precipitation quantities were estimated by 4 cumulative probability functions (CPFs): exponential simple, exponential a two parameters, mixed exponential and gamma. The parameters of the CPFs were estimated by the Maximum Likelihood Method. The simulation process was performed separately for each rainfall station, without considering the spatial correlation between them. The developed model was applied in 196 rainfall stations distributed in 3 homogeneous regions (HR) of precipitation in TAHR. The results showed that the MC of the 1st order was able to reproduce satisfactorily the amount of dry and rainy days. However, in areas heavily influenced by long series of drought, the results were not satisfactory. In relation to the estimated precipitated quantities, the Kolmogorov-Smirnov (KS) test and the probability-probability (P-P) graph showed that the mixed exponential was the one that presented better adherence to the observed data for most months of the year, with the exception of the less rainy months of June, July and August in *RH II* and *RH III*, and in the months of September, October and November for *RH I*, for which the gamma function was more efficient, these results were also confirmed by the low Root Mean Square Error (RMSE) and Mean Absolute Error (MAE) values. Thus, the model developed showed to be efficient in the estimation of average daily rainfall in TAHR, in addition, the use of more than one CPF gave the model greater capacity to estimate rainfall in different locations and seasons.

Keywords: Daily precipitations, Water Resources and Cumulative Probability Functions.

LISTA DE FIGURAS

Figura 1 - Tipos de chuvas	15
Figura 2 - Localização da RHTA.	32
Figura 3 – Uso e ocupação do solo da RHTA	34
Figura 4- Tipos de clima da RHTA.	35
Figura 5 - Regiões Homogêneas de Precipitação da RHTA.	37
Figura 6 - Estações pluviométricas da RHTA.	38
Figura 7 - Fluxograma do algoritmo do modelo estocástico pluviométrico.....	39
Figura 8 - Estações Pluviométricas alvos.	52
Figura 9 - Espacialização da ordem ótima da cadeia de Markov definida pelo critério BIC. ...	57
Figura 10 - Box-Plots da probabilidade de um dia chuvoso antecedido por outro também.....	59
Figura 11 - Box-Plots da probabilidade de dia seco antecedido por um dia chuvoso (P_{01}).	60
Figura 12 - Probabilidades de transição de chuva após um dia seco (P_{10}) e chuva após um dia chuvoso (P_{11}); (a) e (b) – <i>RH I</i> ; (c) e (d) – <i>RH II</i> ; (e) e (f) – <i>RH III</i>	64
Figura 13 - Proporção de melhor aderência de cada distribuição por mês no teste KS; a) <i>RH I</i> - Estação menos chuvosa (maio a outubro) e Estação mais chuvosa (novembro a abril), b) <i>RH II</i> -Estação menos chuvosa (abril a setembro) e Estação mais chuvosa (outubro a março), c) <i>RH III</i> -Estação menos chuvosa (junho a novembro) e Estação mais chuvosa (dezembro a maio).	66
Figura 14 – Função Cumulativa de probabilidades mais adequada, ao nível de significância de 5%, segundo o teste <i>KS</i>	71
Figura 15 – Quantidade de casos de degenerações da distribuição exponencial mista.	72
Figura 16 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a <i>RH I</i>	76
Figura 17 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a <i>RH II</i>	77
Figura 18 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a <i>RH III</i>	77
Figura 19 - Comparação entre as FCPs de precipitação diárias mensais em relação aos dados observados; <i>RH I</i> (48006).	80
Figura 20 – Gráficos das probabilidades-probabilidades (P-P plot) de precipitações diárias mensais; <i>RH I</i> (48006).	82

LISTA DE TABELAS

Tabela 1 – Distribuições cumulativas de probabilidade.....	22
Tabela 2– Testes de aderência mais utilizados na literatura.....	26
Tabela 3 – Cadeias de Markov da 1ª a 3ª ordem.	28
Tabela 4– Valores mínimos de precipitação para dias considerados secos ou chuvosos.	31
Tabela 5– Matriz de probabilidade da <i>CM</i> de 1ª ordem.	40
Tabela 6–Valores percentuais da indicação da ordem ótima da cadeia de Markov pelo critério BIC.....	53
Tabela 7- Valores das probabilidades de ocorrência e não ocorrência de precipitação para as estações alvos.	62
Tabela 8– Os valores do número de aceites do teste <i>KS</i> ao nível de significância ($\alpha= 0,05$). .	64
Tabela 9– Estação pluviométrica com menor número de aderências da RHTA.	65
Tabela 10 - Análises estatísticas mensais dos parâmetros α , β_1 e β_2 para as três RH.....	73
Tabela 11 – Valores médios (\bar{x}) e desvio padrão (σ) do parâmetro μ para as RH.	78
Tabela 12 – Estatística descritiva (méd-média diária; sd-desvio padrão diário; medi-mediana diária; tp-total precipitado mensal; ds-quantidades de dias secos e dc-quantidades de dias chuvosos) das séries de precipitações pluviométricas estimadas e observadas.....	85
Tabela 13 – Valores do critério BIC para indicação da ordem ótima (em vermelho) até a 4ª ordem da cadeia de Markov.....	90
Tabela 14 – Análise de sensibilidade do modelo em relação ao tamanho da amostra por RH.	93

SUMÁRIO

1 INTRODUÇÃO	11
1.1 OBJETIVOS	12
1.1.1 Geral	12
1.1.2 Específicos	12
2 FUNDAMENTAÇÃO TEÓRICA	14
2.1 HIDROLOGIA	14
2.1.1 Tipos de Precipitação	14
2.1.2 Formação das Chuvas	14
2.1.3 Categorias de Chuva	15
2.1.4 Grandezas e medidas de precipitação	16
2.1.5 Modelagem Hidrológica.....	16
2.1.6 Estimativas de Precipitação.....	17
-Tipos de Modelos Pluviométricos	19
2.1.7 Procedimentos para estimar os parâmetros das distribuições probabilísticas.....	24
2.1.8 Testes de aderência.....	25
2.2 MODELAGEM ESTOCÁSTICA DE OCORRÊNCIA DE PRECIPITAÇÃO	26
2.2.1 Cadeia de Markov (CM).....	27
2.2.2 Determinação do valor mínimo de chuva para dias considerados secos.....	30
3. ÁREA DE ESTUDO	32
3.1 REGIÃO HIDROGRÁFICA TOCANTINS-ARAGUAIA (RHTA)	32
3.1.1 Hidrografia e Vegetação	32
3.1.2 Caracterização climatológica	34
3.1.3 Estações pluviométricas.....	36
4. METODOLOGIA.....	39
4.1 MODELO PROPOSTO PARA ESTIMATIVAS DE PRECIPITAÇÃO MÉDIAS DIÁRIAS	39
4.2 MODELAGEM DA OCORRÊNCIA DA CHUVA.....	40
4.2.1 Cadeia de Markov (CM).....	40
4.2.2 Calibração da ocorrência.....	42
4.3 DETERMINAÇÃO DA QUANTIDADE DE PRECIPITAÇÃO DIÁRIA	43
4.3.1 Distribuição Exponencial simples	43
4.3.2 Distribuição Exponencial a dois parâmetros	44

4.3.3 Distribuição da Exponencial Mista.....	44
4.3.4 Distribuição Gama	46
4.3.4 Estimativa dos parâmetros das funções de probabilidade	46
4.3.5 Método da máxima verossimilhança (MVS).....	46
4.3.6 Teste de aderência das FCPs	49
4.3.7 Validação do modelo	50
5. RESULTADOS	52
5.1 DETERMINAÇÃO DA OCORRÊNCIA DE PRECIPITAÇÃO DIÁRIA.....	53
5.1.1 Distribuição Espacial da Otimização da Ocorrência	53
5.1.2 Distribuição temporal da Probabilidade de Ocorrência	58
5.2 DETERMINAÇÕES DA QUANTIDADE DE PRECIPITAÇÃO DIÁRIA.....	64
5.2.1 Validação.....	84
5.2.2 Análise de sensibilidade do Modelo em relação ao tamanho da amostra	92
6 CONCLUSÃO.....	96
7.0 SUGESTÕES E RECOMENDAÇÕES	97
REFERÊNCIAS.....	98
APÊNDICES	113

1 INTRODUÇÃO

A precipitação é um fenômeno aleatório e um dos fatores climáticos que mais afetam as condições hidrológicas de ecossistemas, já que sua ocorrência exerce grande influência na circulação atmosférica, uma vez que parte da energia gerada desta circulação origina-se do calor latente, o qual é formado de precipitação tropical (KIDD; HUFFMAN, 2011). Qualquer variação no regime de precipitação provoca alteração na temperatura do ar, umidade do ar, nebulosidade e na quantidade de radiação solar incidente na superfície, tais alterações afetam rigorosamente o crescimento das plantas (KIST; VIRGENS FILHO, 2015).

A chuva diária é variável no espaço e no tempo, por isso é importante reconhecer seus padrões de ocorrência para uma boa previsão do comportamento climático de uma região. Além disso, a precipitação é utilizada como entrada em modelos determinísticos para geração de hidrogramas (BLANCO et al. 2013). Setores como o de agricultura, projetos de controle de inundações e o abastecimento humano necessitam da precipitação para o planejamento, gestão e operação (SOARES et al. 2016).

De acordo com Coan et al. (2014) algumas características de precipitação podem ser extraídas da análise dos registros do que aconteceu no passado. Contudo, às vezes, as séries registradas nas estações pluviométricas não são longas o suficiente para inferências estatísticas seguras. Neste contexto, surgem os modelos estocásticos que estimam séries de precipitação, permitindo contornar obstáculos expostos e ainda criar situações críticas não observadas com base em distribuições de probabilidade, por exemplo, simulação de séries de precipitação de 10.000 anos (COSTA et al. 2015).

Diversos modelos estocásticos pluviométricos já foram propostos na literatura (TEIXEIRA-GANDRA et al. 2017; SEMENOV, 2008; BOULANGER et al, 2007; CARVALHO et al. 2017a), e estes se diferenciam apenas pelas técnicas empregadas. Os principais modelos estocásticos são: semi-paramétricos ou empíricos, não paramétricos e paramétricos, sendo o último o mais utilizado. No modelo paramétrico a precipitação é dividida por sua ocorrência e pela sua quantidade, as construções das etapas mencionadas são retiradas das frequências observadas dos registros históricos ou através da elaboração de um modelo probabilístico teórico (BAXEVANI; LENNARTSSON, 2015). Vieira et al. (2010) enfatizam que é aconselhável o uso de modelos probabilísticos para estimar a precipitação pluvial de um determinado local.

A maioria dos modelos que estimam precipitação são eficientes nas escalas anuais e mensais, como o modelo de regressão linear múltipla (GOMES et al. 2018). No entanto, quando se trabalha na escala diária o modelo citado se torna inadequado, uma vez que o nível

de dependência temporal não é representado por este modelo, o que resulta em baixos coeficientes de determinação. Este aspecto da persistência do processo de precipitação na escala diária torna a sua geração uma tarefa mais complexa (WILKS, 1998).

Assim, este estudo tem por objetivo testar um modelo estocástico para simulação de séries de precipitações para a Região Hidrográfica Tocantins-Araguaia (RHTA). O modelo proposto é do tipo paramétrico e sua estrutura é dividida em duas etapas, na primeira será utilizada a cadeia de Markov (CM) de 1ª ordem de dois estados para modelar a ocorrência de dias secos e chuvosos. Já na segunda etapa do modelo, foi calculada a quantidade de precipitação por intermédio das distribuições cumulativas de probabilidade Exponencial simples, Exponencial a dois parâmetros, Exponencial mista e Gama.

Os dados de precipitação pluviométrica gerados pelo modelo estocástico podem auxiliar em técnicas de planejamento de atividades que necessitam de estimativas de probabilidades para certos eventos hidrológicos, como por exemplo, os sistemas agrícolas que podem ser submetidos a inúmeras possibilidades de avaliação, dentre elas, pode-se destacar a otimização da produção de uma determinada cultura por meio da decisão de irrigar em função da sequência de dias secos, como consequência disso, ocorre a maior possibilidade de retorno econômico para o agricultor.

Neste contexto, o conhecimento do comportamento das precipitações pluviométricas da *RHTA* tem caráter estratégico para a produção agrícola, pecuária e para as atividades agroindústrias (ANA, 2009; SPERA et al., 2016; MATTOS et al., 2017). Também pode ser utilizado para o planejamento do controle de enchentes e no dimensionamento de obras de engenharia hidráulica (XU et al., 2018; WANG e WANG, 2018).

1.1 OBJETIVOS

1.1.1 Geral

Desenvolver modelo estocástico para estimativa de função cumulativa de probabilidades de precipitação diária.

1.1.2 Específicos

- Determinar probabilidade de ocorrência de dias secos e chuvosos para as estações pluviométricas da RHTA;
- Determinar a cadeia ótima de Markov para regiões homogêneas de precipitação da RHTA;

- Analisar a variabilidade dos parâmetros das funções cumulativas de probabilidade nas regiões homogêneas;
- Verificar o ajuste das curvas geradas pelas funções cumulativas de probabilidades Exponencial simples, Exponencial a dois parâmetros, Exponencial mista e Gama.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 HIDROLOGIA

2.1.1 Tipos de Precipitação

No ciclo hidrológico a precipitação é a variável mais importante, de acordo com Kidd e Huffman (2011) ela provoca grande influência na circulação atmosférica e afeta variáveis climatológicas como a temperatura, umidade relativa do ar e vento. A precipitação pode ocorrer nas formas de chuva, granizo, neblina, neve, orvalho e geada, todas essas depositadas sobre a superfície terrestre em forma de umidade (SILVA, 2011). Melo e Silva (2013) definem os tipos de precipitação como:

Chuva: é a principal forma de precipitação em regiões tropicais e subtropicais, e atinge a superfície terrestre no estado líquido. É considerada a principal variável utilizada na hidrologia.

Granizo: precipitação que ocorre na forma de partículas de gelo com tamanho mínimo de 5 mm. Os granizos são formados pelo congelamento instantâneo das gotículas d'água, e sua formação dá-se pela rápida ascensão do vapor d'água na atmosfera.

Neve: precipitação de flocos formados por cristais de gelo com geometria hexagonal, os quais são desenvolvidos em nuvens bastante frias (abaixo de 0°C).

Orvalho: é a umidade do ar que precipita por condensação na forma de gotas, pela diminuição da temperatura ou em contato com superfícies frias. Este fenômeno está ligado à capacidade de incorporar e reter vapor de água.

Geada: é semelhante ao ponto de orvalho, entretanto, a curva de saturação é abaixo de zero, onde ocorre o processo de sublimação no qual a água precipita diretamente no estado sólido (gelo).

Neblina: é a condensação que ocorre adjacente à superfície, decorrente do resfriamento do ar quente e úmido quando entra em contato com o solo frio.

2.1.2 Formação das Chuvas

A formação de chuvas está ligada à ascensão de massas de ar que são submetidas a um resfriamento adiabático, que faz o vapor d'água atingir o seu ponto de saturação. A partir do nível de saturação em condições favoráveis e com a existência de núcleos com gelo, poeira e outras partículas, os núcleos higroscópicos¹ são formados. O vapor condensa formando minúsculas gotas em torno desses núcleos.

¹ Núcleos relativamente grandes que tem uma afinidade química especial de atração por moléculas de água.

No caso das gotas, um diâmetro específico deve ser alcançado para ultrapassar as forças resistivas do ar, e assim, se deslocarem em direção ao solo, caso isso não ocorra, elas ficam em suspensão na forma de nuvens e nevoeiros (TUCCI, 2015). Dentre os processos de crescimento mais importantes das gotas estão os mecanismos de coalescência e difusão do vapor.

2.1.3 Categorias de Chuva

De acordo com Collischon e Tassi (2008), as categorias de chuva são divididas pelo fator gerador da ascensão da massa de ar (Figura 1). Os tipos de chuva são descritos a seguir:

- a) **Frontais:** são aquelas que acontecem resultantes do encontro direto entre duas massas de ar, sendo uma massa quente e úmida, e a outra fria e seca. A intensidade desta chuva é baixa, com uma duração relativamente longa.
- b) **Orográficas:** são aquelas que ocorrem quando o ar é forçado a transpor barreiras topográficas (relevos íngremes). As intensidades são baixas e duração longa.
- c) **Convectivas:** são aquelas que são provocadas pelo aquecimento desigual das camadas da atmosfera, esta formação está associada a dias quentes e úmidos e com redução brusca de pressão atmosférica, sendo caracterizadas pela alta intensidade e curta duração.




Figura 1 - Tipos de chuvas

Fonte: Collischon e Tassi (2008).

2.1.4 Grandezas e medidas de precipitação

Os principais aparelhos utilizados para medir a chuva, são o pluviômetro e o pluviógrafo (JIMÉNEZ; COLLISCHONN, 2015). Estes instrumentos fornecem informações referentes às grandezas da chuva: a) altura pluviométrica (h): relação entre o volume de água armazenado e a área da superfície do pluviômetro; b) intensidade da precipitação (I), que é a relação entre a altura pluviométrica e a duração da precipitação; c) duração (ΔT), as unidades utilizadas para as grandezas citadas são: milímetros (mm), milímetros por hora (mm/h) ou milímetros por minuto (mm/min) e minutos ou hora (min ou h), respectivamente.

De acordo com Organização Meteorológica Mundial (OMM), as densidades de estações pluviométricas variam de acordo com a localização. Os valores recomendados são: 900 km² por estação em áreas costeiras, 250 km² por estação em áreas montanhosas; 575 km² por estação em regiões com morros e colinas no interior; e 20 km² por estação em áreas urbanas (OMM, 1994).

2.1.5 Modelagem Hidrológica

O entendimento dos processos hidrológicos é importante para a gestão dos recursos hídricos e para o dimensionamento de obras hidráulicas. Neste cenário, a modelagem hidrológica surge como uma ferramenta baseada em sistemas de equações e procedimentos compostos por variáveis e parâmetros, que permitem uma melhor compreensão dos fenômenos hidrológicos em uma bacia hidrográfica, sob diferentes condições ambientais (MARINHO FILHO et al. 2012).

Na prática, os estudos das séries temporais hidrológicas são controlados e influenciados por fatores complexos (ZHANG et al. 2011). De acordo com Chappell et al. (2017) todos os sistemas hidrológicos são fisicamente não lineares. Esta não linearidade deve-se à existência de fenômenos físicos como: infiltração, evapotranspiração, variações espaciais do subsolo e da precipitação (QUINTAS et al. 2011).

A modelagem hidrológica pode ser determinística ou estocástica. A primeira é fundamentada nos fenômenos físicos descritos por equações diferenciais e produzem resposta única para cada simulação de uma série de dados e parâmetros de entrada. Já na segunda, admite-se certa aleatoriedade ou incerteza em suas respostas devido à instabilidade de suas variáveis de entrada, parâmetros ou condições de contorno (FRANCISCO, 2014).

A maioria dos processos hidrológicos não é explicada na sua totalidade por modelos determinísticos, visto que, a maioria das variáveis hidrológicas são aleatórias e governadas por leis probabilísticas. Mediante o exposto, a abordagem estocástica surge como alternativa, pois as variáveis aleatórias são parte integrante deste processo (CHATFIELD, 2004).

Neste estado da arte, a modelagem hidrológica da precipitação pluviométrica é necessária para o entendimento climático de uma região, além do que, esta variável é utilizada como entrada para diversos estudos hidrológicos, como: controle de enchentes (HONG et al. 2017; SARMAH; DAS, 2018), previsão de níveis de água (FIGUEIREDO; BLANCO, 2016; LIU et al. 2018; WUNSCH et al. 2018), estimativa de erosão (COSTA; BLANCO, 2018; LISBOA et al. 2017), agricultura (ALVES et al. 2017; KELLER FILHO et al. 2006); pegada hídrica (AYALA, L. M. et al. 2016; XINCHUN et al. 2018) e em modelos chuva-vazão (BLANCO et al. 2013; CHOU, 2014; SHOAIB et al. 2014).

2.1.6 Estimativas de Precipitação

Ressalta-se que os modelos hidrológicos estão sujeitos a incertezas dos parâmetros, dados de medições e na sua estrutura (Krueger et al. 2010). Sendo assim, para qualquer técnica de modelagem, a heterogeneidade do regime de chuva causa desajuste entre o observado e o modelado, isto é atribuído às incertezas contidas nos dados de precipitação (OCKENDEN et al. 2017). Uma revisão com mais detalhes sobre a incerteza que estão atreladas aos dados de medição é apresentada por Mcmillan et al. (2012).

A falta de estações com dados disponíveis de chuvas diárias no espaço e no tempo é um obstáculo para sua estimativa (WANDERLEY et al. 2012). Segundo Oliveira et al. (2008), é comum encontrar baixa densidade de estações pluviométricas e com períodos curtos de dados, além disso, as séries temporais ainda possuem muitas falhas.

A ausência de dados de precipitação dificulta o uso de geradores climáticos em virtude de a precipitação ser empregada como variável motriz na estimativa de outras variáveis climáticas (RASMUSSEN, 2013), como é o caso da temperatura. Estas falhas estão relacionadas com a falta de monitoramento do equipamento (estação automática), ausência do observador (estação convencional), perda de anotações ou transcrição de registros (BIER et al. 2017).

Diante desta situação, é necessário aplicar modelos matemáticos e estatísticos que sejam capazes de gerar séries sintéticas de chuva (ANDRADE JÚNIOR et al. 2001; OLIVEIRA et al. 2010). Desta maneira, estes métodos podem ser utilizados para o preenchimento de falhas, estimativa das lâminas de chuva e na ampliação das séries de dados. Na literatura, existem diversas técnicas matemáticas, que vem sendo utilizadas e aplicadas em diversas regiões para este fim, como por exemplo:

No estudo de Correia et al. (2016) foi constatado a eficiência do uso de Redes Neurais Artificiais (RNAs) no preenchimento de falhas em dados de precipitação mensal na Bacia do Rio Doce, estado do Espírito Santo. Foram admitidos dados de entrada com falhas de 7%,

15% e 30%. Na verificação da qualidade do preenchimento, os autores constataram que apenas os dados com falha de 7% obtiveram valores de NSE (coeficiente de eficiência de Nash e Sutcliffe) e R^2 (Coeficiente de determinação) superiores a 0,8. De acordo com Lee e Kang (2015) as RNAs são dependentes da grande quantidade de dados com qualidade.

Os métodos de interpolação também vêm sendo utilizados como alternativa para o preenchimento de falhas e na estimativa de chuva em locais que não apresentam estações de medição (BARGAOUI; CHEBBI, 2009). Segundo Wanderley et al. (2012), foi provada a eficácia do uso do método de interpolação geostática de Krigagem Ordinária (KO) para preenchimento de falhas de precipitação mensal em estações pluviométricas no estado de Alagoas.

Teegavarapu e Chandramouli (2005) testaram o método de Ponderação de Distância Inversa modificado (PDI) para confrontar com outros 3 métodos: Método Ponderado do Coeficiente de Correlação (MPCC), RNAs e KO, para estimar dados de precipitação em 20 estações no estado de Kentucky-EUA. Os três últimos métodos se mostraram mais eficientes. Aly et al. (2009) avaliou os métodos de MPCC, PDI, método de Otimização de Peso Linear (OPL) e RNAs para preenchimento de falhas de precipitação diária no sudoeste e sul da Flórida, EUA.

A cadeia de Markov (CM) aliada a um modelo paramétrico também é utilizada para geração de séries sintéticas e no preenchimento de falhas, na primeira etapa estima-se a quantidade de chuva para os dias considerados chuvosos, já na segunda, é simulada a ocorrência de chuva (chuvoso) e não ocorrência de chuva (seco) via CM. No trabalho realizado por Teixeira-Gandra et al. (2017) foi constatado que a modelagem estocástica utilizando a CM, de dois estados, aliada à distribuição Gama de dois parâmetros, podem ser utilizadas como ferramenta de preenchimento de falhas em séries de precipitação diária, no estado do Rio grande do Sul.

Leivas et al. (2005) destacam outra importante ferramenta na hidrologia, a regionalização hidrológica, a qual é empregada para transferência de informações de locais com dados para locais sem dados. No trabalho de Gonçalves et al. (2016) foram determinados seis grupos homogêneos de precipitação pluviométrica para o estado do Pará, considerando os anos com ocorrência de El Niño e La Niña. Essas regiões foram definidas através do método hierárquico de Ward, utilizando como variáveis: latitude, longitude, altitude e a precipitação média anual.

Muitos modelos vêm sendo desenvolvidos pelos pesquisadores ao longo dos últimos anos como descrito anteriormente, porém, os trabalhos concentram-se nas escalas anuais e

mensais, já que na escala diária existe a presença de muitos zeros nas séries, que por sua vez representa os dias sem chuva. Segundo Wilks (1998), a dependência das precipitações diárias é regida por fenômenos complexos, o que aumenta a dificuldade da modelagem da chuva nessa escala.

-Tipos de Modelos Pluviométricos

Com a definição dos tipos de chuva (tópico 2.1.3), é possível propor a modelagem pluviométrica mais adequada para cada região sabendo o tipo recorrente de precipitação, visto que, chuvas frontais possuem certa dependência temporal, em virtude de o mecanismo gerador de precipitação persistir por vários dias. Em contrapartida, as chuvas convectivas ocorrem normalmente nos fins de tarde de verão, portanto, sua persistência é quase independente (NASCIMENTO; KELMAN, 1995). Destaca-se que, algumas regiões podem ser afetadas por diversos tipos de chuvas simultaneamente, e nelas o processo de modelagem é ainda mais complexo.

Na simulação diária de precipitação pluviométrica é comum o uso de modelos que simulem em duas etapas, na primeira, é reproduzida a ocorrência de precipitação em intervalos discretos para dias chuvosos e secos, já na segunda, é simulada a ocorrência contínua de precipitação, na qual são estimadas as suas quantidades para os dias considerados chuvosos. Portanto, estes modelos necessitam ser construídos de modo que sejam simuladas a parte discreta e a contínua (BAXEVANI; LENNARTSSON, 2015).

Neste contexto, existem modelos que são capazes de descrever a precipitação de maneira satisfatória, segundo Brissette et al. (2007) estes podem ser divididos: em semi-paramétricos ou empíricos, não paramétricos e paramétricos.

-Modelos Semi-Paramétricos ou Empíricos

Na sua formulação são utilizados parâmetros estatísticos cujas ocorrências e a quantidade de chuva é estimada através de histogramas ajustados aos dados. De acordo com Semenov et al. (1998) a distribuição de um modelo semi-empírico é mais flexível do que as distribuições dos modelos paramétricos. Consequentemente, este tipo de modelo adequa-se a diversos climas distintos, no entanto, a desvantagem desta abordagem está na quantidade de parâmetros a serem estimados.

No trabalho de Semenov et al. (1998) foi realizada uma comparação entre 2 modelos de clima (WGEN e LARS-WG) em 18 locais distribuídos nos EUA, Europa e Ásia. Os modelos geraram dados diários das variáveis climáticas (temperatura mínima e máxima; precipitação e radiação solar). Os resultados apontaram que o LARS-WG apresentou maior eficiência do que WGEN.

Semenov (2008) testou novamente a eficácia do modelo LARS-WG, mas, neste caso o estudo foi direcionado para simulação da precipitação diária máxima anual, levando em consideração os eventos climáticos extremos, em 20 locais de climas diferentes. No processo de construção do modelo, foram selecionados os intervalos em um histograma diretamente relacionado com a magnitude dos eventos considerados. O modelo reproduziu as precipitações diárias máximas anuais com períodos de retorno de 10 e 20 anos com precisão para todos os locais.

Mehrotra e Sharma (2007) aplicaram um modelo estocástico semi-paramétrico para geração de chuvas diárias em 30 estações meteorológicas de Sydney, no leste da Austrália. As análises realizadas mostraram a boa capacidade do modelo em reproduzir as propriedades espaciais e temporais das chuvas. Além disso, as variações de longo prazo das baixas frequências de chuva também alcançaram uma boa representatividade.

-Modelos não paramétricos

Os modelos não paramétricos não possuem estrutura definida, e no processo de simulação dependem apenas dos dados disponíveis para gerar as estimativas. O uso deste tipo de modelo concentra-se na tentativa de simular os processos físicos geradores de precipitação. Neste cenário, uma das técnicas mais utilizadas é conhecida como reamostragem de dados (*bootstrapping*). O uso deste método estatístico é indicado em casos em que existe a dificuldade em determinar as informações da amostra, por exemplo: média, variância, coeficientes de correlação, etc.

Lall et al. (1996) desenvolveram um modelo que engloba os principais mecanismos de geração de precipitação. Os autores assumiram um modelo fundamentado na probabilidade de Kernel para que a estrutura tenha maior flexibilidade em se ajustar a qualquer região. Com isso, evitam-se inconsistências relacionadas ao ajuste do modelo para regiões específicas. Para teste da metodologia, foram utilizados os dados da cidade de Utah, no oeste dos EUA.

Buishand e Brandsma (2001) usaram do método de reamostragem do vizinho mais próximo para simular precipitação diária e temperatura simultaneamente para múltiplas localidades, na Bacia do rio Reno - Alemanha. As simulações de longo prazo se mostraram eficientes na geração de dados de precipitação para locais sem dados. Como mencionado, os resultados foram bons, no entanto, este método impossibilita a geração de séries maiores além das quais estão disponíveis no banco de dados, já que, a técnica só é capaz de replicar e reorganizar os dados existentes.

Em Sydney - Austrália, Harrold et al. (2003a, b) simularam a ocorrência de chuvas diárias via *CM* e as quantidades por meio de um modelo não paramétrico. A diferença entre o

modelo proposto e os tradicionais, está na modificação da estrutura de Markov para múltiplos estados de ocorrência (muito seco, seco, intermediário, úmido e muito úmido). O uso deste artifício objetivou reproduzir a variabilidade das sequências de chuva a longo prazo. No estudo de Srikanthan et al. (2005) foi utilizado do mesmo método citado para simular chuvas diárias para Sydney e Melbourne, Austrália.

Boulanger et al. (2007) propuseram um gerador de precipitações diárias baseado em redes neurais artificiais (RNAs). Na etapa de verificação de precisão do modelo, foram testadas diversas configurações para simular as ocorrências (Markov e RNAs), e as quantidades de chuvas (modelos paramétricos e RNAs). Os resultados apontaram que o modelo mais eficiente era o que utilizava *CM* para simular as ocorrências e as RNAs para estimar as quantidades.

-Modelos Paramétricos

Os modelos paramétricos são os mais utilizados na literatura por sua flexibilidade e facilidade de ajuste, no entanto, em comparação aos outros modelos mencionados, estes não proporcionam o mesmo nível de detalhamento do processo. Estes modelos são normalmente divididos em duas etapas: ocorrência, que utilizam processos estocásticos de renovação (GREEN, 1964; ROLDAN; WOOLHISER, 1982a; TSAKIRIS, 1988; NASCIMENTO; KELMAN, 1995) e *CM* (WAN et al. 2005; MEHROTRA; SHARMA, 2007; CARVALHO et al. 2017a; NG et al. 2017), e as quantidades, para as quais são empregadas distribuições de probabilidade (CALGARO et al. 2009; LI et al. 2012; SILVA et al. 2013).

As quantidades de precipitação em dias considerados chuvosos podem ser geradas por meio de distribuições estatísticas ajustadas aos dados observados (MELLO; SILVA, 2013). Existem diversas distribuições probabilísticas associadas aos modelos de ocorrência, a Tabela 1 traz uma síntese das mais utilizadas em estudos de precipitação.

Tabela 1 – Distribuições cumulativas de probabilidade.

Distribuição Estatística	Literatura
Gama (2 parâmetros)	Baú et al. (2013); Calgaro et al. (2009); Castellví et al. (2004); Coan et al. (2014); Dash (2012); Liao et al. (2004); Neto et al. (2005); Silva et al. (2007); Stowasser (2012); Szyniszewska e Waylen (2012); Teixeira-Gandra et al. (2016, 2017); Wan et al. (2005).
Weibull (2 parâmetros)	Barkotulla (2012); Martin et al. (2008); Selker e Haith (1990); Sharma (1996); Silva et al. (2007); Francisco et al. (2015).
Exponencial simples	Detzel e Mine (2011a); Haan et al. (1976); Pedron e Klosowski (2008); Richardson (1981); Todorovic e Woolhiser (1975); Wan et al. (2005).
Exponencial a dois parâmetros	Detzel e Mine (2011a); Nascimento e Kelman (1995)
Exponencial mista	Aba et al. (2014); Detzel e Mine (2011a, b); Foufoula-Georgiou e Lettenmaier (1987); Kist e Virgens filho (2015); Moreno-Pérez et al. (2014); Wan et al. (2005); Woolhiser e Pegram (1979); Wilks (1998); Wilks (1999).

Richardson (1981) simulou através da distribuição exponencial simples as precipitações pluviométricas diárias, temperaturas e a radiação solar em três cidades dos EUA (Temple, Spokane e Atlanta). Apesar de resultados satisfatórios, o autor aconselha o uso de distribuições de probabilidade com maiores números de parâmetros (gama e exponencial mista). Pedron e Klosowski (2008) também utilizaram a distribuição exponencial simples para 18 estações pluviométricas no estado do Paraná, a FCP utilizada mostrou uma boa aderência aos dados, entretanto, em intensidades de precipitação inferiores a 10 mm os resultados não foram satisfatórios.

Segundo Detzel e Mine (2011a), poucos trabalhos empregam a distribuição exponencial a dois parâmetros. Mas, segundo Nascimento e Kelman (1995), essa distribuição não pode ser desprezada, já que sua aplicação em 4 sub bacias da bacia do Rio Uruguai (Canoas, Pelotas, Passo fundo e Uruguai) mostrou-se satisfatória para a modelagem de precipitação. Além do que, os autores ainda alertam sobre o alto grau de incerteza atrelado as extrapolações de distribuições de probabilidade com grande número de parâmetros.

Wan et al. (2005) avaliaram o desempenho de vários modelos estocásticos na geração da quantidade e ocorrência da precipitação diária em 657 estações no Canadá. Para geração das quantidades, foram testadas 4 distribuições de probabilidade (exponencial simples, exponencial mista, gama e normal-assimétrica). Os resultados indicaram que a distribuição

exponencial mista foi superior para os meses menos chuvosos, bem como para a maioria dos casos, enquanto a distribuição gama foi adequada para os meses mais chuvosos.

Calgaro et al. (2009) aplicaram um modelo paramétrico de geração de séries sintéticas para o estado do Rio Grande do Sul. Na geração de ocorrência, os autores realizaram uma modificação na *CM* com a finalidade de representar a variabilidade espacial de cada estação. E para estimativa da quantidade de precipitação foi utilizada a distribuição gama de dois parâmetros, a qual foi ajustada por um modelo senoidal. Este recurso matemático aumentou a capacidade do modelo em representar as variações sazonais de precipitação.

No intuito de determinar as características climáticas regionais da China, Liao et al. (2004) utilizaram um modelo estocástico para geração de precipitação diária em 672 estações, sendo adotada uma estrutura baseada na *CM* de 1ª ordem e a distribuição gama. Com base nessa estrutura, a precipitação foi simulada com eficiência em toda a China, mas, os eventos de precipitações máximas mensais não foram bem representados.

Szyniszewska e Waylen (2012) aplicaram um modelo de geração de precipitação diária em quatro províncias (Lopburi, Chachoengsao, Buriram e Sisaket) no nordeste da Tailândia. A *CM* foi empregada para modelar as transições de dias secos e chuvosos, e a quantidade de precipitação foi representada pela distribuição gama cujos parâmetros foram estimados a partir da média e variância através do método dos momentos.

No distrito de Chapai Nawabganj, localizado a noroeste de Bangladesh, Barkotulla (2012) estudou os fatores de precipitação que influenciavam na ocorrência de seca agrícola. O autor utilizou a *CM* de 1ª ordem para definir as probabilidades de ocorrência de precipitação, e para a modelagem da quantidade, foi usada a função de distribuição Weibull.

Kist e Virgens Filho (2015) realizaram análises de precipitação diária para 29 localidades, no estado do Paraná. Para isso, foram aplicadas algumas funções de probabilidades (exponencial, gama, Weibull, log-normal, pareto generalizado e exponencial mista). Nesse caso, foi verificada a aderência das distribuições por meio de testes não-paramétricos (Anderson-Darling e Qui-Quadrado). Baseado nos resultados, a distribuição exponencial mista foi a que apresentou melhores ajustes aos dados seguida das distribuições Gama e Weibull, respectivamente.

Aba et al. (2014) realizaram a modelagem de precipitação utilizando a distribuição exponencial mista e Weibull para quatro estações pluviométricas na bacia do Rio Damansara, na Malásia. Os resultados indicam que para climas tropicais, o modelo estocástico usando uma distribuição exponencial mista, é a melhor escolha para geração de séries de precipitação. Li et al. (2013) em uma avaliação de 24 estações meteorológicas em duas bacias hidrográficas

(Chute-du-Diable e Yamaska) na província de Quebec (Canadá), também recomendam o uso da distribuição exponencial mista.

O uso da distribuição da exponencial mista mostrou eficiência na modelagem de precipitação diária em 33 estações meteorológicas localizadas no sul da Espanha. Neste trabalho em particular, a exponencial mista foi condicionada aos efeitos da perturbação da Oscilação do Atlântico Norte (NAO) por meio da utilização do índice de NOA (MORENO-PÉREZ et al., 2014).

Em Santa Maria (RS) foram analisadas 5 distribuições de probabilidade (gama, Weibull, normal, log-normal e exponencial simples) para estimar as quantidades de precipitação diária (SILVA et al. 2007). As funções que melhor representaram as quantidades e precipitação foram as funções gama e Weibull.

No trabalho de Santos (2017) também foi constatada a eficiência do uso das funções gama e Weibull para estimar as quantidades de chuvas médias diárias em 80 estações pluviométricas na Bacia Hidrográfica do Rio Tapajós, utilizando a *CM* de 1ª ordem. Os resultados apontaram que a função gama é mais eficiente para os meses mais úmidos e a função Weibull para os meses menos chuvosos.

2.1.7 Procedimentos para estimar os parâmetros das distribuições probabilísticas

Na modelagem probabilística é indispensável a etapa de estimativa dos parâmetros das distribuições de probabilidade. Segundo Caldeira et al. (2015), estes parâmetros guardam informações importantes das precipitações e possuem relação direta com a localização geográfica das estações pluviométricas. Em vista disso, a má qualidade dos estimadores prejudica diretamente os resultados a serem alcançados. Entre os métodos existentes, os mais conhecidos e aplicados são os métodos dos momentos (*MM*) e o método da máxima verossimilhança (*MVS*) (RICKLI et al. 2008).

Naghattini e Pinto (2007) definem o *MM* como a igualdade entre os momentos amostrais aos populacionais. O *MM* é um método simples, e a qualidade dos seus estimadores em geral são inferiores e menos eficientes do que os estimadores do *MVS* para amostras de grande tamanho ($n > 100$) ou para distribuições de três ou mais parâmetros. Por mais que o *MVS* seja considerado um estimador bastante eficaz por gerar resultados com menores valores de variância, para casos em que o tamanho da amostra é pequeno, a qualidade deste é comparável ou inferior ao *MM*.

Rickli et al. (2008) estudaram a chuva mensal em Piracicaba - SP, pela distribuição gama, utilizando três diferentes estimadores: *MM*; *MVS*; Greenwood e Durand. Os resultados

mostram que os parâmetros estimados pelo *MVS* foram satisfatórios para a maioria dos meses. Calgaro et al. (2009), com o uso do *MVS*, estimaram os parâmetros da distribuição gama e também obtiveram bons resultados na simulação de chuvas diárias no estado do Rio Grande do Sul.

Nascimento e Kelman (1995) utilizaram o *MM* para estimar os parâmetros da distribuição exponencial a dois parâmetros para aferir as precipitações diárias de 4 sub-bacias da bacia do Rio Uruguai. Os resultados demonstraram que o método é adequado para estimar os parâmetros desta distribuição.

Detzel e Mine (2011a, b) empregaram o *MVS* para aferir os parâmetros de algumas distribuições para bacia do rio da Prata, no primeiro, usou-se a função exponencial simples, exponencial a dos parâmetros, gama e exponencial mista, e no segundo, utilizou-se apenas a exponencial mista. Os resultados destes trabalhos mostram que em séries longas de precipitação, o uso do *MSV* estima de forma adequada os parâmetros das distribuições teóricas.

Francisco et al. (2015) utilizaram o *MVS* para determinar os parâmetros da distribuição Weibull para a precipitação mensal do estado da Paraíba, os resultados mostraram que as probabilidades de 25%, 50% e 75% foram bem representadas pela distribuição de Weibull para a maioria dos meses. No entanto, no período chuvoso (junho, julho e agosto) não obtiveram bom ajuste.

Para a bacia do Tapajós, Santos (2017) usou tanto do *MM* e *MVS* para definir os parâmetros alfa e beta das funções gama e Weibull para estimar chuvas diárias. A autora constatou que o *MVS* se mostrou superior para a maioria dos meses, no entanto, para meses considerados secos (junho, julho e agosto), o *MM* foi mais satisfatório.

2.1.8 Testes de aderência

O teste de aderência é uma etapa essencial para a modelagem hidrológica, pois nele ocorre a verificação dos resultados da distribuição em relação aos dados históricos. Portanto, uma vez confirmado o ajuste, admite-se a hipótese de que a distribuição é capaz de representar o conjunto de informações de forma satisfatória (FRANCISCO et al. 2015). Os testes de hipóteses normalmente utilizados são os testes não paramétricos qui-quadrado (χ^2), Kolmogorov-Smirnov (KS) e Anderson-Darling (AD) (Tabela 2).

Tabela 2– Testes de aderência mais utilizados na literatura.

Testes de aderência	Autores
(χ^2)	Morais et al. (2001)
(KS)	Baú et al. (2013); Beijo et al. (2003); Braga et al. (2018); Cargnelutti filho et al. (2004); Coan et al. (2014); Francisco et al. (2015); Martin et al. (2008); Martins et al. (2010); Oliveira et al. (2010); Pedron e Klosowski (2008)
(χ^2) e (KS)	Borges e Thebaldi (2016); Caldeira et al. (2015); Oliveira et al. (2005); Teixeira-Gandra et al. (2017); Zakaria e Deni (2016)
(χ^2) e (AD)	Kist e Virgens filho (2015)

Conforme descrito na Tabela 2, o teste *KS* é o mais utilizado. Esse teste baseia-se na comparação entre a distribuição de frequência empírica e a probabilística. Isto posto, efetua-se a diferença absoluta entre as essas distribuições acumuladas. Uma vez definido o valor máximo do módulo da diferença, é comparado com um valor crítico tabelado que é definido de acordo com o número de observações da série testada (VIEIRA et al. 2010).

2.2 MODELAGEM ESTOCÁSTICA DE OCORRÊNCIA DE PRECIPITAÇÃO

A modelagem da ocorrência de precipitação considera dois estados nos processos aleatórios (secos e molhados). De acordo com Nascimento e Kelman (1995), os principais modelos estocásticos utilizados para simular o processo de ocorrência são: sequências alternadas de dias secos e chuvosos (alternância de eventos com renovação), séries binárias discretas (*CM* e processos de Bernoulli) e processos pontuais (processos de Poisson). Dentre todos os modelos estocásticos citados, a *CM* é a mais utilizada na literatura (ALAM et al. 2013; BÁU et al. 2013; CALGARO et al. 2009; CARVALHO et al. 2017a; CHEN et al. 2017; DETZEL; MINE, 2011b; HABIBI et al. 2018; LAZRI et al. 2015; MANDAL et al. 2014; NG et al. 2017; SANTOS, 2017; SONNADARA; JAYEWARDENE, 2014; YOO et al. 2016; ZAKARIA; DENI, 2016).

Outro aspecto que deve ser considerado no processo de ocorrência é a persistência ou dependência temporal da precipitação. Visto que, de acordo com o estudo de Genovez (1987) foi comprovado que quando o modelo se baseia na hipótese de sequências não correlacionadas de dias secos e chuvosos, não apresenta resultados satisfatórios.

No estudo desenvolvido por Roldan e Woolhiser (1982a) foi realizada uma comparação entre os processos Markovianos e de alternância de eventos, uma distribuição geométrica truncada foi utilizada para simular a sequência de dias chuvosos, e uma distribuição binomial negativa truncada para simular sequência de dias secos para 4 estações

nos EUA. Para todas as estações estudadas, o modelo da *CM* se mostrou superior ao de alternância de eventos.

Os modelos que utilizam a *CM* possuem várias vantagens segundo Yoo et al. (2016), as principais estão na facilidade de se estimar os parâmetros e na geração de dados, estas características tornam esse modelo mais utilizado do que os modelos baseados no processo de Poisson, por exemplo, visto que a última estrutura apresenta maior complexidade na estimativa dos parâmetros.

2.2.1 Cadeia de Markov (CM)

Os modelos que utilizam a *CM* para gerar as ocorrências de precipitação vêm sendo recorrentes na literatura nacional e internacional (ARAÚJO et al. 2012; KELLER FILHO et al. 2006). Existem várias configurações de *CM* na literatura, por exemplo: *CM* homogêneas (BÁU et al. 2013; SANTOS; BASSEGIO, 2011; SILVA et al. 2010), *CM* não homogêneas (RAJAGOPALAN et al. 1996; AILLIOT; MONBET, 2012), modelos semi-Markovianos (SEMENOV et al. 1998), cadeia híbrida de Markov (HANSEN; INES, 2005) e modelos de Markov ocultos (CHEN et al., 2017). Em todos os casos, a interpretação dos estados continua a ser uma característica fundamental desses modelos.

O processo estocástico Markoviano é fundamentado na conjuntura de que os estados de chuva ou não chuva precedentes são irrelevantes para a predição dos estados seguintes, ou seja, o sistema não possui “memória”, entretanto, é necessário que o estado atual seja conhecido. Os parâmetros de estado e de tempo da *CM* assumem intervalos discretos ($X_1, X_2, X_3, \dots, X_n$). A relação descrita na Equação 1, estabelece que a distribuição condicional ou de transição X_{t+1} de dada série histórica, depende apenas do estado presente “ X ” do processo no tempo “ t ”. Logo, $P(X_{t+1}=j / X_t=i)$ define a probabilidade de transição, em um passo, do estado “ i ” para o estado “ j ” no instante de tempo “ t ”.

$$P(x_{t+1} = j/x_0 = i_0, x_1 = i_1, \dots, x_t = i_t) = P(x_{t+1} = j/x_t = i_t) \quad (1)$$

A Equação 1 refere-se a uma *CM* de 1ª ordem de dois estados, ou seja, apenas os dias atuais e anteriores são levados em consideração na análise, sob as condições de dias considerados secos ($X_t=0$) ou chuvosos ($X_t=1$). Para considerar mais dias anteriores na definição de P , são utilizadas as *CM* de ordens superiores. Assim, a definição das *CM* de 2ª, 3ª e 4ª ordem pode ser computada, pelas Equações 2, 3 e 4.

$$P(x_{t+1} = j/x_0 = i_0, x_1 = i_1, \dots, x_t = i_t) = P(x_{t+1} = j/x_t = i_t, x_{t-1} = i_{t-1}) \quad (2)$$

$$P\left(x_{t+1} = \frac{j}{x_0} = i_0, x_1 = i_1, \dots, x_t = i_t\right) = P(x_{t+1} = j/x_t = i_t, x_{t-1} = i_{t-1}, i_t, x_{t-2} = i_{t-2}) \quad (3)$$

$$P\left(x_{t+1} = \frac{j}{x_0} = i_0, x_1 = i_1, \dots, x_t = i_t\right) = P\left(x_{t+1} = \frac{j}{x_t} = i_t, x_{t-1} = i_{t-1}, x_{t-2} = i_{t-2}, x_{t-3} = i_{t-3}\right) \quad (4)$$

A configuração dos estados secos e chuvosos varia de acordo com a ordem da cadeia escolhida, como mostrado nas Equações de 2 a 4, portanto, como forma de exemplo, foi elaborada a Tabela 3, que descreve a forma de posicionamento dos estados na *CM* até a 3ª ordem.

Tabela 3 – Cadeias de Markov da 1ª a 3ª ordem.

Primeira ordem								
Atual \ Anterior	Anterior							
	S	M	SS	MS	SM	MM		
	S	SS	MS					
M	SM	MM						

Segunda Ordem						
Atual \ Anterior	Anterior					
	SS	SM	MS	MM		
	S	SSS	SMS	MSS	MMS	
M	SSM	SMM	MSM	MMM		

Terceira Ordem								
Atual \ Anterior	Anterior							
	SSS	MSS	SMS	SSM	SMM	MSM	MMS	MMM
	S	SSSS	MSSS	SMSS	SSMS	SMMS	MSMS	MMSS
M	SSSM	MSSM	SMSM	SSMM	SMMM	MSMM	MMSM	MMMM

*S- seco; M – molhado.

Na literatura a *CM* mais utilizadas é a de 1ª ordem, o que significa que o evento do dia atual depende do evento do dia anterior (DENI et al. 2009). Segundo Chen et al. (2012), o número de parâmetros necessários para simular a ocorrência de precipitação, utilizando a *CM*, aumenta exponencialmente com a ordem do processo. Visto que, os modelos Markovianos de 1ª, 2ª e 3ª ordem necessitam de dois, quatro e oito parâmetros, respectivamente.

De acordo com estudos anteriores de Wilks (1999), as *CM* de 1ª ordem podem não ser adequadas para gerar longos períodos menos chuvosos e chuvosos. Portanto, os modelos de

Markov de ordem mais alta apresentam melhores desempenhos, mas as estimativas dos parâmetros desses modelos necessitam de séries históricas mais longas.

Em diversos estudos (CHEN; BRISSETTE, 2014; KELLER FILHO et al. 2006; LI et al. 2014; NG et al. 2017; ZAKARIA; DENI, 2016) já foi comprovado que a definição da ordem ótima da *CM* varia de acordo com o clima da região e com as épocas do ano da área de estudo. Para climas úmidos são mais indicados os modelos de 1ª ordem (DETZEL; MINE, 2011b). Enquanto que, para regiões com clima mais seco e árido, ordens superiores são mais recomendadas (DENI et al. 2009).

Ng et al. (2017) testaram até a quinta 5ª ordem para estabelecer a cadeia ótima de Markov na bacia do rio Kelantan, Malásia. Os resultados sugeriram que as *CM* de 2ª e 3ª ordem eram adequadas para simular ocorrências mensais e anuais de precipitação. Entretanto, os resultados apontaram que o uso da cadeia de 5ª ordem não foi satisfatório, portanto, o seu emprego não foi recomendado pelos autores.

Keller Filho et al. (2006) testaram várias ordens para a *CM* nos estados do Tocantins, Mato Grosso e Goiás. Os resultados mostraram que o uso da 3ª ordem era o mais indicado para simular as ocorrências diárias de chuva nessas regiões, ou seja, o processo de persistência depende de 3 dias secos e chuvosos anteriores. Jones e Thornton (1997) também recomendam o uso da 3ª ordem para estações localizadas em regiões tropicais.

No estado da Paraíba, Azevedo e Leitão (1990) também constataram que a 3ª ordem da *CM* era mais apropriada para simular precipitações diárias, no entanto, em algumas regiões que sofriam a interferência de brisas litorâneas, foi sugerido o uso da 2ª ordem. Vale frisar que, para algumas microrregiões do sertão de Cajazeiras, Alto Piranhas e Carris Velhos foram recomendadas ordens superiores a 3ª ordem. De acordo com Moreno-Pérez et al. (2014), uma característica importante no uso de ordens mais altas da *CM* é a redução do tamanho da amostra, que aumenta o nível de incerteza nas estimativas dos parâmetros.

A determinação da ordem ótima de um modelo de Markov é normalmente definida pelos critérios de informação Akaike (*AIC*) (Akaike, 1974) e a bayesiana (*BIC*) (Schwarz, 1978). Segundo Katz (1981) o critério *AIC* tende a superestimar a ordem da cadeia a ser empregada, por outro lado, ainda de acordo com o autor o critério *BIC* consegue proporcionar resultados mais consistentes.

O modelo adequado será aquele que produzir o menor *AIC* ou *BIC*, esses critérios são calculados pelo princípio da parcimônia, visto que, a penalidade dos testes aumenta proporcionalmente com o aumento da ordem da cadeia. Existe uma semelhança entre os dois critérios, discordando apenas no grau de rigor adotado.

Back e Miguel (2017) utilizaram a *CM* de 1ª ordem associada à distribuição geométrica para avaliar as variações sazonais e espaciais da ocorrência de dias secos e chuvosos em cinco estações pluviométricas, no estado de Santa Catarina. Os autores constataram que o uso desta metodologia apresentou bom desempenho para estimar a probabilidade de dias secos e chuvosos.

A ocorrência de dias secos e chuvosos foi definida para região de Rio Largo–Alagoas, por meio da *CM*. E na modelagem das quantidades de precipitação, foi utilizada a função Gama de dois parâmetros (CARVALHO et al. 2017a). Os resultados apontaram que a *CM* é uma boa ferramenta para indicar as épocas com maiores chances de ocorrências de eventos extremos de precipitação.

Zakaria e Deni (2016) utilizaram 1ª e 2ª ordem das *CM* com a distribuição geométrica para identificar as características e a persistência de períodos secos e chuvosos para monções diárias em três regiões diferentes da Malásia Peninsular. Os resultados indicaram que a 2ª ordem é a mais adequada para descrever a distribuição dos períodos de seca na maioria dos locais estudados.

Habibi et al. (2018) utilizaram a *CM* de 1ª ordem não-estacionária para avaliar a seca na bacia do Chélif-Zahrez, região semiárida do norte da África. As análises mostraram que a probabilidade de secas de vários anos é bastante alta, principalmente nas sub-bacias ao sul onde as secas podem chegar até dois anos consecutivos. No estudo de Nalbantis e Tsakiris (2009) e Sanusi et al. (2015) também foi utilizada a *CM* de 1ª ordem não-estacionária para caracterizar a ocorrência de seca na Grécia e Malásia Peninsular.

2.2.2 Determinação do valor mínimo de chuva para dias considerados secos

Um dia é considerado seco quando em um período de 24 horas, nenhum evento de precipitação acontece, portanto, o dia sem chuva é determinado por um valor limite. Na literatura a determinação desse valor limiar de precipitação, que considere os dias como secos possui várias definições (Tabela 4). Assim, a ausência desse limite deixa em aberto inúmeras abordagens a serem aplicadas, como por exemplo:

Vasconcellos et al. (2003) definiram dia seco atrelado ao balanço hídrico, que por sua vez depende de algumas características, como: física do solo, clima, evapotranspiração das plantas da região em estudo. Outros trabalhos determinaram como dias secos aqueles em que a precipitação seja igual a zero ou quando fosse inferior a evapotranspiração de referência (ANDRADE JUNIOR et al. 2001; VASCONCELLOS et al. 2003; VIANA et al. 2002).

Na região de Sete Lagoas, MG, Silva et al. (2010) usaram como dias secos os valores de precipitação menores que os valores estimados de evapotranspiração para o plantio de

milho. Carvalho et al. (2017a) definiram as ocorrências de dias secos e chuvosos considerando seis limites de referências de precipitação (0, 1, 2, 3, 4 e 5 mm), os dias com limite igual ou inferior a esses foram valores considerados como secos.

Uma definição estabelecida por Barron et al. (2003) determina que dias secos ou chuvosos estão atrelados a necessidades das atividades humanas. Na literatura existem diversos valores que foram estabelecidos por cada autor de acordo com objetivo do estudo, como pode ser visto na Tabela 4.

Tabela 4– Valores mínimos de precipitação para dias considerados secos ou chuvosos.

Limiar mínimo (mm)	Autores
0,10	Back e Miguel (2017); Deni et al. (2009); Dourado Neto et al. (2005); Keller Filho et al. (2006); Moreno-Pérez et al. (2014); Santos (2017); Sediyaama et al. (1996); Zakaria e Deni (2016)
0,20	Calgaro et al. (2009); Mormeneo e Castellvi (2001)
0,30	Detzel e Mine (2011a); Baú et al. (2013); Mehrotra e Sharma (2009)
0,50	Morais et al. (2001)
0,85	Barron et al. (2003)
1,00	Santos et al. (2009); Teixeira-Gandra et al. (2016)
2,50	Johnson et al. (1996)
3,00	Ferreira (2012)
5,00	Santos e Bassegio (2011); Pizzato et al. (2012); Viana et al. (2002)
10,0	Deni et al. (2009)

Para determinar um dia como chuvoso para este trabalho, a precipitação foi tomada como sendo igual ou superior a 0,1 mm. Sendo que este é o valor mais utilizado nos trabalhos de acordo com a Tabela 4. Além do que, o valor estabelecido é o equivalente a menor quantidade registrada por um pluviômetro.

3. ÁREA DE ESTUDO

3.1 REGIÃO HIDROGRÁFICA TOCANTINS-ARAGUAIA (RHTA)

3.1.1 Hidrografia e Vegetação

A *RHTA* é a segunda maior bacia hidrográfica brasileira em termos de área e vazão, estando atrás apenas da bacia do Amazonas. A área de drenagem da *RHTA* é de 918.822 km², o que representa 11% do território nacional, seus limites passam pelo território autônomo do Distrito Federal (0,1%) e por 5 estados das regiões Norte, Nordeste e Centro-Oeste, sendo eles: Maranhão (3,4%), Mato Grosso (14,7%), Goiás (21,3%), Tocantins (30,2%) e no Pará (30,3%). De acordo com a Agência Nacional de Águas (ANA, 2006) a *RHTA* ainda pode ser subdividida em 3 sub bacias: Tocantins Baixo (TOB), Tocantins Alto (TOA) e Araguaia (ARA), conforme a Figura 2.

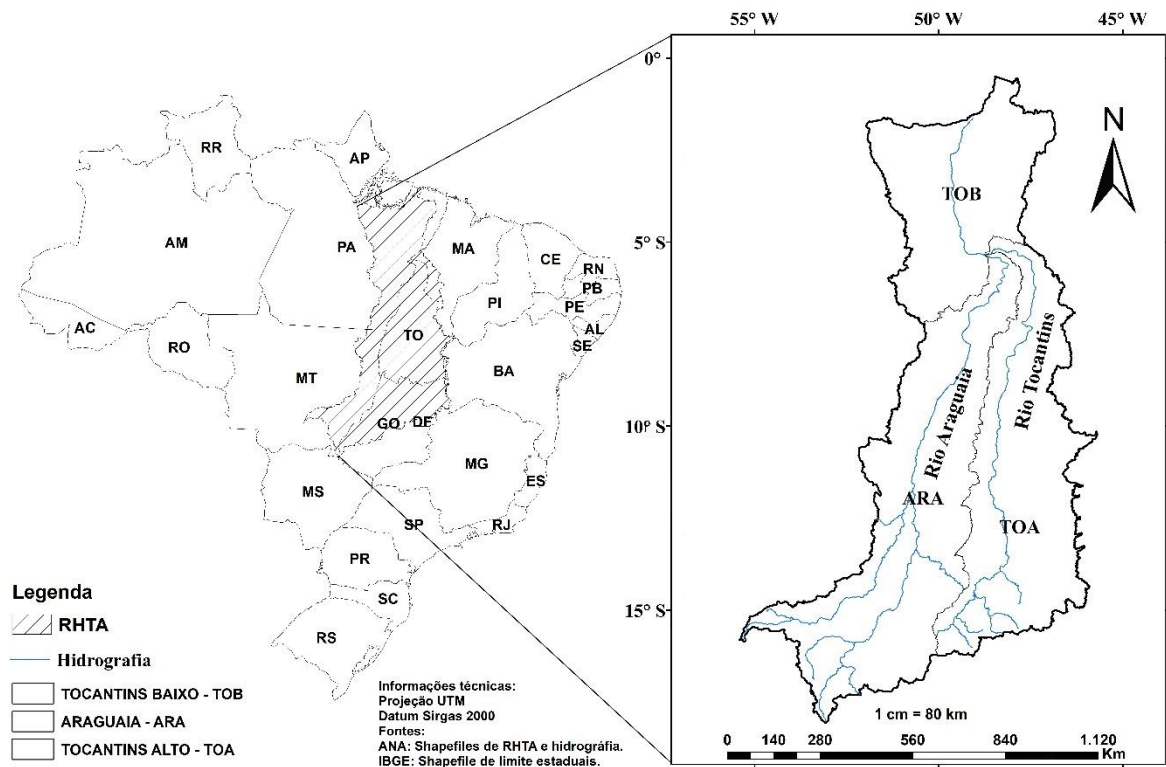


Figura 2 - Localização da RHTA.

De acordo com Falck et al. (2015) os rios Tocantins e Araguaia são os dois principais da *RHTA*. O rio Tocantins é formado na parte sul da bacia no planalto de Goiás, acerca de 1000 metros de altitude, pelos rios Maranhão e das Almas, sua extensão é de 1960 km até a sua Foz na Baía do Marajó. Seu principal afluente é o rio Araguaia que flui 1670 km antes de sua confluência com o Tocantins. Na margem direita do Tocantins merece destaque os

seguintes afluentes: Bagagem, Tocantinzinho, Paranã, Sonos, Manoel Alves Grande e Farinha; já na margem esquerda, ficam os rios Santa Teresa e Itacaiúnas (ANA, 2013).

Na bacia em questão existem diversos usos da água, de acordo com ANA (2009) a vazão utilizada é de $95 \text{ m}^3\text{s}^{-1}$, deste total, só a irrigação usa ($57 \text{ m}^3\text{s}^{-1}$), dessedentação animal ($16 \text{ m}^3\text{s}^{-1}$) e o abastecimento humano ($13 \text{ m}^3\text{s}^{-1}$). A predominância dos usos para irrigação e pecuária tornam estas atividades estratégicas para economia da região. Além disso, Westin et al. (2014) afirmam que o turismo e mineração também merecem destaque, principalmente na sub bacia *ARA*.

A *RHTA* apresenta dois biomas: a Floresta Amazônica, que se localiza nas porções norte e noroeste da bacia 35%, e o Cerrado que ocupa os 65% restantes. O bioma Amazônico é constituído por diversos ecossistemas: floresta ombrófila densa, floresta ombrófila aberta, floresta estacional decidual e semidecidual, campinarana, formações pioneiras, refúgios montanos, savana amazônica, matas de terra firme, matas de várzeas e matas de igapó. No Bioma de cerrado, as formações fisionômicas são o cerradão, o cerrado típico, o campo cerrado, o campo sujo cerrado e o campo limpo são predominantes (ANA, 2009). Nos dois biomas citados, existe o Ecótono² Amazônia-Cerrado, que está situado ao sul da sub-bacia *TOB*, e ao norte do Tocantins e a noroeste e norte da sub-bacia *ARA*. Por outro lado, o Ecótono Cerrado-Caatinga se localiza a nordeste do Tocantins (VALENTE et al., 2013).

A dinâmica do uso e ocupação da *RHTA* vem sofrendo mudanças no sentido norte-sul desde a abertura da rodovia Belém-Brasília, na década de 60, e com a construção da Transamazônica na década de 70 e 80. Dentre os diversos tipos de uso do solo nesta região, os mais relevantes, estão divididos em áreas urbanizadas, de lavouras, de florestas, de sistemas agroflorestais, pastagens e estabelecimentos agropecuários (Figura 3). Além do que, um dos maiores complexos minerais do mundo (Serra do Carajás) está localizado na mesma (ANA, 2009).

² Área de transição ambiental entre dois ou mais biomas que fazem fronteira.

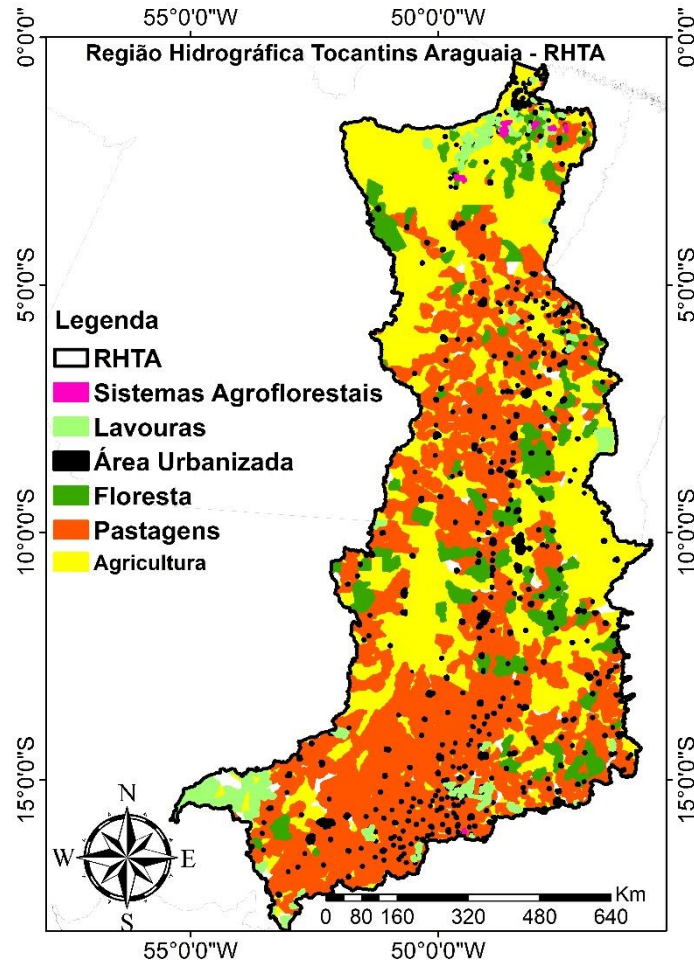


Figura 3 – Uso e ocupação do solo da RHTA
 Fonte: Adaptado do IBGE (2014).

3.1.2 Caracterização climatológica

A maioria da *RHTA* segundo Alvares et al. (2013a) possui temperatura média anual acima de 26°C, contudo, nas porções noroeste da sub bacia ARA e sudeste da TOA, as temperaturas médias anuais variam de 23°C a 26°C. Para classificação climática da *RHTA*, utilizou-se a atualização mais recente de Köppen para os tipos de climas brasileiros, realizada por Alvares et al. (2013b), seguindo a classificação dos autores que disponibilizaram as informações em forma de mapa com resolução de 100 metros, gerou-se a Figura 4.

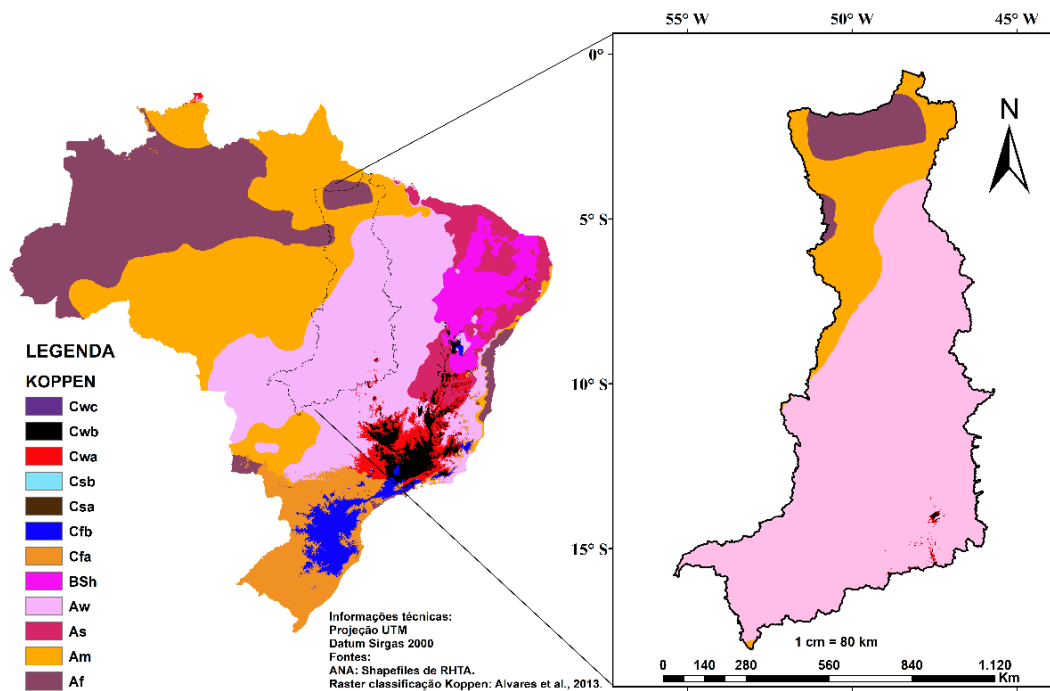


Figura 4- Tipos de clima da RHTA.
 Fonte: Adaptado de Alvares et al. (2014b).

De acordo com a Figura 4, a *RHTA* possui cinco climas característicos (Af, Am, Aw, Cwa e Cwb). Af (úmido megatérmico): precipitações anuais superiores a 3.000 mm. Am (tropical úmido megatérmico): precipitação anual da ordem de 2.000 mm. Aw (quente e úmido megatérmico): precipitação anual da ordem de 1.700 mm. Cwa (subtropical): precipitações anuais da ordem de 1.500 mm. Cwb (clima temperado marítimo): precipitações anuais da ordem de 1400 mm. Os climas Cwa e Cwb são influenciados por elevadas altitudes (ROLIM et al. 2007).

Os totais pluviométricos aumentam na direção sul-norte da área de estudo, ocorrendo 1.500 mm (Brasília) a 3.000 mm (Belém), e decrescendo no sentido de oeste para leste 1.800 mm a 1.200 mm (ANA, 2009). O Paranã (TO) é o município com menor valor de precipitação, tendo a média em torno de 1 mm/mês entre junho e agosto. O período seco é caracterizado em três meses do ano (setembro, outubro e novembro) na porção norte, e para as outras regiões remanescentes os meses são de cinco a seis (maio a outubro) (ANA/MMA, 2006).

De acordo com Marengo (2004), as regiões tropicais apresentam alta variação espacial e temporal no comportamento da precipitação. Além disso, a maioria dos eventos de precipitações não ultrapassam algumas horas de duração, e estes são influenciados por vários fenômenos que interferem nas diversas escalas de precipitação (FALCK et al. 2016).

Neste contexto, o conhecimento do comportamento das precipitações pluviométricas da *RHTA* tem caráter estratégico para a produção agrícola, pecuária e para as atividades agroindústrias (ANA, 2009; SPERA et al., 2016; MATTOS et al., 2017). Também pode ser utilizado para o planejamento do controle de enchentes e no dimensionamento de obras de engenharia hidráulica (XU et al., 2018; WANG e WANG, 2018).

3.1.3 Estações pluviométricas

As informações de 499 estações pluviométricas foram retiradas do banco de dados da Agência Nacional de Águas - ANA e do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do INMET. Na seleção das estações foram consideradas aquelas em que as séries históricas tivessem dados consistidos e com poucas falhas, e na definição do intervalo foi adotado o critério adotado por Santos (2017), que utilizou séries com limite de 1,8% de seus dados faltantes.

Optou-se neste trabalho pelo não preenchimento de falhas, seguindo as recomendações de Detzel e Mine (2011a) e Báu et al. (2013). Segundo estes autores, as falhas nas séries afetam a qualidade da definição das probabilidades de transição e na estimativa dos parâmetros das funções de densidade de probabilidade (FDPs).

Devido à extensão territorial da *RHTA* e sua variabilidade de precipitação, optou-se por classificar as estações pluviométricas nas regiões homogêneas (RH) de precipitação definidas por Gomes et al. (2018), sendo necessárias as informações das coordenadas geográficas de cada estação. As três *RH* podem ser vistas na Figura 5.

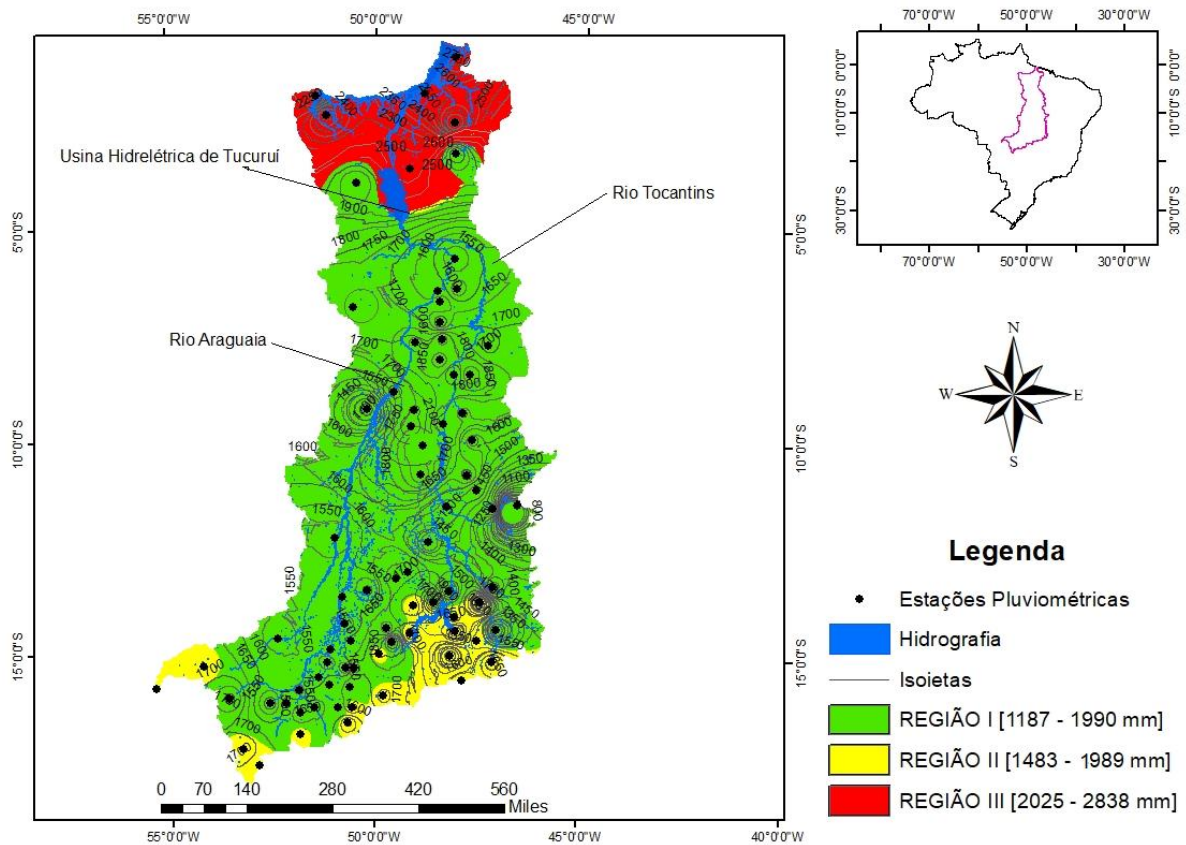


Figura 5 - Regiões Homogêneas de Precipitação da RHTA.

Fonte: Gomes et. (2018).

Keller Filho et al. (2006) afirmaram que a falta de dados pluviométricos pode ser contornada quando se trabalha em *RH*, pois a regionalização explora o máximo das informações da bacia em estudo. Após aplicação do limiar de falhas de 1,8%, foram catalogadas 196 estações do INMET e da ANA (Apêndice A), as quais foram utilizadas como entrada do modelo estocástico. Desse total de estações pluviométricas selecionadas, apenas 33 possuem séries com 30 anos de dados, 63 estações com séries de 29-20 anos e 100 estações restantes possuem séries entre 8 e 19 anos.

Na Figura 6, é possível observar a distribuição espacial das estações pluviométricas. Uma vez classificadas as estações nas *RH*, foram definidas as ocorrências e as quantidades de precipitação diária.

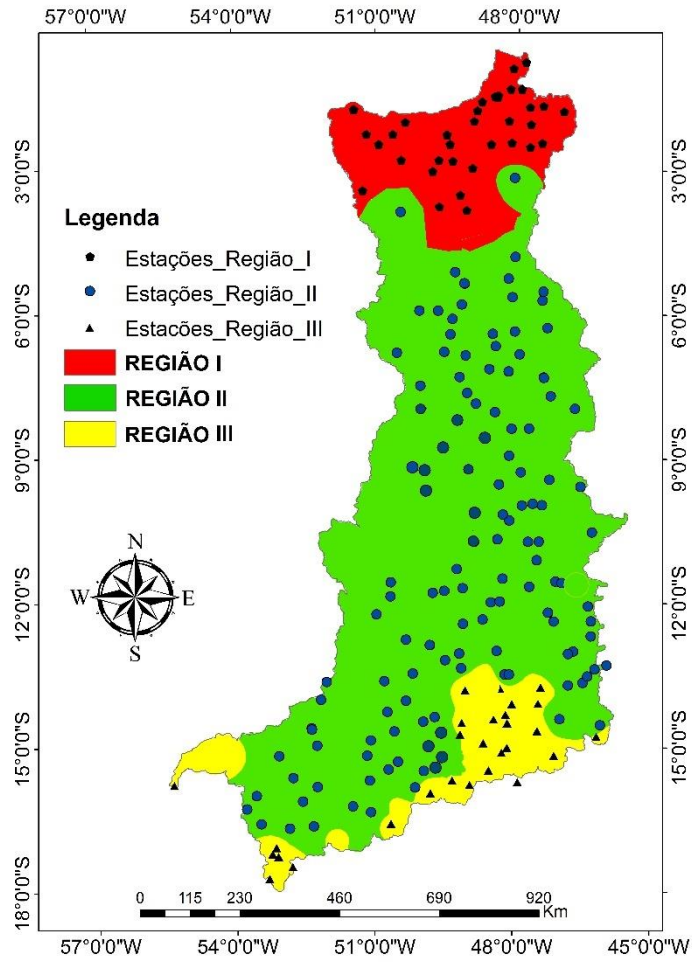
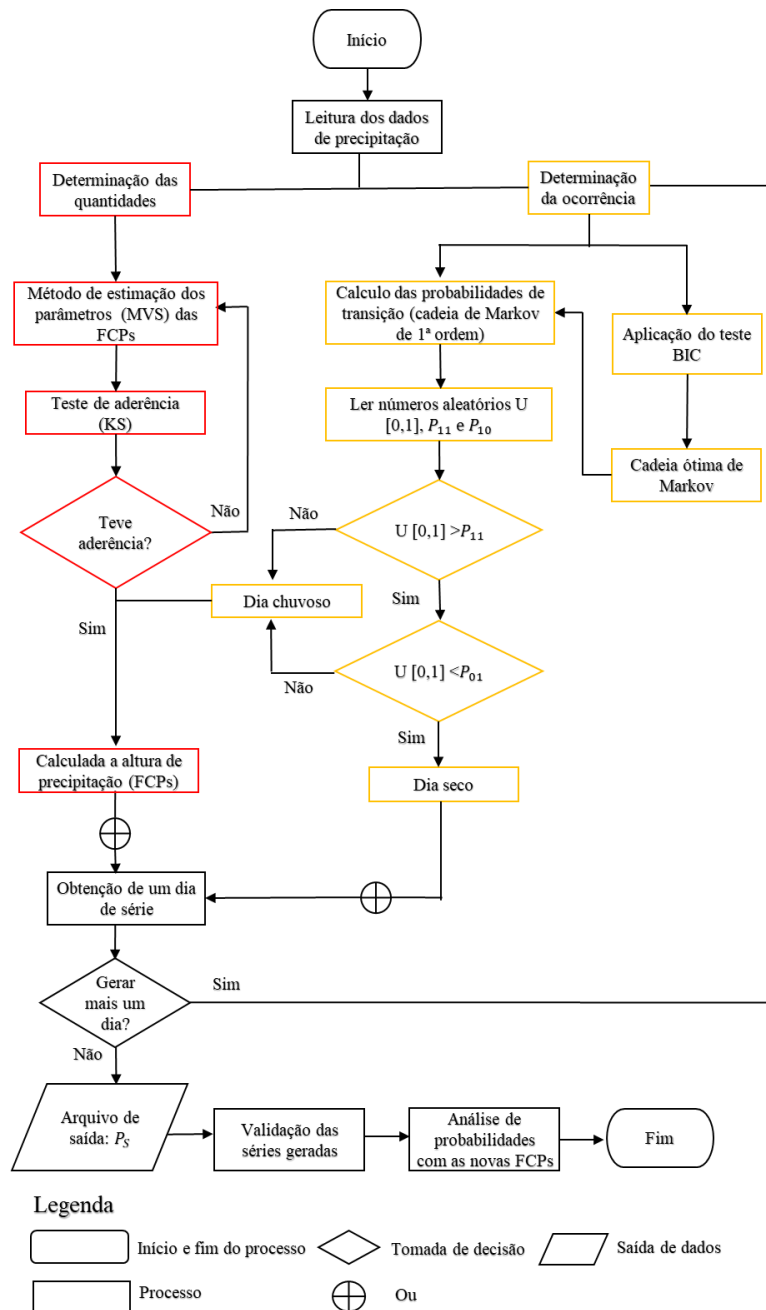


Figura 6 - Estações pluviométricas da RHTA.

4. METODOLOGIA

4.1 MODELO PROPOSTO PARA ESTIMATIVAS DE PRECIPITAÇÃO MÉDIAS DIÁRIAS

O modelo proposto é do tipo univariado, tendo por objetivo estimar as precipitações médias diárias nas *RH* da *RHTA*. O modelo foi analisado em duas etapas, na primeira, foram realizadas as estimativas das ocorrências de precipitação dos dias secos e chuvosos, e na segunda, foram definidas as alturas de lâminas precipitadas para os dias considerados chuvosos (Figura 7).



*Em amarelo: 1ª etapa do modelo; Em vermelho: 2ª etapa do modelo.

Figura 7 - Fluxograma do algoritmo do modelo estocástico pluviométrico.

No modelo foi adotada sazonalidade mensal com comportamento estacionário. Essa escolha é fundamentada nos trabalhos de Back e Miguel (2017); Detzel e Mine (2011b); Hundedcha et al. (2009) e Kist e Virgens filho (2015).

4.2 MODELAGEM DA OCORRÊNCIA DA CHUVA

4.2.1 Cadeia de Markov (CM)

Para modelagem da ocorrência de precipitação foi utilizada a *CM* de 1ª ordem de dois estados, essa escolha foi embasada nos bons resultados obtidos por Calgaro et al. (2009); Detzel et al. (2011b) e Santos (2017). Assim, a persistência da cadeia de 1ª ordem, é definida pela matriz de probabilidade de transição (Tabela 5).

Tabela 5– Matriz de probabilidade da *CM* de 1ª ordem.

Anterior		
Atual	$X_{t+1}=0$	$X_{t+1}=1$
$X_t=0$	P_{00}	P_{01}
$X_t=1$	P_{10}	P_{11}

Fonte: Adaptado de Báu et al. (2013).

As probabilidades da matriz de transição são definidas como:

$$P_{00} = P [X_{t+1}=0 / X_t=0]$$

$$P_{01} = P [X_{t+1}=1 / X_t=0]$$

$$P_{10} = P [X_{t+1}=0 / X_t=1]$$

$$P_{11} = P [X_{t+1}=1 / X_t=1]$$

As probabilidades são descritas pelas seguintes hipóteses de combinação entre os estados seco ($X_t=0$) e chuvoso ($X_t=1$):

P_{00} - é a probabilidade de não chover hoje, pois não choveu ontem;

P_{01} - é a probabilidade de não chover hoje, pois choveu ontem;

P_{10} - é a probabilidade de chover hoje, pois não choveu ontem; e

P_{11} - é a probabilidade de chover hoje, pois choveu ontem.

Os cálculos dessas probabilidades são realizados por meio da contagem dos elementos “N” presentes nas séries históricas de precipitação de uma determinada estação pluviométrica (Equações 6, 7, 8 e 9).

$$\hat{P}_{ij} \left\{ \begin{array}{l} P_{00} = \frac{N_{00}}{N_{01} + N_{00}} = \frac{N_{00}}{N_0} \quad (6) \\ P_{01} = \frac{N_{01}}{N_{00} + N_{01}} = \frac{N_{01}}{N_0} = 1 - P_{00} \quad (7) \\ P_{10} = \frac{N_{10}}{N_{11} + N_{10}} = \frac{N_{10}}{N_1} = 1 - P_{11} \quad (8) \\ P_{11} = \frac{N_{11}}{N_{10} + N_{11}} = \frac{N_{11}}{N_1} \quad (9) \end{array} \right.$$

Sendo:

N_{00} = Número de dias secos com anterior também seco;

N_{01} = Número de dias secos com anterior chuvoso;

N_{10} = Número de dias chuvosos com anterior seco;

N_{11} = Número de dias chuvosos com dia anterior chuvoso.

De forma genérica ao exposto acima, podemos escrever a *CM* de 1ª ordem, conforme citado por Wilks (2006) (Equação 10):

$$\hat{P}_{01} = \frac{N_{01}}{N_{0*}} \text{ e } \hat{P}_{11} = \frac{N_{11}}{N_{1*}} \quad (10)$$

Em que:

O símbolo “*” representa a possibilidade de dia seco (0) ou chuvoso (1), de acordo com o caso em questão. Portanto, $N_{1*} = N_{10} + N_{11}$ e $N_{0*} = N_{00} + N_{01}$.

A partir da modelagem de ocorrência de precipitação diária, foram determinados os valores de probabilidade de transição para os estados secos e chuvosos. O primeiro dia da série foi considerado como estado primitivo. Os demais estados foram classificados conforme o limiar adotado de 0,1 mm.

No processo de modelagem das séries de ocorrência da precipitação diária, foram determinados os valores da probabilidade de transição para cada um dos novos estados, secos ou chuvosos. Sendo que, foi classificado como estado primitivo, o primeiro dia da série de precipitação, quanto aos demais estados.

As definições dos estados foram realizadas pela geração de números aleatórios uniformemente distribuídos no intervalo entre [0,1] (U_t). Mas para isso, foram utilizados os valores críticos de transição, que segundo Wilks (1998), são representados por P_{01} e P_{11} , Equações 11 e 12, respectivamente.

$$P_c = \begin{cases} x_{t-1} = 0 \rightarrow P_c = P_{01} \\ x_{t-1} = 1 \rightarrow P_c = P_{11} \end{cases} \quad (11)$$

$$x_t = \begin{cases} 1, se u_t \leq P_c \\ 0, caso contrário \end{cases} \quad (12)$$

Muitos trabalhos (ARAÚJO et al. 2012; BACK et al. 2017; BAU et al. 2013; CARVALHO et al. 2017a) negligenciam o processo de avaliação da melhor ordem da *CM*, realizando diretamente a validação dos modelos apenas utilizando a 1ª ordem. Entretanto, este procedimento pode mascarar características físicas importantes do processo de precipitação, visto que, os erros encontrados quando comparadas às precipitações pluviométricas estimadas com as observadas, podem ser causados pela maior dependência de dias anteriores (ordens mais altas), ou pela própria incapacidade do modelo em representar tal fenômeno. Portanto, optou-se neste trabalho por executar a otimização da *CM* aplicando o teste BIC até a 4ª ordem.

4.2.2 Calibração da ocorrência

As *CM* de dois estados até a 4ª ordem foram determinadas, conforme descrito no Tópico 2.2.1. Como mostrado, a probabilidade \hat{P}_{ij} é calculada pela Equação 10, e as demais probabilidades de transição \hat{P}_j , \hat{P}_{ijk} , \hat{P}_{ijkl} e \hat{P}_{ijklm} foram definidas seguindo a mesma estrutura genérica mostrada por Wilks (2006). As estimativas dessas probabilidades foram obtidas separadamente para cada estação pluviométrica. Para definição da *CM* ótima, foi aplicado o critério BIC (Equação 13), conforme descrito por Dastidar et al. (2010). A *CM* mais apropriada foi aquela que alcançou o menor valor de BIC.

$$BIC(m) = -2L_m + S^m(Ln n) \quad (13)$$

Sendo:

m - ordem da *CM* testada;

S - número de estados;

n - tamanho da amostra.

Aplicando a Equação 13 às probabilidades de transição calculadas pelas *CM*, as funções de verossimilhança para os tensores de primeira, segunda, terceira, quarta e quinta ordens são definidas como:

$$L_0 = \sum_{i=0}^{s-1} N_j \ln(p_j) \quad (14)$$

$$L_1 = \sum_{i=0}^{s-1} \sum_{j=0}^{s-1} N_{ij} \ln(p_{ij}) \quad (15)$$

$$L_2 = \sum_{i=0}^{s-1} \sum_{j=0}^{s-1} \sum_{k=0}^{s-1} N_{ijk} \ln(p_{ijk}) \quad (16)$$

$$L_3 = \sum_{i=0}^{s-1} \sum_{j=0}^{s-1} \sum_{k=0}^{s-1} \sum_{l=0}^{s-1} N_{ijkl} \ln(p_{ijkl}) \quad (17)$$

$$L_4 = \sum_{i=0}^{s-1} \sum_{j=0}^{s-1} \sum_{k=0}^{s-1} \sum_{l=0}^{s-1} \sum_{m=0}^{s-1} N_{ijklm} \ln(p_{ijklm}) \quad (18)$$

Em que:

N = representa o número de dias presentes nas séries históricas com as transições (i, j, k, l e m);

p =representa as probabilidades de transição.

4.3 DETERMINAÇÃO DA QUANTIDADE DE PRECIPITAÇÃO DIÁRIA

A segunda parte do modelo estocástico de precipitações diárias envolve a modelagem de quantidades de precipitação condicionada aos dias considerados chuvosos ($P \geq 0,1$ mm). Assim, quando x_i for maior ou igual a 0,1 mm são aplicadas as FDPs para identificar as regiões de probabilidades superiores e inferiores aos valores das variáveis aleatórias. Neste estudo, foram aplicadas 4 FDPs (exponencial simples, exponencial a dois parâmetros, exponencial mista e gama) de não excedência³, tendo como propósito buscar qual delas representa melhor os dados históricos de precipitação diária.

4.3.1 Distribuição Exponencial simples

Segundo Thom (1958), a distribuição exponencial simples é geralmente empregada nas informações com alta assimetria, como aquelas cujo histograma tem a forma *J* invertido. Já Wan et al. (2005) afirmaram que a função citada é um caso especial da distribuição gama, a FDP da exponencial simples é dada pela Equação 19.

$$f_x(x) = \frac{1}{\beta} \exp\left(-\frac{x}{\beta}\right); x \geq 0 \quad (19)$$

³ Corresponde ao percentual da variável ser menor ou igual a um dado valor.

A função cumulativa de probabilidade (FCP) da exponencial simples é dada pela Equação 20 (NAGHETTINI; PINTO, 2007).

$$F(x) = 1 - \exp\left(-\frac{x}{\beta}\right) \quad (20)$$

Sendo:

x - a variável aleatória; e

β - parâmetro da distribuição.

4.3.2 Distribuição Exponencial a dois parâmetros

A FDP da distribuição Exponencial a dois parâmetros é definida pela Equação 21 (NASCIMENTO; KELMAN, 1995).

$$f_x(x) = \frac{1}{\beta} \exp\left(-\frac{x-\alpha}{\beta}\right); x > \alpha; \beta > 0 \quad (21)$$

E sua FCP é descrita pela Equação 22.

$$F(x) = 1 - \exp\left(-\frac{x-\alpha}{\beta}\right) \quad (22)$$

Sendo:

x - a variável aleatória; e

α e β - os parâmetros da distribuição.

4.3.3 Distribuição da Exponencial Mista

A FDP da distribuição exponencial mista a três parâmetros pode ser definida pela Equação 23:

$$f_x(x) = \frac{\alpha}{\beta_1} \exp\left(-\frac{x}{\beta_1}\right) + \frac{(1-\alpha)}{\beta_2} \exp\left(-\frac{x}{\beta_2}\right); x > 0; 0 \leq \alpha \leq 1; \beta_1 \geq \beta_2 \quad (23)$$

A Equação 23 por sua vez pode ser integrada analiticamente, portanto, sua FCP resultante resolvida para x como uma função de $F(x)$, é descrita na Equação 24.

$$F(x) = \int_0^x f_x(x) dx = 1 - \alpha \exp\left(-\frac{x}{\beta_1}\right) - (1 - \alpha) \exp\left(-\frac{x}{\beta_2}\right) \quad (24)$$

Sendo:

x – representa o valor assumido pela variável aleatória;

α – é o fator de probabilidade de proporção da mistura de exponenciais;

β_1 e β_2 – são os parâmetros da distribuição.

De acordo com Wilks (1998), a condição $\beta_1 \geq \beta_2$ nos dois parâmetros de escala não é matematicamente necessária para aplicação da Equação (23), mas essa condição é imposta, a fim de permitir que a FDP possa ser utilizada em modelos do tipo multivariado, ou seja, a geração das quantidades de precipitação pluviométrica para vários locais simultaneamente dentro de um limite pré-estabelecido, como por exemplo, uma bacia hidrográfica. Mas, neste estudo, apenas o modelo univariado foi empregado.

Para melhor compreensão da variabilidade dos parâmetros da exponencial mista, escolheu-se adotar o mesmo procedimento realizado por Moreno-Pérez et al. (2014), no qual os autores aplicaram a esperança matemática (Equação 25) da função exponencial mista, para visualizar o comportamento geral da respectiva função.

$$\mu = \alpha\beta_1 + (1-\alpha)\beta_2 \quad (25)$$

Como resultado, a distribuição exponencial mista é representada pelos parâmetros α , β_1 e μ . Ainda segundo Moreno-Pérez et al. (2014), o parâmetro α apresenta alta variabilidade ao longo do tempo (ruído).

É importante mencionar que a exponencial mista a três parâmetros pode ser reduzida a uma exponencial simples quando ($\alpha=1$ ou $\alpha=0$ e $\beta_1=\beta_2$), esse acontecimento é conhecido como degeneração da exponencial mista. Esse tipo de acontecimento é indesejável e deve ser monitorado, uma vez que, o desempenho da exponencial mista nesses casos é perdido.

4.3.4 Distribuição Gama

De acordo com Silva et al. (2013), considerando o parâmetro $\alpha=1$, a distribuição gama torna-se uma distribuição exponencial simples. A distribuição gama a dois parâmetros tem como FDP (Equação 26) (DASH et al. 2012).

$$f_x(x) = \frac{x^{\alpha-1} \exp\left(-\frac{x}{\beta}\right)}{\beta^\alpha \Gamma(\alpha)}; \text{ para } 0 < x < \infty \quad (26)$$

A $F(x)$ é a probabilidade de ocorrência de um evento menor ou igual a x , a FCP dessa distribuição pode ser escrita pela função incompleta de gama (Equação 27) (THOM, 1958).

$$F(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} \int_0^x u^{\alpha-1} \exp\left(-\frac{u}{\beta}\right) du \quad (27)$$

Sendo:

α e β - os parâmetros de forma (adimensional) e o de escala, respectivamente;

x - variável aleatória contínua;

$\Gamma(\alpha)$ - simboliza a função Gama do parâmetro α (alpha);

u - é a variável aparente utilizada para integração.

4.3.4 Estimativa dos parâmetros das funções de probabilidade

Uma vez definido os parâmetros das FCPs, é possível calcular as probabilidades associadas a quaisquer eventos de precipitação. Portanto, as estimativas dos parâmetros das 4 distribuições foram determinadas por meio do *MVS*, já que, segundo Naguettini e Pinto, (2007) a técnica *MVS* fornece bons resultados em séries longas de dados, como é o caso aqui, que se utiliza de séries diárias de precipitação pluviométrica.

4.3.5 Método da máxima verossimilhança (MVS)

O parâmetro de escala $\hat{\beta}$ da distribuição exponencial simples é calculado pela Equação 28 (WOOLHISER; ROLDÁN, 1982b).

$$\hat{\beta} = \frac{1}{\bar{x}} \quad (28)$$

Sendo \bar{x} a média amostral dos dados de precipitação (mm), a qual é calculada pela Equação 29.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^n x_i \quad (29)$$

Para a distribuição exponencial a dois parâmetros são necessárias as definições dos parâmetros de forma $\hat{\alpha}$ e de escala $\hat{\beta}$. O primeiro é calculado pela Equação 30 (JOHNSON; KOTZ, 1970).

$$\hat{\alpha} = \min(x_1, x_2, \dots, x_n); \quad (30)$$

Obtendo-se o valor mínimo da série com a Equação 30 e a média amostral dada pela Equação 29, o parâmetro de escala $\hat{\beta}$ (Equação 31) pode ser definido, como:

$$\hat{\beta} = \bar{x} - \hat{\alpha} \quad (31)$$

No caso da exponencial mista, foi também utilizado o *MVS*. No entanto, ao aplicar a forma clássica do método, é notado que os parâmetros da distribuição exponencial mista estão de forma implícita na formulação (Equação 32) (DETZEL; MINE, 2011b):

$$\ln L(x; \alpha; \beta_1; \beta_2) = \sum_{i=1}^n \ln \left\{ \frac{\alpha}{\beta_1} \exp\left(-\frac{x}{\beta_1}\right) + \frac{(1-\alpha)}{\beta_2} \exp\left(-\frac{x}{\beta_2}\right) \right\} \quad (32)$$

Assim, para estimativa dos parâmetros, é necessário encontrar os valores que maximizem a Equação 32. Entretanto, quando ocorre a tentativa de derivar a Equação 32, verifica-se que esta não possui solução analítica. Por esse motivo, é necessário recorrer ao uso de métodos numéricos baseados no princípio da *MVS*.

Os artifícios numéricos de *MVS* mais conhecidos para resolução deste tipo de problema, são as técnicas de pontuação ou o método de Newton-Raphson para resolução de equações não lineares decorrentes da diferenciação da função de verossimilhança logarítmica. No entanto, o *MVS* normalmente expõe características indesejáveis, como a inversão de grandes matrizes hessianas, a instabilidade do processo de maximização numérica e as matrizes definidas não positivas resultantes (CARVALHO et al. 2017b). Com objetivo de superar a situação indesejável mencionada, foi utilizado o algoritmo *expectation-maximization* (EM). Este algoritmo iterativo foi proposto por Dempster et al. (1977). Um fato importante na estrutura deste método, é a capacidade do mesmo em estimar os

parâmetros em amostras com dados faltantes. Posto que, no contexto de séries de precipitação, essa é uma característica que deve ser levada em consideração.

Araújo et al. (2010) explicam que no caso da distribuição gama, aplica-se a condição $\alpha > 0$ na Equação 26. Algumas considerações matemáticas são implementadas originando as Equações 33 a 37.

$$\hat{\alpha} = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \quad (33)$$

Em que:

$$A = \ln \bar{x} - x_g \quad (34)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (35)$$

$$x_g = \frac{1}{n} \sum_{i=1}^n \ln(x_i) \quad (36)$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (37)$$

Sendo:

\bar{x} - a média amostral das precipitações (mm);

x_g - a média geométrica das precipitações (mm);

x_i - o i -ésimo valor da precipitação (mm); e

n - o número de dados de precipitação.

Determinada a probabilidade de ocorrência da precipitação e os parâmetros das FCPs, é possível determinar os valores das quantidades de precipitação. Mas, para isso, é necessário transformar a variável aleatória x (precipitação), que está representada pela probabilidade de ocorrência acumulada (p) de acordo com a função teórica utilizada. Deste modo, foi aplicado o método da inversão para todas as funções de probabilidade (Equação 38).

$$F^{-1}(p) = x(F) \quad (38)$$

No caso da determinação das quantidades de precipitação pluviométrica na exponencial mista, difere das demais FCPs, uma vez que, a inversão dessa função é condicionada à média β . Essa média assume o valor β_1 ou β_2 , a escolha é feita através da

geração de um número aleatório [0,1] (U_i). U_i é comparado com o fator de probabilidade α , caso $u_i \leq \alpha$, a média escolhida é β_1 ; caso contrário, a média escolhida é β_2 .

4.3.6 Teste de aderência das FCPs

Nesse caso, foi aplicado o teste *KS* (Equação 39) para verificar a aderência das distribuições de probabilidades. Esse teste é definido como a diferença absoluta entre os dados observados de precipitação pluviométrica acumulados e as distribuições de probabilidades acumuladas. Após este procedimento, define-se o valor máximo do módulo da diferença para ser comparado com o valor crítico tabelado ao nível de significância 5% ($\alpha=0,05$).

$$D_{max} = \max |P_o(x) - P_s(x)| \quad (39)$$

Em que:

D_{max} – é o valor absoluto do teste *KS*;

$P_o(x)$ - é a precipitação pluviométrica observada;

$P_s(x)$ - é a precipitação pluviométrica estimada pela FCP.

O *KS* trabalha com duas hipóteses:

-Hipótese nula= H_0 (não existem diferenças entre as séries de precipitação pluviométricas);

-Hipótese alternativa= H_1 (existe alguma diferença entre as séries de precipitação pluviométricas).

Quando o valor de D_{max} é inferior ao valor crítico tabelado (C_α), aceita-se H_0 e se rejeita H_1 , caso contrário, rejeita-se H_0 e se aceita H_1 . Para os valores C_α , existem várias tabelas disponíveis (NAGHETTINI; PINTO, 2007; VIALI, 2008), mas, aqui se escolheu calcular C_α através da Equação 40, proposta por Stephens (1974).

$$C_\alpha = \frac{K_\alpha}{\sqrt{n+0,12+0,11\sqrt{n}}} \quad (40)$$

Sendo:

$K_\alpha = 1,358$ (para o nível de confiança 95%); e

n = é o número de elementos da amostra.

Após aplicação do teste *KS*, foi realizada a comparação entre as probabilidades observadas e esperadas através do gráfico Probabilidade-Probabilidade ou P-P plot, assim como realizado por Santos et al. (2018). Os resultados deste gráfico são eixos com a mesma dimensão de probabilidade, sendo que a FCP mais adequada é aquela que mais se aproxima da linha diagonal 1:1. Além disso, para a validação das FCPs foram calculadas as distâncias entre as probabilidades esperadas e observadas através de dois critérios de desempenho: *mean absolute error* (MAE) (Equação 41) e *Root mean square error* (RMSE) (Equação 42). Esses critérios são regularmente empregados como forma de avaliar o desempenho e a eficiência de modelos em simular o fenômeno estudado conforme descrito por Chai e Draxler (2014). Os menores valores desses critérios confirmam melhor qualidade de ajuste e menores erros.

$$MAE = \frac{\sum_{i=1}^n (P_{oi} - P_{ei})}{n} \quad (41)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_{oi} - P_{ei})^2}{n}} \quad (42)$$

Sendo:

P_o e P_e - são as probabilidades observadas e estimadas, respectivamente, no instante i ;

n - é o número total de probabilidades.

4.3.7 Validação do modelo

Para validação das precipitações estimadas com as probabilidades de Markov e FCPs, foram calculados os Erros absolutos (E_{abs}) (Equação 43) da (máxima diária, média diária, mediana diária, desvio padrão diário e total precipitado mensal), objetivando verificar a semelhança das propriedades estatísticas entre as precipitações estimadas e observadas. Vale frisar que, todos os cálculos realizados para as precipitações estimadas referem-se à média de 1000 simulações. Segundo Hansen e Ines (2005), o número suficiente de simulações é aquele que permite uma boa representação das séries de precipitação observadas.

$$E_{ABS} = (P_{obs} - P_{est}) \quad (43)$$

Em que: P_{obs} é a precipitação observada e P_{est} é precipitação estimada pelo modelo.

4.3.8 Análise de sensibilidade do modelo ao tamanho da amostra

Neste estudo foi realizada uma análise de sensibilidade das amostras de precipitação para as três *RH* da *RHTA*. Visto que, segundo Paiva e Clarke (1997), a eficiência do modelo estocástico de precipitação é afetada pelo comprimento do registro da série histórica de precipitação. Sendo assim, foram selecionadas três estações: *RH I* (82191), *RH II* (82861) e *RH III* (1753000), com séries históricas de 30 anos, estas séries foram reduzidas progressivamente até 1 ano, tendo por objetivo a definição da amostra mínima que apresente comportamento estatístico semelhante às séries históricas de 30 anos. Para cada redução, o coeficiente de desempenho de Camargo (*c*) das ocorrências e das quantidades de precipitação foram calculadas.

O índice (*c*) (Equação 44) foi proposto por Camargo e Sentelhas (1997), e este é obtido pelo produto do índice de Willmott (*d*) (Equação 45) com o coeficiente de correlação de Pearson (*r*) (Equação 46).

$$c = r \times d \quad (44)$$

$$d = 1 - \frac{\sum_{j=1}^n (E_j - o_j)^2}{\sum_{j=1}^n [(E_j - \bar{o}) + (o_j - \bar{o})]^2} \quad (45)$$

$$r = \frac{n(\sum_{j=1}^n E_j o_j) - (\sum_{j=1}^n E_j)(\sum_{j=1}^n o_j)}{\sqrt{[(n\sum_{j=1}^n (E_j)^2) - (\sum_{j=1}^n E_j)^2][(n\sum_{j=1}^n (o_j)^2) - (\sum_{j=1}^n o_j)^2]}} \quad (46)$$

Sendo:

r - coeficiente de correlação de Pearson;

d - índice de concordância de Willmott;

E_j - precipitação pluviométrica estimada no *j*-ésimo período;

O_j - precipitação pluviométrica observada na série histórica no *j*-ésimo período;

O - média da série histórica de precipitação pluviométrica;

n - número de períodos avaliados.

5. RESULTADOS

Seguindo a Figura 7, foram calculadas para todas as estações das 3 *RH* da *RHTA* as probabilidades de transição da *CM*, e os respectivos valores do critério BIC. Os resultados das estimativas dos parâmetros das 4 distribuições analisadas pelo método do *MVS*, os valores dos testes *KS* e da validação, são apresentados na sequência.

Em virtude da grande quantidade de dados gerados, foram selecionadas 12 estações pluviométricas alvos (Figura 8): *RH I* (Vigia-48006; Cipoal-250000; Colônia Santo-147011; Abaetetuba-148010), *RH II* (Fazenda Surubim-649000; Carolina-82765; Paraíso do Tocantins-1048001; Colônia-1248000; Aragarças-83368) e *RH III* (São José da Serra-1555005; Fazenda Taquari-1853000; São João D'Aliança-1447002), para melhor compreensão da metodologia empregada.

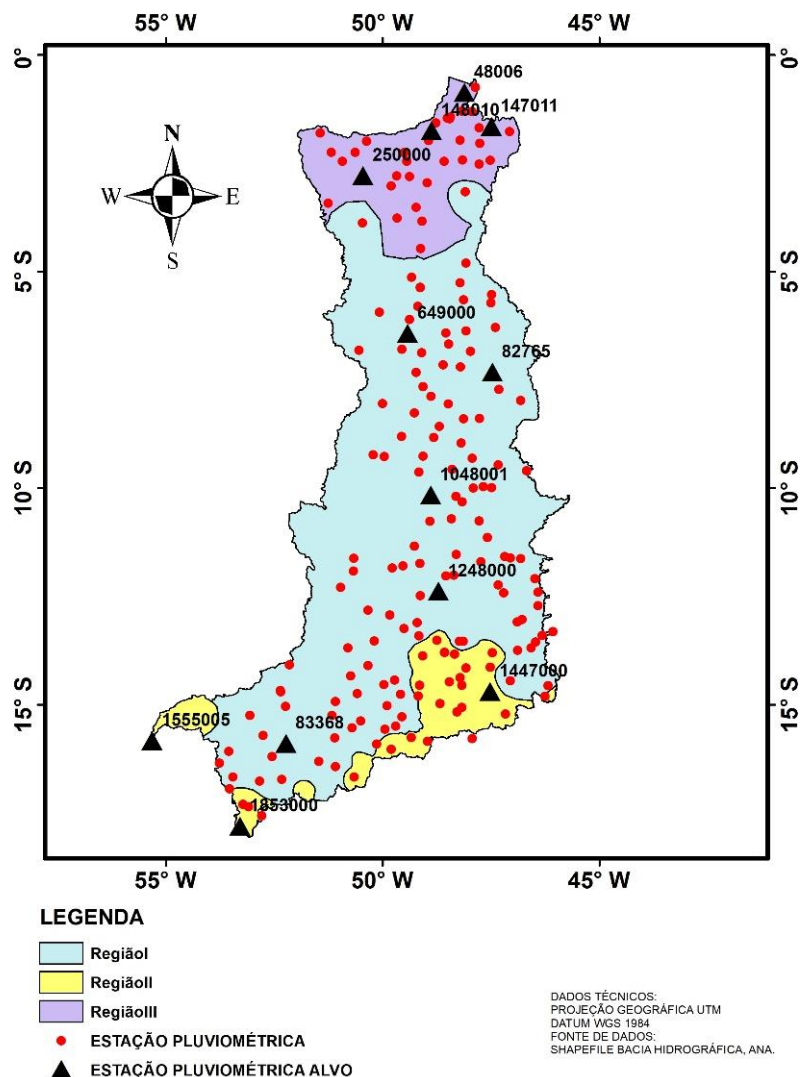


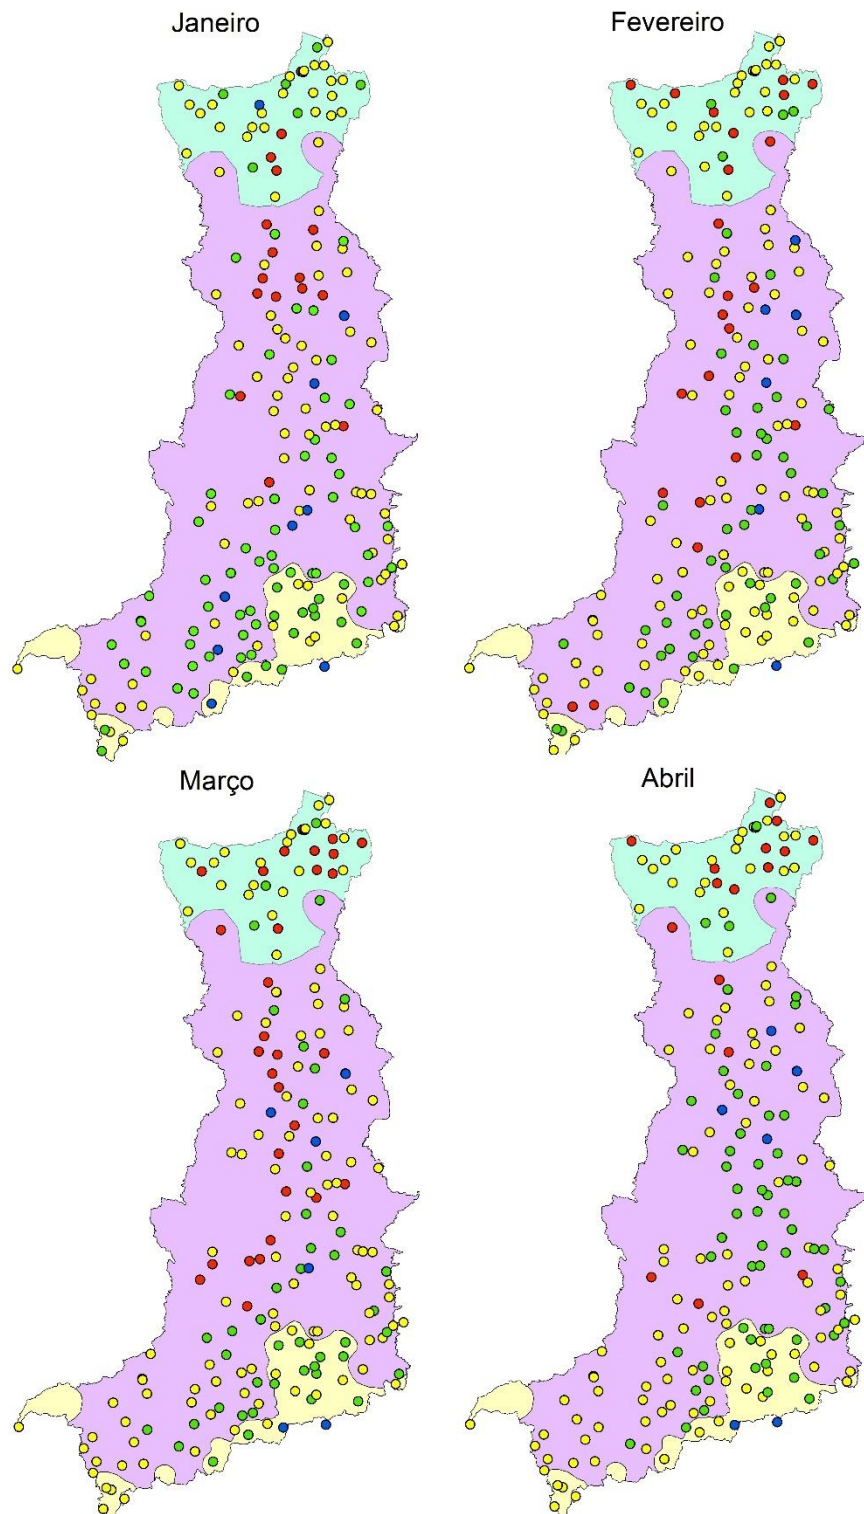
Figura 8 - Estações Pluviométricas alvos.

Os resultados da Tabela 6 mostram que os valores médios percentuais para a 1ª ordem foram de 72,53%, 56,77% e 62,50% para as *RH I, II e III*, respectivamente. Assim a *CM* de 1ª ordem é mais apropriada para simulação das ocorrências para as três *RH*. Contudo, é possível observar que a ordem da *CM* altera de acordo com a sazonalidade climática observada através dos meses do ano. Em contrapartida, em nenhuma das regiões ocorreu a indicação da *CM* de 4ª ordem. Resultados semelhantes foram encontrados por Sonnadara e Jayewardene (2014), que constataram que a 1ª ordem da *CM* era suficiente para modelar os comprimentos secos e chuvosos de precipitação no Sri Lanka. Deni et al. (2008) também afirmaram que a 1ª ordem da *CM* reproduzia com eficiência as séries chuvosas na Malásia peninsular, enquanto que para dias menos chuvosos foram mais adequadas, ordens mais altas.

Em uma avaliação realizada por Keller Filho et al. (2006) nos estados de Tocantins, Mato Grosso e Goiás, os autores sugeriram o emprego de *CM* de 3ª ordem como *CM* ótima sendo determinada através do teste *F*. Contudo, como observado na Tabela 6, a 3ª ordem foi a menos indicada pelo critério *BIC*. A não concordância dos resultados pode ser justificada pela diferença entre o tamanho do período de agregação, sendo bimestral para o estudo citado, e mensal no presente trabalho.

A maior recorrência das cadeias de ordem 0 (zero) foi no período de maio a outubro para as *RH II e III*, e nos meses de janeiro a junho para a *RH I* (Tabela 6). Essa diferença é justificada pelos sistemas atmosféricos convectivos serem mais atuantes nesse período do ano, o que concede às precipitações estas características de independência. Esses resultados corroboram com os encontrados por Falck et al. (2015). Nesse caso, os autores mostraram que as áreas da *RH II e III* apresentam baixos valores de persistência de precipitação para os meses de maio a outubro.

Em relação às informações fornecidas na Tabela 6, foi possível realizar uma análise quantitativa das ordens da *CM*. No entanto, neste contexto é importante espacializar as informações das ordens para cada estação pluviométrica da *RHTA*, visto que dessa maneira é possível visualizar onde está acontecendo a indicação de ordens mais altas (Figura 9). Vale destacar que a Figura 9 foi dividida em intervalos quadrimestrais com intuito da melhor visualização das ordens da *CM* nas estações pluviométricas.



Legenda

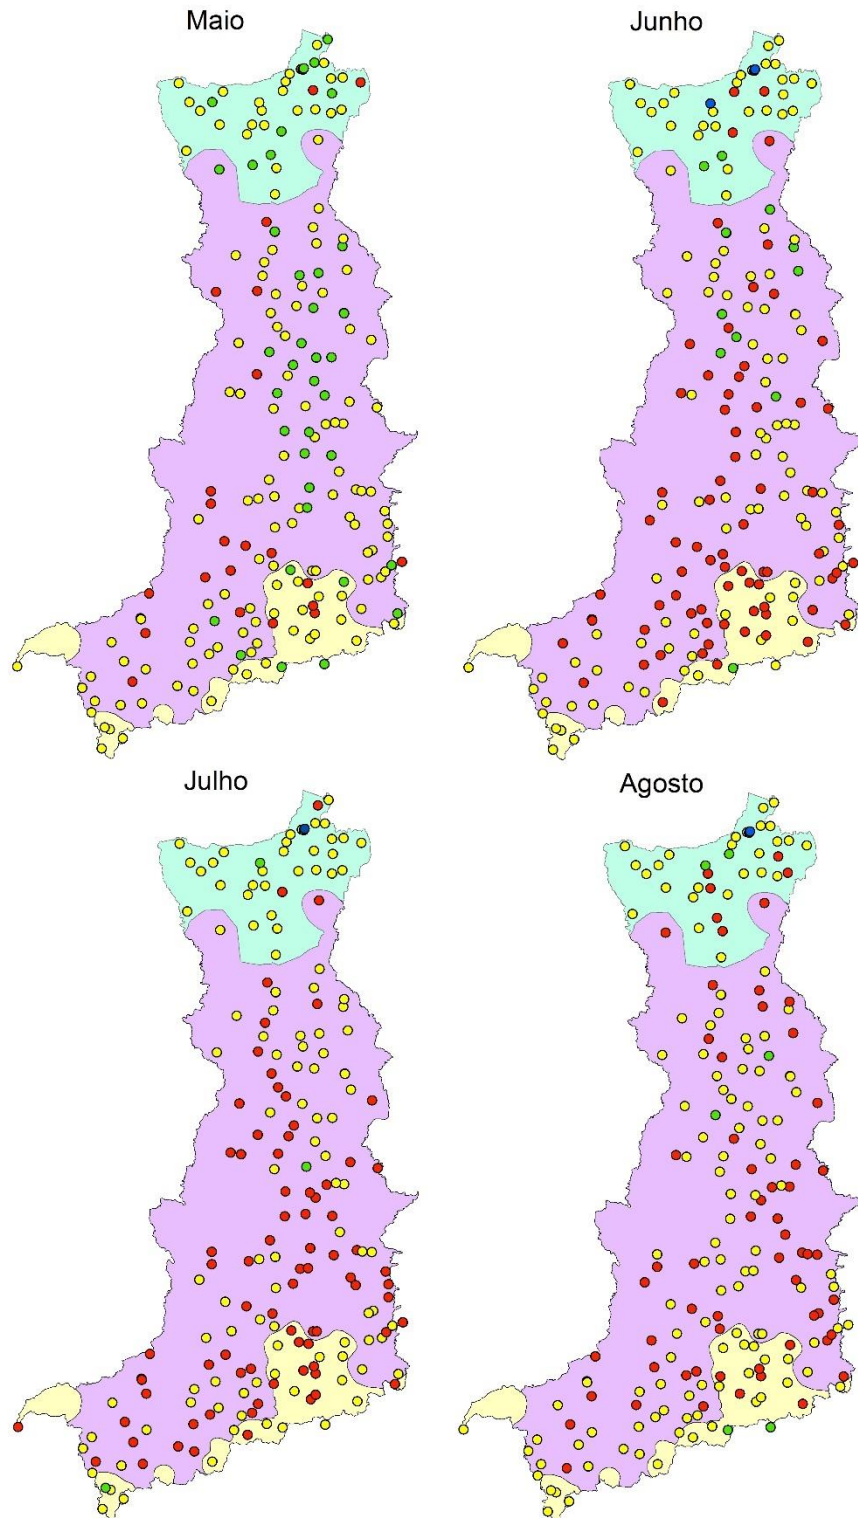
Regiões homogêneas

- Região I
- Região II
- Região III

Ordem da cadeia de Markov

- 0
- 1
- 2
- 3

(a) janeiro a abril



Legenda

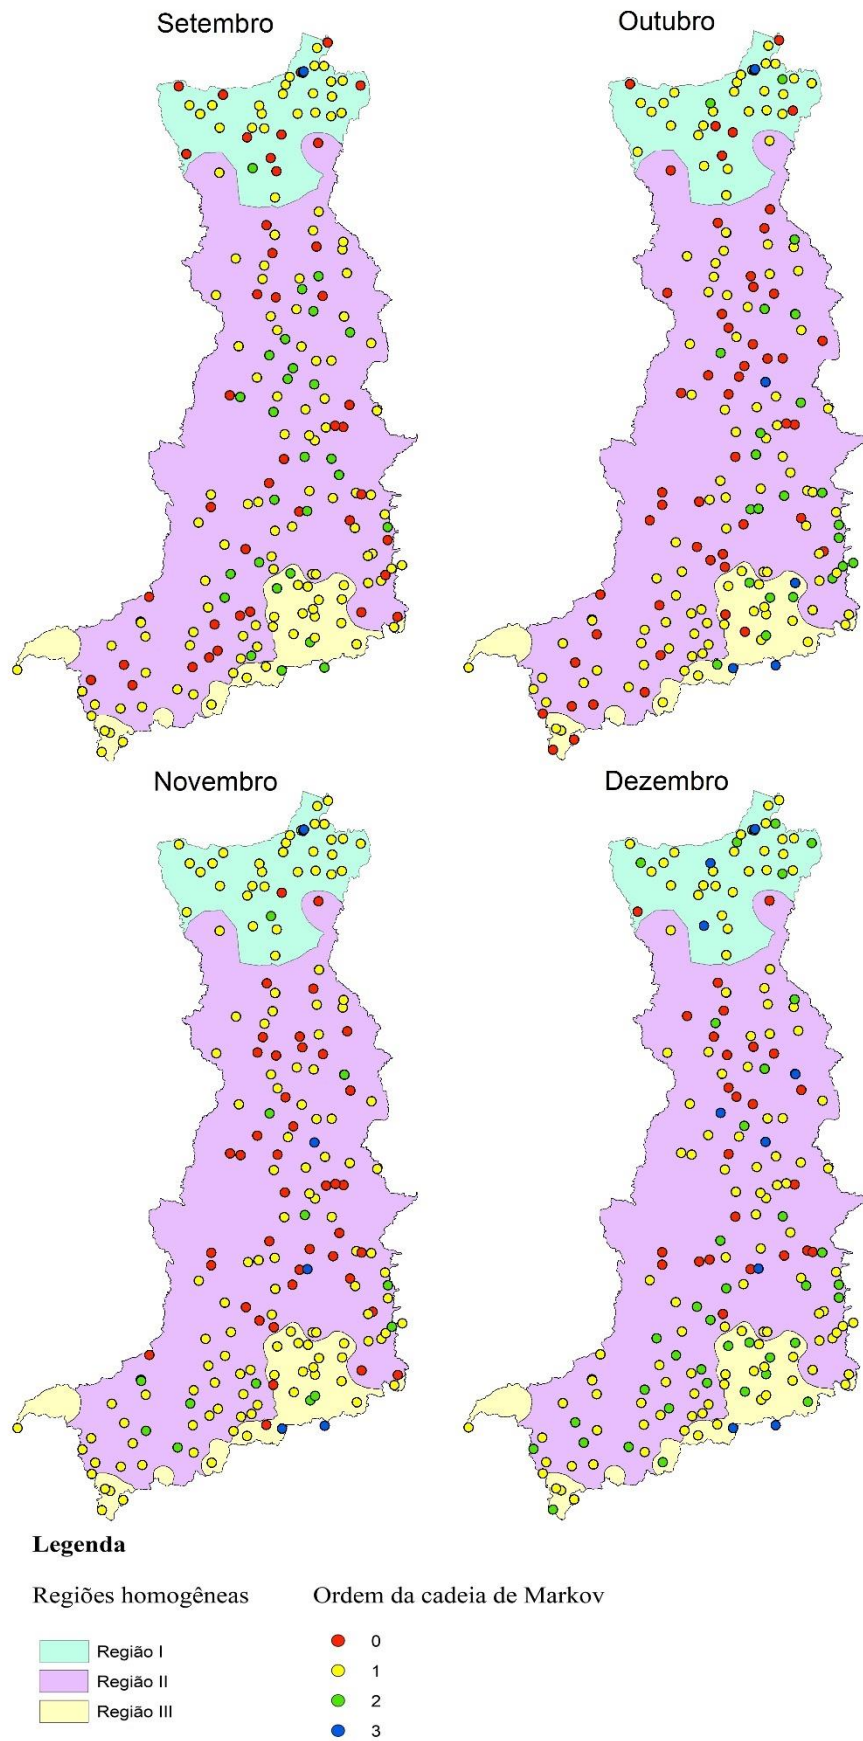
Regiões homogêneas

- Região I
- Região II
- Região III

Ordem da cadeia de Markov

- 0
- 1
- 2
- 3

(b) maio a agosto




(c) setembro a dezembro

Figura 9 - Espacialização da ordem ótima da cadeia de Markov definida pelo critério BIC.


Nas áreas leste e central da *RH I* (Figura 9), onde foram indicadas 2ª e 3ª ordem das cadeias de Markov, há uma maior dependência de dias anteriores de precipitação. Isto se justifica pelo fato dessas áreas apresentarem os maiores eventos com longa duração de seca, conforme demonstrou o estudo de Santos et al. (2017b), o qual reforça que estes eventos estão relacionados a variabilidade climática dos oceanos Atlântico (Gradiente do Atlântico) e Pacífico (ENOS). Chen et al. (2014), em Platô de Loess, na China, também constataram que em áreas com longos períodos de seca os modelos utilizando as *CM* de 2ª e 3ª ordem são mais apropriados para representar a ocorrência de precipitação.

5.1.2 Distribuição temporal da Probabilidade de Ocorrência

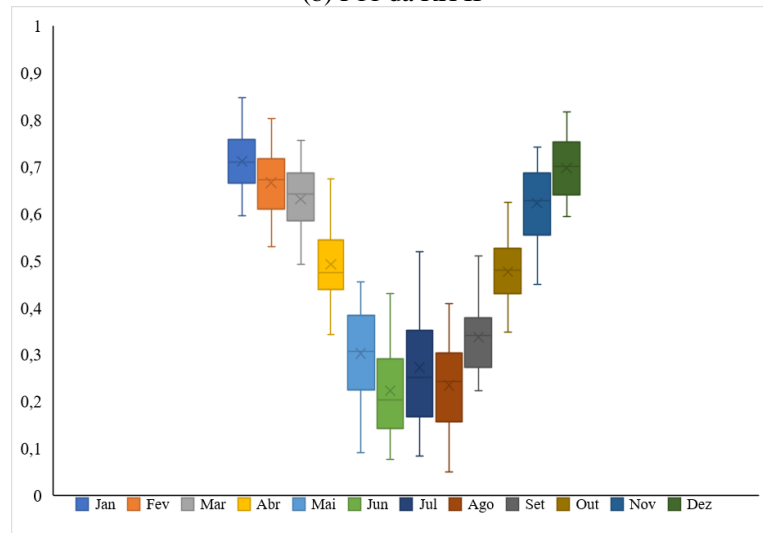
Como descrito no capítulo anterior, o critério de otimização *BIC* indicou a *CM* de 1ª ordem, como adequada para modelagem das ocorrências de precipitação pluviométrica nas três *RH* da *RHTA*, bem com em diversos estudos (Li et al., 2014; Sanusi et al., 2015; Back e Miguel, 2017; Carvalho et al., 2017). Portanto, neste trabalho assume-se a condição de que o evento atual depende do evento ocorrido no dia anterior para os estados seco e chuvoso. Desse modo, foram gerados Box-Plots das probabilidades P_{11} e P_{01} para as *RH* (Figuras 10 e 11), os valores destes parâmetros foram utilizados com o objetivo de visualizar a dinâmica dos períodos chuvosos e secos em cada *RH*.



(a) P11 da RH I




(b) P11 da RH II



(c) P11 da RH III

Figura 10 - Box-Plots da probabilidade de um dia chuvoso antecedido por outro também chuvoso (P_{11}).



(a) P01 da RH I



(b) P_{01} da $RH II$ (c) P_{01} da $RH III$

Figura 11 - Box-Plots da probabilidade de dia seco antecedido por um dia chuvoso (P_{01}).

Nas Figuras 10 e 11, observa-se que a probabilidade P_{01} apresenta menor dispersão e assimetria que a probabilidade P_{11} . Além disso, foi constatado na Figura 10, que a menor variabilidade dos dados ocorreu no mês de fevereiro na $RH II$, enquanto, nas $RH I$ e III aconteceram em janeiro e março. Nos meses de janeiro a abril, ocorrem as maiores contribuições de precipitação nas RH . Segundo Gonçalves et al. (2018), este padrão está associado a sistemas atmosféricos em grande escala como o deslocamento norte-sul da zona de convergência intertropical (ZCIT).

Na $RH I$, o período de setembro a novembro (Figura 11 a), é caracterizado como a estação menos chuvosa, e outubro é o mês com a maior probabilidade de não ocorrência de chuvas. Segundo Amanajás e Braga (2012), neste mesmo período a ZCIT está situada mais ao norte e combinada aos movimentos ascendentes localizados ao norte do equador geográfico,

ela contribui para intensificar a diminuição de precipitação sobre o leste da Amazônia, Centro Oeste e Nordeste do Brasil.

Já no mês de julho são encontradas as maiores probabilidades de períodos secos para as *RH II* e *III*, com aumento dos regimes pluviométricos iniciando apenas em setembro (Figura 11 b e c), diferente da *RH I* (Figura 11 a). Isso corrobora com o estudo de Marengo e Nobre (2009), onde os autores destacam que antecipação do período seco nas *RH II* e *III* em relação a *RH I* estão associados a posição mais a sul da Zona de Convergência do Oceano Atlântico Sul (ZCAS).

A presença de alguns *outliers* nas probabilidades de ocorrência foi constatada nas probabilidades de chover (Figura 10) e de não chover (Figura 11), isso acontece devido à influência dos sistemas atmosféricos em algumas estações. No quadrimestre chuvoso (janeiro a abril) (Figura 10), os principais eventos extremos ocorreram nas estações das *RH I* e *II*, salvo a *RH III*, em que não apresentou nenhum outlier. Loureiro et al. (2015) mostraram que os fenômenos meteorológicos ENOS (El Niño Oscilação Sul) e Dipolo Atlântico eram mais atuantes na *RH I* e em algumas áreas da *RH II*. Para a probabilidade de não chover (Figura 11), os eventos extremos aconteceram no quadrimestre maio a agosto nas *RH II* e *III*, e no quadrimestre setembro a dezembro na *RH I*.

De um modo geral, as probabilidades de chover P_{11} e de não chover P_{01} foram apresentadas para todas as *RH*, no entanto, é necessário retratar as características mais locais da dependência da precipitação. Para isso, foram expostas na Tabela 7, as probabilidades de ocorrência de chuva encontradas para 12 estações alvos. Nesse caso, as probabilidades de transição trazem intrinsecamente, informações relativas aos períodos secos (em vermelho) e chuvosos (em azul) de cada estação. Além, de evidenciar a magnitude as quais as estações estão sendo submetidas. Esta constatação é notada ao se comparar os valores das probabilidades das estações nas *RH*, contudo, em uma mesma *RH*, os comportamentos das estações são diferentes, essa variabilidade é atribuída às características locais de precipitação.

Tabela 7- Valores das probabilidades de ocorrência e não ocorrência de precipitação para as estações alvos.

RH I									
Código	48006		147011		250000		148010		
Meses	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁	
Jan	0,3866	0,7652	0,4107	0,8115	0,5516	0,7604	0,5112	0,7273	
Fev	0,6222	0,8418	0,6748	0,8422	0,7222	0,8519	0,6264	0,7947	
Mar	0,6564	0,8172	0,6964	0,8700	0,7343	0,8664	0,6319	0,8057	
Abr	0,7623	0,8442	0,7018	0,8626	0,6897	0,8674	0,6352	0,8209	
Mai	0,7115	0,8109	0,5976	0,8140	0,4983	0,7521	0,6132	0,7547	
Jun	0,6515	0,7524	0,5086	0,6427	0,3333	0,5370	0,4392	0,6085	
Jul	0,6148	0,6749	0,4429	0,6031	0,2441	0,4106	0,3666	0,6059	
Ago	0,3699	0,5833	0,3466	0,5285	0,1774	0,3459	0,3052	0,4844	
Set	0,1598	0,3182	0,2333	0,4689	0,2040	0,3125	0,2912	0,4263	
Out	0,0909	0,3133	0,1810	0,4000	0,2090	0,3069	0,2277	0,3448	
Nov	0,1005	0,2561	0,1741	0,3691	0,2111	0,4110	0,2103	0,3723	
Dez	0,1593	0,5654	0,2124	0,5976	0,3495	0,6076	0,3206	0,5640	

RH II										
Código	649000		82765		1048001		1248001		83368	
Meses	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁
Jan	0,4396	0,4984	0,6024	0,7137	0,5107	0,6133	0,4008	0,5505	0,5378	0,7415
Fev	0,4721	0,5486	0,5282	0,7562	0,544	0,6672	0,3491	0,5525	0,4699	0,671
Mar	0,5559	0,6067	0,5982	0,732	0,5889	0,582	0,3241	0,4471	0,4018	0,6247
Abr	0,4162	0,5802	0,3783	0,636	0,3152	0,5354	0,1765	0,3152	0,1882	0,4754
Mai	0,2769	0,3899	0,1646	0,4906	0,0969	0,3655	0,0363	0,3043	0,0596	0,2727
Jun	0,0946	0,2162	0,0476	0,2656	0,015	0,1176	0,0113	0,2	0,0193	0,35
Jul	0,044	0,2162	0,0204	0,2857	0,0122	0,1333	0,0087	0,25	0,0172	0,2
Ago	0,0662	0,0638	0,0313	0,1111	0,0226	0,3611	0,0043	0,5	0,0166	0,3333
Set	0,1295	0,2549	0,1236	0,3395	0,1155	0,3557	0,0564	0,1935	0,1212	0,2551
Out	0,2077	0,311	0,2835	0,4451	0,3192	0,4205	0,2579	0,287	0,2829	0,3364
Nov	0,2809	0,246	0,3559	0,5012	0,4104	0,471	0,3112	0,3577	0,4507	0,5501
Dez	0,3433	0,3496	0,5064	0,6205	0,5307	0,6081	0,378	0,5381	0,5096	0,7236

RH III									
Código	1555005		1853000		1447002				
Meses	P ₀₁	P ₁₁	P ₀₁	P ₁₁	P ₀₁	P ₁₁			
Jan	0,4593	0,6926	0,5494	0,6945	0,3645	0,7147			
Fev	0,5493	0,6695	0,5477	0,6781	0,3399	0,6720			
Mar	0,4579	0,6379	0,4826	0,6436	0,2732	0,7025			
Abr	0,3013	0,5629	0,2703	0,5061	0,1996	0,4379			
Mai	0,1529	0,4545	0,1283	0,3036	0,0660	0,3167			
Jun	0,0571	0,2759	0,0547	0,2857	0,0219	0,3333			
Jul	0,0212	0,1111	0,0338	0,2581	0,0181	0,3333			
Ago	0,0520	0,2759	0,0497	0,3125	0,0229	0,2105			
Set	0,1576	0,4270	0,1673	0,3083	0,1007	0,3373			
Out	0,2353	0,4409	0,3074	0,3840	0,3219	0,5216			
Nov	0,3768	0,5714	0,4203	0,5511	0,4007	0,6777			
Dez	0,4591	0,6955	0,5000	0,6809	0,4179	0,7083			

Nos estudos realizados por Menezes et al. (2015) e Morais et al. (2005), os autores observaram que dezembro é o mês em que ocorre a estação chuvosa na maioria das áreas do Estado do Pará. Entretanto, na porção ao sul do Pará, o início da estação chuvosa é antecipado para o mês de outubro. Já em algumas localidades, como no sudoeste, sudeste e uma parte do centro-sul, o início da estação chuvosa é em novembro.

Em um estudo realizado no estado do Mato Grosso, verificou-se que os meses de junho, julho e agosto são considerados os menos chuvosos na porção leste e nordeste do estado, com pequenos epicentros distribuídos no bioma Cerrado, isso acontece devido ao enfraquecimento da massa de ar Equatorial Continental e a maior ocorrência da massa de ar Polar que se inicia no mês de abril. Já no mês de setembro, ocorre o processo contrário, o que favorece o aumento dos índices pluviométricos para a região (MARCUIZZO et al. 2011).

Ainda conforme a Tabela 7, a estação (1555005) situada na *RH III* apresenta período menos chuvosos nos meses de maio a outubro e o período mais chuvoso entre os meses de novembro a abril. No que se refere à estação (1248001) na *RH II*, o período mais acentuado de seca vai de abril a setembro; e entre outubro e março ocorre o período mais chuvoso. No caso da estação (48006) na *RH I*, o período seco vai de agosto a janeiro, enquanto o período chuvoso se inicia em fevereiro, essas características diferenciadas estão relacionadas com a maior interferência das brisas marítimas e das linhas de instabilidade provocadas pela maior proximidade com o Oceano Atlântico (GERMANO et al. 2017).

Para evidenciar as diferenças citadas entre as probabilidades de chover após um dia seco (P_{01}) e de chover após um dia úmido (P_{11}), foram elaborados três gráficos comparativos (Figura 12). Ao analisá-los, os comportamentos climáticos de cada localidade ficam evidentes.



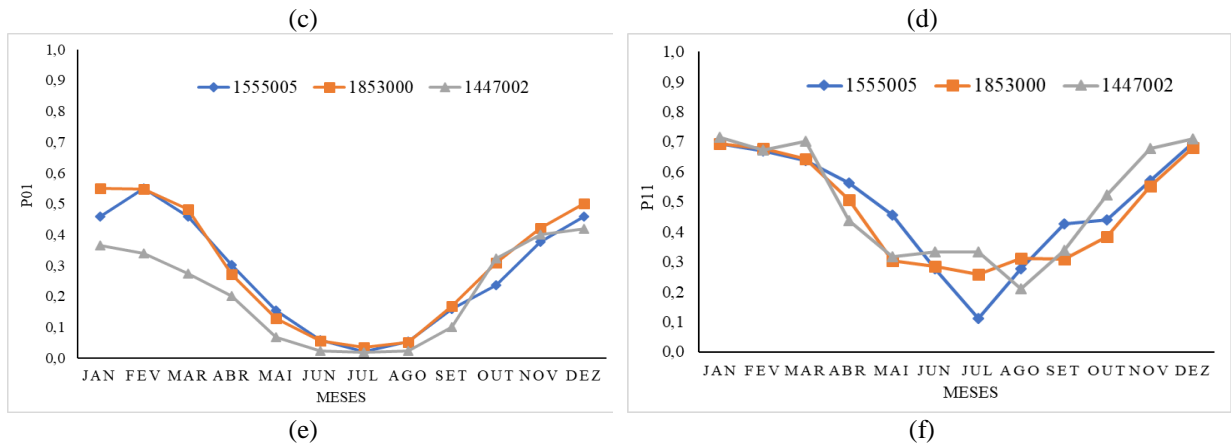


Figura 12 - Probabilidades de transição de chuva após um dia seco (P_{10}) e chuva após um dia chuvoso (P_{11}); (a) e (b) – *RH I*; (c) e (d) – *RH II*; (e) e (f) – *RH III*.

Na maioria das estações (Figura 12), principalmente as que estão localizadas nas *RH II* e *III*, as probabilidades P_{01} indicaram baixa probabilidade de transição no período menos chuvosos (junho a agosto), ou seja, valores mais próximos de zero. Essa transição se apresentou maior nas estações localizadas na *RH I*. Isso pode ser explicado devido ao tipo de clima Am e Af predominante na foz da *RHTA*.

5.2 DETERMINAÇÕES DA QUANTIDADE DE PRECIPITAÇÃO DIÁRIA

Na segunda etapa do modelo, são determinadas as quantidades de precipitação diária. Primeiramente, foram geradas as FCPs (Exponencial simples, exponencial a dois parâmetros, Exponencial mista e Gama) com os dados diários de precipitação para cada uma das estações selecionadas na (Apêndice A). Para estimativa dos parâmetros foram utilizadas as Equações de 28 a 37.

Com os parâmetros estimados, foi utilizada a Equação 40 para calcular os valores do teste *KS* com o nível de significância ($\alpha=0,05$). Os resultados do número de aderências das 196 estações podem ser vistos na Tabela 8. Conforme descrito no modelo, as análises foram divididas em períodos mensais.

Tabela 8– Os valores do número de aceites do teste *KS* ao nível de significância ($\alpha=0,05$).

	RH I	RH II	RH III	RH I	RH II	RH III
FCPs	Valores absolutos			Valores percentuais (%)		
E1 - Exponencial simples	0	15	3	0	0,961	0,892
E2 - Exponencial de dois parâmetros	155	845	177	33,991	54,166	52,678
E3 - Exponencial mista	397	1405	280	87,061	90,064	83,333
G - Gama	366	1311	270	80,263	84,038	80,357
Total	456	1560	336			

Na verificação do ajuste dos modelos probabilísticos às séries de precipitação diária (Tabela 8), é possível constatar que a distribuição exponencial mista e a gama foram as mais adequadas para as três *RH*, com média de 86,81% e 81,55% de aceitação da hipótese H_0 , respectivamente. Contudo, os resultados apontam uma melhoria no uso da exponencial mista. Liu et al. (2011) em um estudo para 10 estações pluviométricas na bacia hidrográfica do rio Yishu, China, também constataram que a exponencial mista reproduziu com melhor eficiência as precipitações, quando comparadas à distribuição gama.

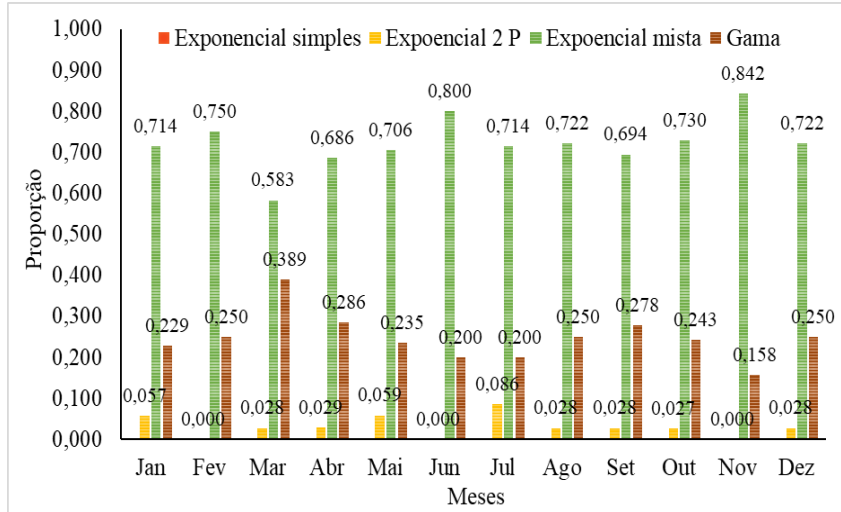
Em relação à exponencial a dois parâmetros e a simples (Tabela 8), essas foram mais eficientes na representação das precipitações das *RH II* e *III*, em vista disso, fica evidente que para modelagem das precipitações na *RH I* é mais indicado o uso distribuições com maior flexibilidade, como é o caso da exponencial mista. De acordo com Detzel e Mine (2011a), as duas distribuições comentadas se mostram bastante similares, uma vez que, apenas em meses em que as chuvas foram mais intensas essa diferença é notada.

Ainda na Tabela 8, existem alguns casos que as FCPs não apresentaram aderências aos dados observados, neste contexto, pode-se citar a estação (148009) situada na *RH I*, que apresentou aderências em apenas 3 (valores em vermelho) dos 12 períodos mensais analisados (Tabela 9), essa foi a estação pluviométrica com o menor número de aderências da *RHTA*. Isso pode decorrer por influência de sistemas meteorológicos regionais e locais que interferem de maneira significativa nas precipitações pluviométricas. Souza et al. (2015), mencionam em seu estudo que essa região sofre fortes influências das oscilações atmosféricas de múltiplas escalas temporais entre 2 a 190 meses.


Tabela 9– Estação pluviometrica com menor número de aderências da RHTA.

Cód.	Meses	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Agos	Set	Out	Nov	Dez
148009	E1	0,200	0,269	0,270	0,269	0,264	0,253	0,213	0,206	0,201	0,185	0,186	0,218
	E2	0,176	0,165	0,193	0,175	0,189	0,170	0,108	0,114	0,111	0,135	0,132	0,199
	E3	0,153	0,087	0,082	0,092	0,080	0,101	0,093	0,108	0,056	0,096	0,068	0,065
	G	0,088	0,146	0,153	0,151	0,157	0,167	0,112	0,116	0,109	0,123	0,120	0,154
	Tab.	0,056	0,054	0,049	0,051	0,054	0,062	0,066	0,076	0,083	0,083	0,084	0,065

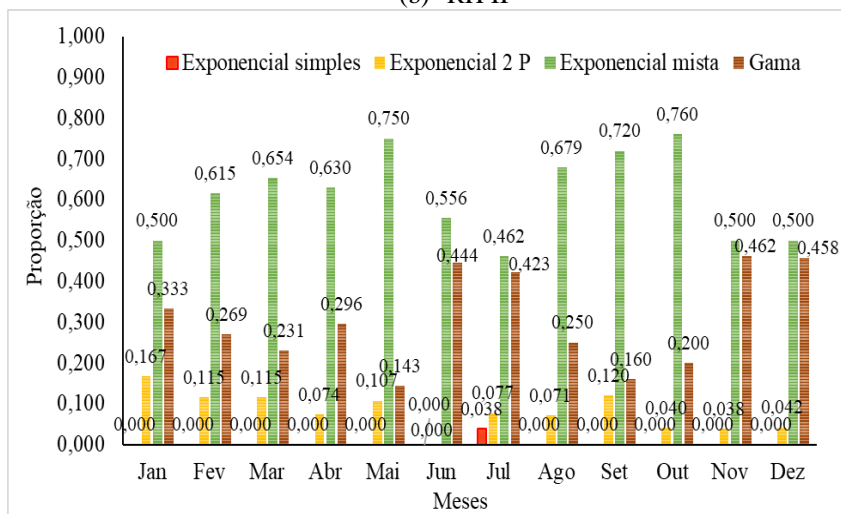
Como mencionado, a hipótese nula (H_0) no teste *KS*, foi aceita para a maioria dos casos nas distribuições exponencial mista e gama. Todavia, em alguns casos, as distâncias máximas calculadas são mais afastadas do que outras, quando comparados ao valor crítico (K_α). Assim, para levar em consideração este aspecto, foi elaborada a Figura 13, com o propósito de verificar a qualidade destas aderências.



(a) RHI



(b) RH II



(c) RH III

Figura 13 - Proporção de melhor aderência de cada distribuição por mês no teste KS; a) RH I-Estação menos chuvosa (maio a outubro) e Estação mais chuvosa (novembro a abril), b) RH II-Estação menos chuvosa (abril a setembro) e Estação mais chuvosa (outubro a março), c) RH III-Estação menos chuvosa (junho a novembro) e Estação mais chuvosa (dezembro a maio).

Ao contrário do mostrado na Tabela 8, a Figura 13 comprova a superioridade das melhores aderências proporcionadas pela distribuição exponencial mista, isto é justificado devido o maior grau de flexibilidade oferecido pelas médias β_1 e β_2 . Logo, indica-se para as três *RH*, a Exponencial mista, como a distribuição mais adequada para a simulação das precipitações diárias. No entanto, é percebido que o desempenho desta distribuição é afetada pelas variações sazonais de cada *RH*. Aba et al. (2014), Li et al. (2013), Moreno-Pérez et al. (2014) também indicam o uso da exponencial mista para modelagem da precipitação pluviométrica.

Na *RH II* (Figura 13 b) a distribuição exponencial mista mostrou-se em média mais adequada para representar a estação mais chuvosa (71,6%), e para o período menos chuvoso com média de 67,21%. Enquanto para as *RH III* (Figura 16 c) e *RH I* (Figura 16 a), ocorre uma inversão do desempenho da exponencial mista, visto que, as aderências foram em média melhor na estação menos chuvosa, com média de 63,25% e 73,75%, respectivamente, enquanto para estação mais chuvosa, com valores médios de 58,82% para a *RH II* e 70,65% para *RH I*. Os estudos realizados por Kist e Virgens (2015), no estado do Paraná, mostraram resultados similares, de acordo com os autores, a exponencial mista foi melhor em 74% na época de estiagem e 59% na época mais úmida.

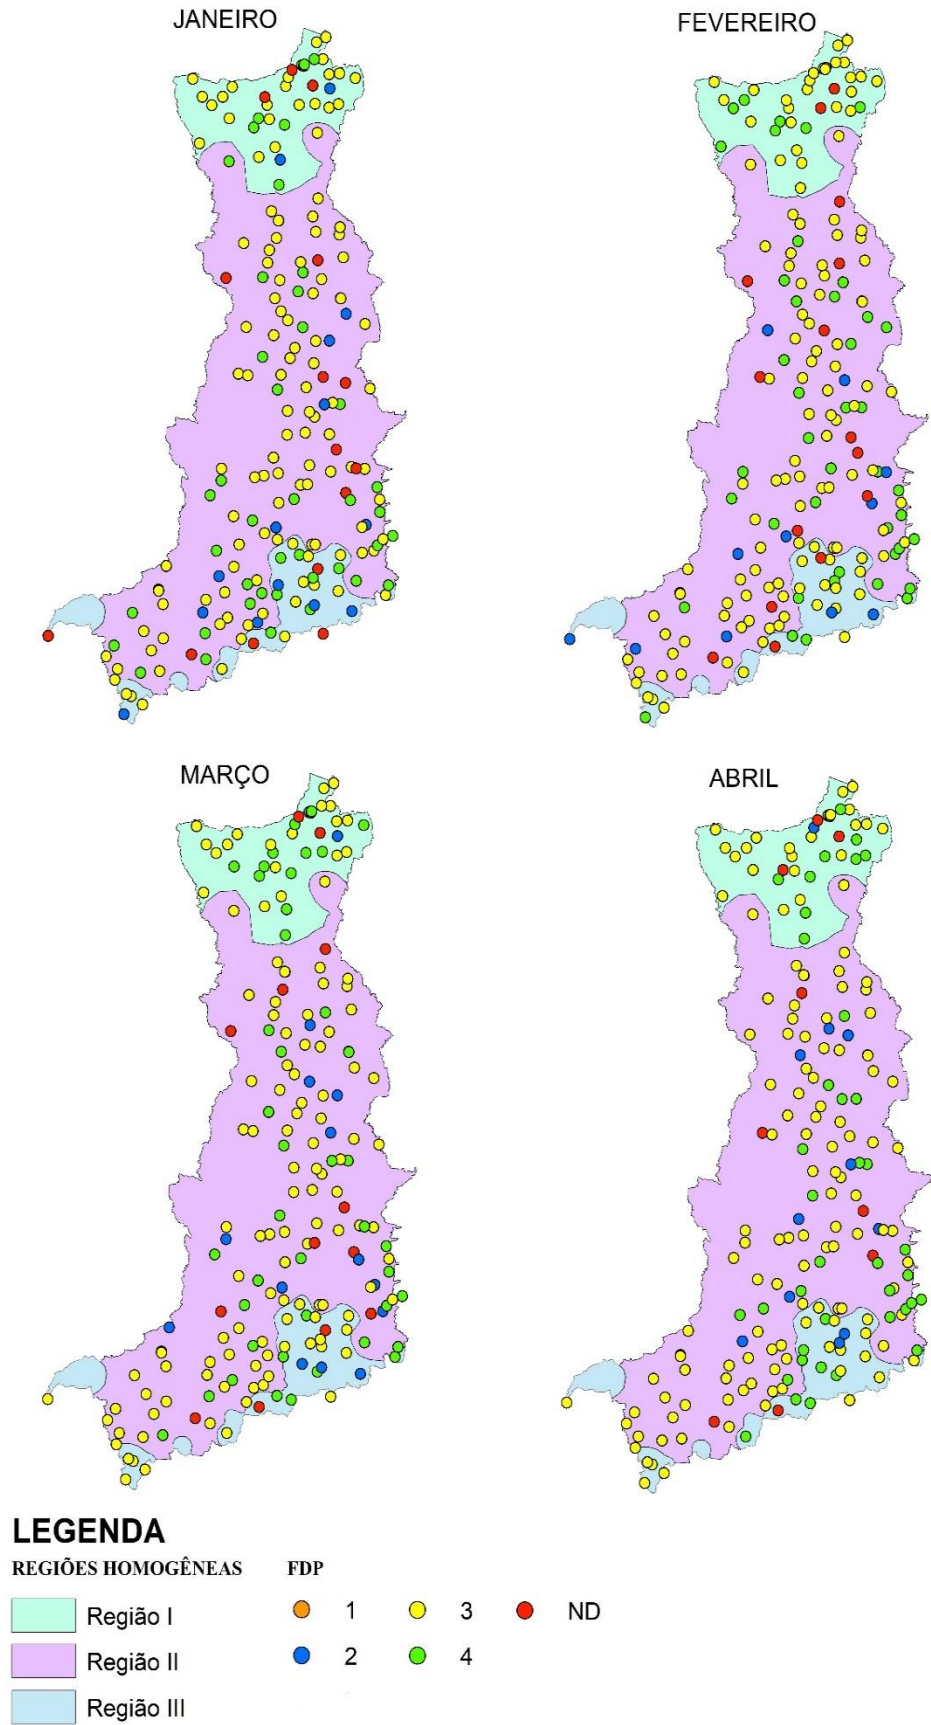
Ainda em relação a exponencial mista, é importante notar o caso particular do mês de julho para as *RH II* e *III*. Neste caso, observou-se que o desempenho da distribuição gama quase se equiparou a da exponencial mista (Figura 13 b e c), isso pode ter acontecido devido à particularidade da função gama ($\alpha=1$), conseqüentemente, esta função aumenta sua eficiência em séries de alto valor de assimetria, que é o comportamento característico da precipitação para meses menos chuvosos.

Wan et al. (2005) também comprovaram a superioridade da distribuição exponencial mista para modelagem das precipitações de 657 estações no Canadá, os resultados indicaram que a distribuição exponencial mista é superior no geral, especialmente durante os meses mais quentes, enquanto a distribuição gama é adequada para os meses de inverno.

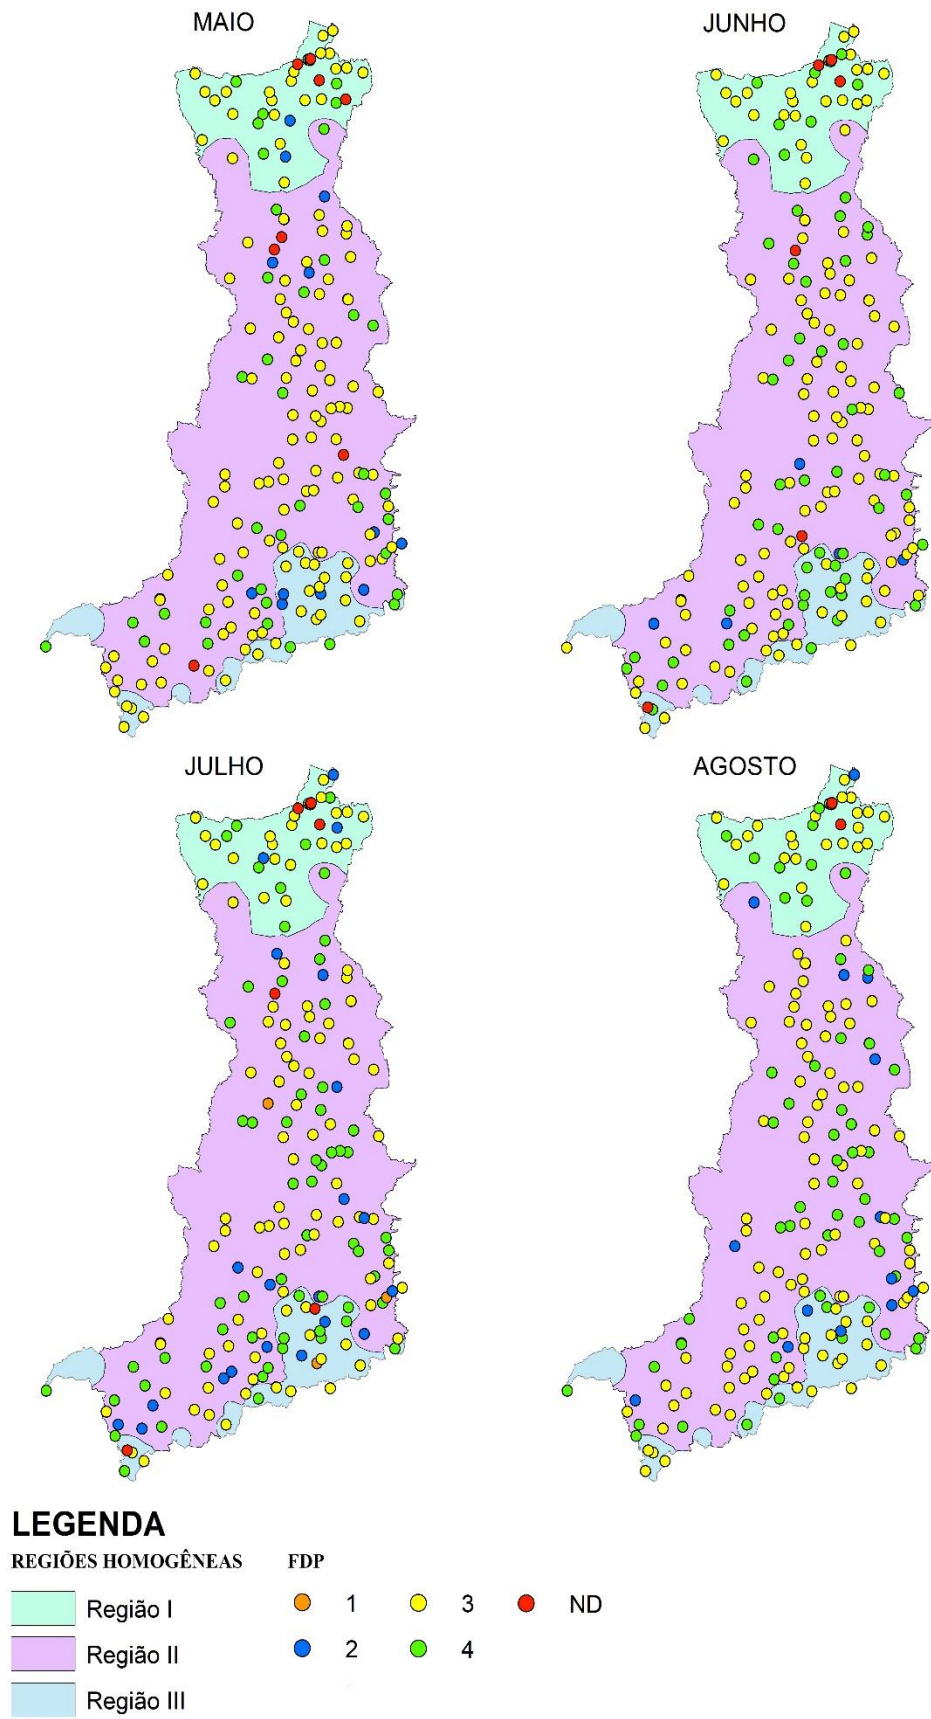
No caso da distribuição exponencial simples não apresentou um bom ajuste, visto que, o número de aceites da H_0 foi praticamente inexistente para todas as *RH* (Figura 13), ressalva nos meses de julho com recorrência de 0,016% e 0,038% nas *RH II* e *III*, essa particularidade é explicada devido à dificuldade de estimar os parâmetros das distribuições nas séries com muitos zeros nas séries históricas. Portanto, nesses casos, não foram possíveis as estimativas dos parâmetros das demais distribuições. Os resultados descritos acima, corroboram para os estudos de Blain et al. (2007) e Silva et al. (2013). O bom desempenho da função exponencial

simples pode ser explicado pela maior frequência observada nas classes iniciais, decrescendo suavemente, em forma de “J” invertido (LYRA et al. 2006).

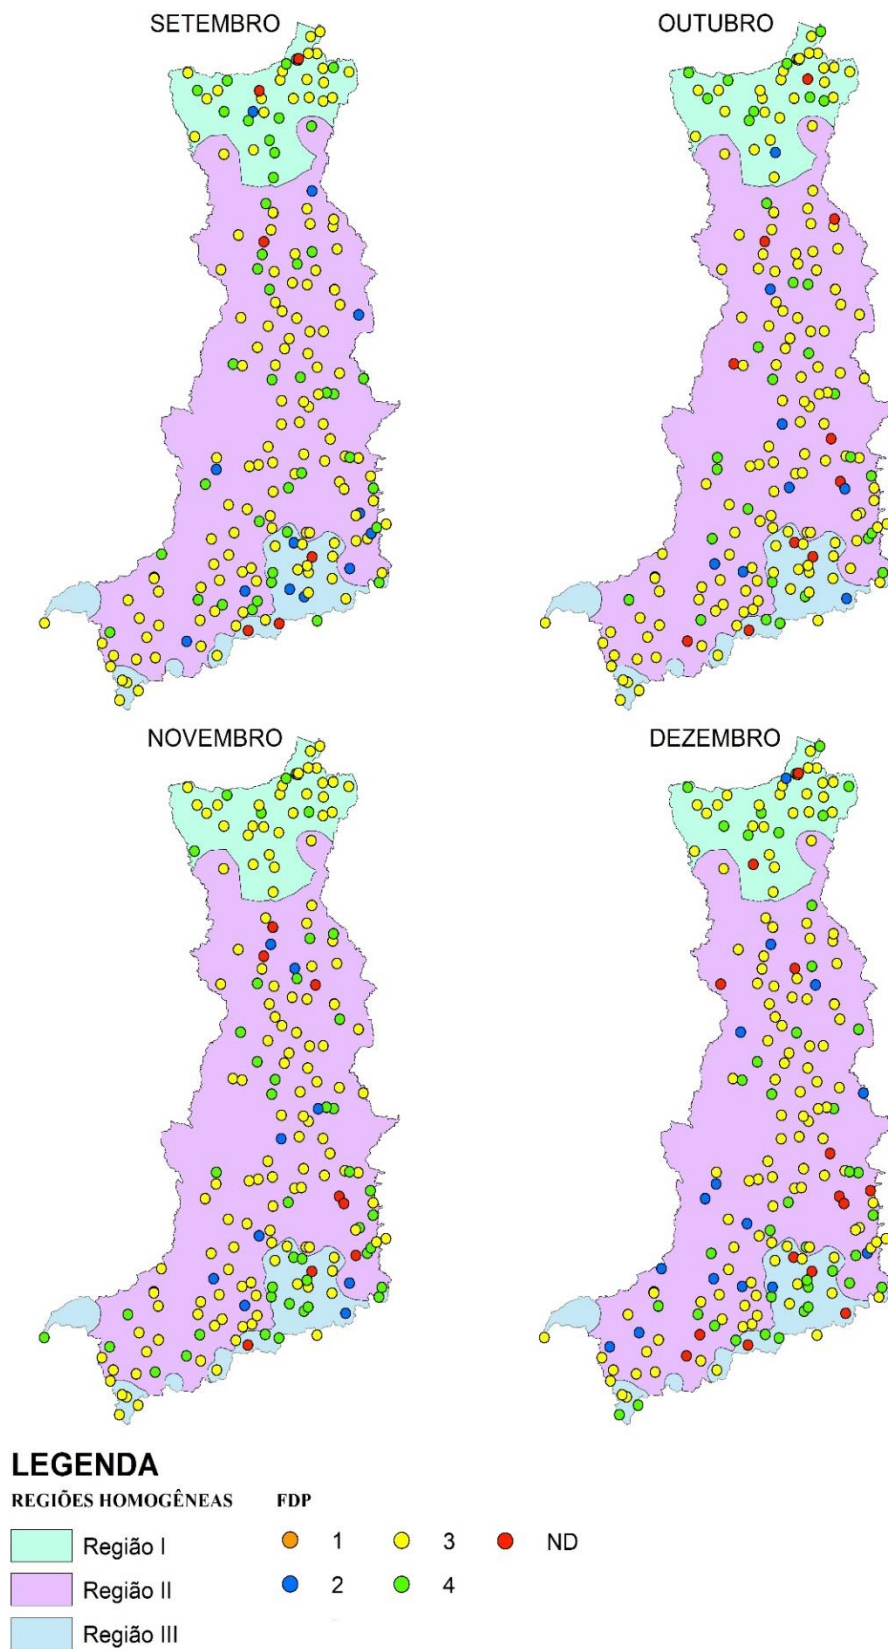
Com os resultados obtidos no teste *KS* (Figura 13), foram especializados os postos pluviométricos com as FCPs que obtiveram melhores ajustes (Figura 14). Algumas pesquisas (Papalexiou e Koutsoyiannis, 2012 e 2013) apontam que a modelagem de precipitação varia conforme o clima característico do local, tornando, pouco provável, que apenas uma FCP seja capaz de representar as precipitações. Pois cada FCP apresenta limitações em seu espaço paramétrico quando associada às características de precipitação.



(a) janeiro a abril



(b) maio a agosto



(c) setembro a dezembro

Figura 14 – Função Cumulativa de probabilidades mais adequada, ao nível de significância de 5%, segundo o teste *KS*.

Obs: FCPs (1=Exponencial simples; 2= Exponencial a dois parâmetros; 3= Exponencial mista; 4=Gama; ND=Nenhuma das FCPs obtiveram aderência).

Na Figura 14, percebe-se que a distribuição exponencial mista teve desempenho satisfatório em quase todas as áreas da *RHTA*. Entretanto, como mencionado no (Tópico 4.3.3), existem alguns casos particulares em que a exponencial mista se reduz a uma exponencial simples ($\alpha=1$ ou $\alpha=0$, $\beta_1=\beta_2$), este processo é conhecido como degeneração.

Assim, no presente estudo, foram encontrados os maiores casos de degenerações em áreas localizadas no sudeste (1246001, 1246000, 1147003), sudoeste (1150000, 1250001, 1150001), nordeste (1346005 e 1446000) e noroeste (849002 e 949000) da *RH II* (Figura 15). Percebe-se que nestas áreas ocorreu a substituição do uso da exponencial mista para gama ou exponencial a dois parâmetros (Figura 14). Desta forma, a exponencial a dois parâmetros mostrou bom desempenho para estas áreas. No entanto, nos casos em que a gama se saiu melhor, foi devido a sua maior capacidade da distribuição de representar as intensidades de precipitação (DETZEL; MINE, 2011a).

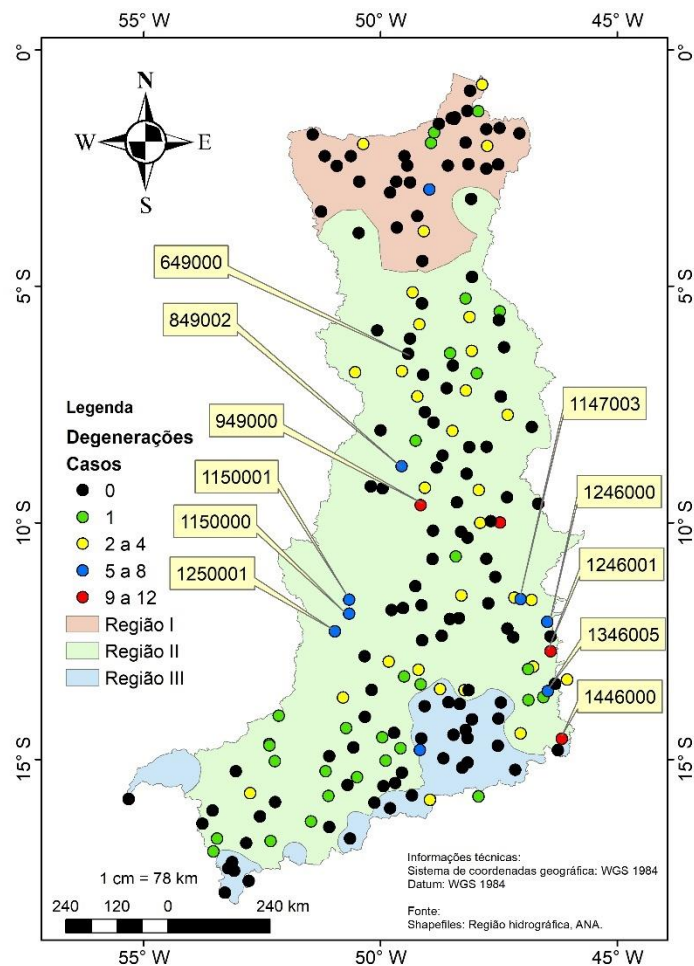


Figura 15 – Quantidade de casos de degenerações da distribuição exponencial mista.

Segundo HAIDAR et al. (2013), as áreas localizadas no nordeste e sudeste da *RH II*, estão localizadas no ecótono (Cerrado-Caatinga), e esses locais apresentam florestas estacionais decíduais, as quais estão submetidas a menores índices de precipitação anual 1200 a 1400 mm.ano⁻¹ e apresentam estiagens que podem atingir até sete meses, já nas áreas do noroeste e sudoeste, são caracterizadas por áreas de ecótono (Amazônia-Cerrado), com florestas do tipo estacional semidecidual/floresta ombrófila, onde os níveis de precipitação chegam a 2100 mm.ano⁻¹. Entretanto, a estação (649000) não apresentou nenhuma degeneração (Figura 15), e essa também está inserida no bioma de ecótono (Amazônia-Cerrado), contudo, a estação encontra-se mais ao norte da *RH II*. Segundo Oliveira-Júnior et al. (2017), esta região é mais influenciada pelos regimes pluviométricos da região Amazônica. Sem dúvidas, as regiões de ecótono, devem e merecem ser analisadas com mais cautela. Essa constatação corrobora com o apontado por Christoffersen et al. (2014), pois os autores citam que as regiões de ecótono, ainda são sistemas complexos, que evidenciam desafios a modelagem de variáveis hidroclimáticas.

Ainda conforme a (Figura 15), a ocorrência de degenerações diminui na *RH III*, indicando maior adequabilidade da exponencial mista. De acordo com Gomes et al. (2019), a *RH III* apresenta as maiores altitudes da *RHTA*. Desta forma, tem-se que uma das possíveis causas das degenerações, pode ter relação com as características geomorfológicas da região. Segundo Valente et al. (2013), em seu estudo na planície do Bananal situada no rio Araguaia, foi constatado que as unidades geomorfológicas aliadas as características de vegetação afetam diretamente a dinâmica pluviométrica local e regional.

No caso dos parâmetros das FCPs, analisaram-se apenas os parâmetros da exponencial mista, já que esta foi a que alcançou o maior valor de aceites da H_0 no teste *KS*. Segundo Leonard et al. (2008), a estatística descritiva deve ser empregada em séries de dados de precipitação diárias. Mediante ao exposto, foram determinados os valores de máximo (Máx), mínimo (Mín), média (Méd) e coeficiente de variação (CV) e o desvio padrão (SD) dos parâmetros α , β_1 e β_2 (Tabela 10).

Tabela 10 - Análises estatísticas mensais dos parâmetros α , β_1 e β_2 para as três RH.

Est.	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Agos	Set	Out	Nov	Dez	
<i>RH I</i>													
α	Máx	0,982	0,970	0,993	0,990	1,000	1,000	0,904	1,000	0,929	0,784	0,879	0,936
	Mín	0,000	0,000	0,072	0,023	0,037	0,008	0,000	0,127	0,035	0,028	0,062	0,000
	Méd	0,653	0,677	0,698	0,700	0,594	0,584	0,590	0,613	0,566	0,480	0,475	0,508
	CV	0,241	0,272	0,249	0,255	0,302	0,285	0,261	0,213	0,250	0,224	0,189	0,274
	SD	0,369	0,402	0,357	0,364	0,509	0,488	0,443	0,347	0,442	0,468	0,397	0,538

$\beta 1$	Máx	275,041	92,846	33,407	60,117	40,292	70,470	59,213	21,521	46,138	53,442	43,595	106,036
	Mín	13,468	13,545	15,207	12,987	11,924	5,738	7,645	5,818	7,152	3,101	3,804	10,898
	Méd	28,608	23,110	21,696	21,962	20,558	16,311	14,478	11,304	12,566	16,668	20,373	26,494
	CV	1,515	0,560	0,222	0,439	0,383	0,708	0,672	0,333	0,563	0,545	0,431	0,819
	SD	43,330	12,936	4,812	9,649	7,865	11,556	9,723	3,767	7,069	9,087	8,784	21,689
$\beta 2$	Máx	18,047	20,308	21,299	20,776	18,504	14,498	11,877	11,776	10,085	10,544	13,253	14,677
	Mín	0,494	0,408	0,789	0,605	0,181	0,177	0,609	0,153	0,489	0,493	0,377	0,857
	Méd	5,911	8,150	7,913	7,290	6,107	5,059	4,140	3,425	3,468	3,305	3,862	5,759
	CV	0,877	0,663	0,814	0,838	0,804	0,827	0,821	0,818	0,765	0,699	0,768	0,745
	SD	5,186	5,405	6,441	6,106	4,911	4,185	3,398	2,803	2,652	2,311	2,966	4,291

RH II

α	Máx	0,994	0,968	0,988	0,992	0,99	1	1	1	0,99	1	0,989	0,991
	Mín	0,047	0,005	0,052	0,027	0	0	0	0	0	0	0	0,017
	Méd	0,691	0,698	0,699	0,641	0,545	0,506	0,503	0,545	0,605	0,656	0,693	0,687
	CV	0,363	0,32	0,269	0,381	0,457	0,546	0,633	0,533	0,41	0,338	0,299	0,341
	SD	0,251	0,223	0,188	0,244	0,249	0,276	0,319	0,29	0,248	0,222	0,207	0,234
$\beta 1$	Máx	68,144	354,303	51,27	92,787	54,703	79,175	122,992	81,308	98,656	106,761	151,961	97,377
	Mín	14,321	13,203	14,253	10,37	4,331	3,636	0,567	2,508	6,392	11,315	12,745	13,948
	Méd	21,453	23,443	20,061	19,245	17,719	17,514	14,199	16,711	19,017	19,779	21,694	21,754
	CV	0,357	1,283	0,259	0,455	0,419	0,7	0,986	0,799	0,627	0,463	0,592	0,427
	SD	7,652	30,086	5,197	8,748	7,426	12,261	14,006	13,347	11,926	9,164	12,854	9,295
$\beta 2$	Máx	24,055	24,149	23,682	20,191	18,317	29,444	24,232	14,13	18,228	18,588	25,9	25,544
	Mín	0,401	0,466	0,229	0,178	0,149	0,101	0,166	0,132	0,177	0,127	0,265	0,496
	Méd	9,124	8,549	8,208	7,036	5,468	5,523	5,646	5,394	5,694	6,363	7,663	8,838
	CV	0,713	0,754	0,761	0,783	0,777	0,907	0,776	0,691	0,769	0,792	0,819	0,765
	SD	6,501	6,45	6,246	5,51	4,251	5,011	4,382	3,728	4,381	5,037	6,278	6,765

RH III

α	Máx	0,997	0,993	1,000	0,955	1,000	0,999	0,979	0,983	1,000	1,000	0,990	0,963
	Mín	0,022	0,031	0,042	0,135	0,000	0,000	0,000	0,184	0,044	0,018	0,516	0,014
	Méd	0,738	0,681	0,713	0,602	0,519	0,517	0,532	0,586	0,549	0,598	0,794	0,688
	SD	0,336	0,362	0,325	0,399	0,609	0,680	0,466	0,410	0,435	0,478	0,173	0,366
	CV	0,248	0,247	0,231	0,240	0,316	0,352	0,248	0,240	0,239	0,286	0,138	0,252
$\beta 1$	Máx	46,215	57,285	53,416	24,748	42,161	78,880	23,275	42,293	36,911	102,797	21,723	102,791
	Mín	13,603	13,467	12,211	12,285	7,063	2,367	4,183	2,752	8,381	10,140	12,264	12,963
	Méd	19,490	20,139	19,273	17,052	18,777	17,407	10,832	14,488	16,863	25,649	17,122	22,373
	CV	0,407	0,429	0,404	0,234	0,489	0,965	0,491	0,500	0,368	0,908	0,140	0,734
	SD	7,930	8,645	7,781	3,982	9,177	16,798	5,322	7,244	6,201	23,290	2,401	16,415
$\beta 2$	Máx	19,548	19,521	17,096	15,157	17,202	15,227	9,731	11,839	13,961	17,838	18,779	19,618
	Mín	0,583	0,866	0,146	0,271	0,136	0,121	0,100	0,772	0,154	0,150	1,066	1,326
	Méd	9,449	8,550	8,091	6,279	6,117	5,973	4,294	5,412	5,471	7,730	8,762	10,505
	CV	0,598	0,651	0,669	0,653	0,716	0,690	0,672	0,639	0,651	0,670	0,657	0,558
	SD	5,647	5,568	5,411	4,098	4,382	4,122	2,888	3,457	3,561	5,178	5,753	5,865

De modo geral, os valores dos parâmetros demonstraram média e alta variabilidade ao longo dos doze meses para as três *RH* (Tabela 10). Com relação ao parâmetro α , Detzel (2009) e Wilks (1998) também calcularam algumas estatísticas básicas, encontrando valores médios de 0,66 e 0,60, respectivamente. Nesta pesquisa, o valor médio encontrado foi de: *RH I* (0,594), *RH II* (0,621) e *RH III* (0,624). Em virtude do exposto, verifica-se que os valores médios do parâmetro α para as três *RH* são semelhantes, isso está relacionado com as características climáticas predominantes do tipo *Aw* e *Am* na *RHTA* (Figura 4). Segundo Alvares et al. (2014b) o clima *Am* e *Aw* apresentam algumas distinções no período seco de precipitação, mas que no contexto geral as características climáticas são bastante similares.

No que diz respeito aos valores mínimos do parâmetro β_1 (Tabela 10), esses ocorreram nos meses com os menores índices de precipitação das *RH*. Para as *RH II* e *III*, ocorreu nos meses de junho a agosto, enquanto que para a *RH I* foi no período de outubro a novembro. Esta constatação também é confirmada por Rocha Filho (2016) em seu estudo sobre precipitação para região sul do Brasil, nos estados do Paraná, Santa Catarina e Rio Grande do sul, onde os menores valores de β_1 coincidiram com os meses de menores índices pluviométricos, e os maiores, nos meses com maiores índices de precipitações.

Em relação aos máximos do parâmetro β_2 , foram obtidos valores crescentes nos meses com as maiores probabilidades de chover, exceto para os meses de junho e julho na *RH I*, e nos meses de maio e junho na *RH II*. Além disso, é observado na Tabela 10, que os maiores valores do *CV* para as *RH I* e *II* acontecem nos meses citados anteriormente. Este acontecimento anômalo pode ser explicado pela ocorrência de eventos extremos de precipitação.

Nesse contexto, em relação ao parâmetro mencionado, existe um valor discrepante ($\beta_2=29,444$) na estação pluviométrica (1346003) na *RH II*, este fato está relacionado ao evento extremo de chuva, cujo registro foi de 84 mm ocorrido em 27 de junho de 1973. Nesses casos, a estimativa dos parâmetros da FCP fica comprometida pela presença deste dado discrepante. No restante da série histórica, para o mês de junho na estação pluviométrica citada, apresentou registros de dias secos em quase todo período selecionado.

Segundo Wilks (1998), a razão dos parâmetros (β_1/β_2) da exponencial mista, podem indicar o grau de intensidade das precipitações de uma região. Em seu estudo, essa razão foi obtida para todas as estações pluviométricas, e estes tiveram o valor médio de 4,8, e os valores médios aqui obtidos foram: *RH I* (6,807), *RH II* (6,282) e *RH III* (5,908).

Os resultados encontrados acima corroboram com afirmado por Loureiro et al. (2015), onde os autores afirmaram que os municípios com as maiores intensidades de precipitação

estão concentrados na *RH I*, em especial no nordeste do estado do Pará. E os de menores intensidades de precipitação, ocorrem no sudeste da *RH III*. As Figuras 16 a 18 mostram os resultados obtidos para os valores de α , β_1 e β_2 da função exponencial mista para as estações alvo.

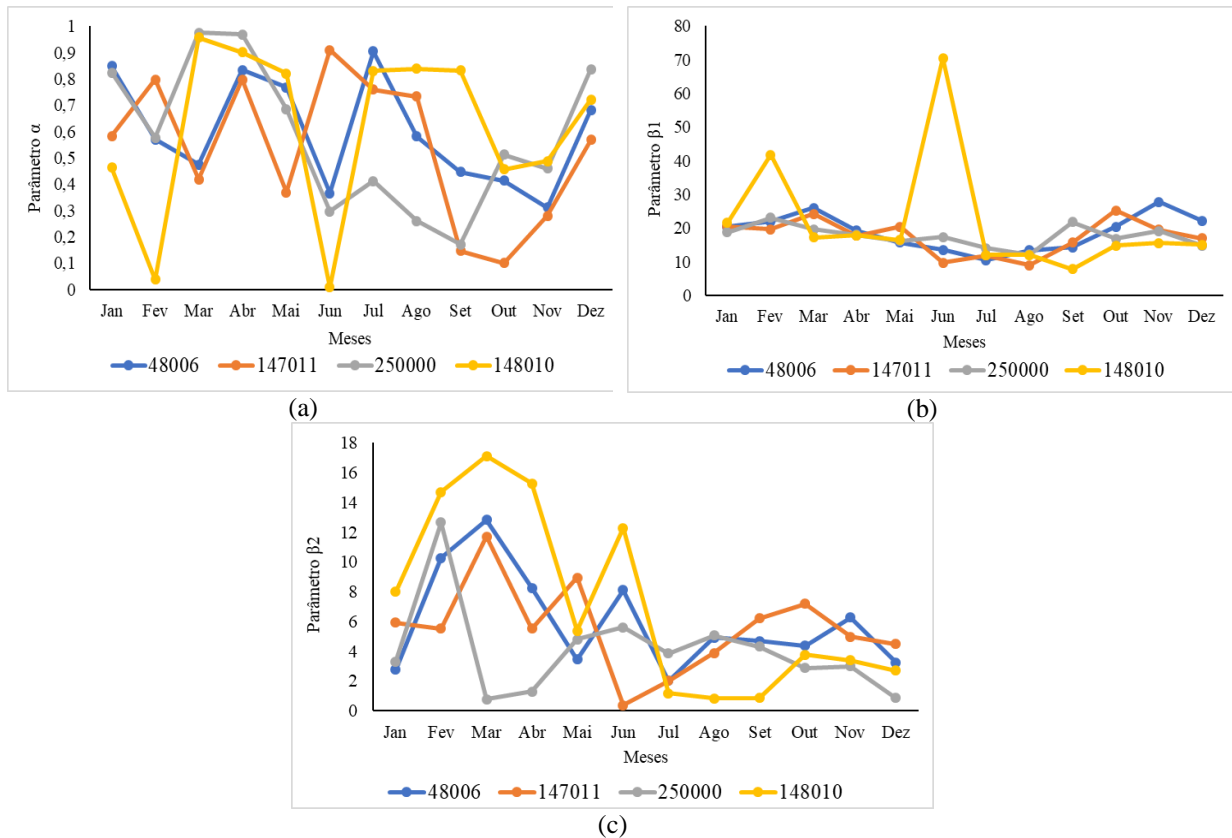





Figura 16 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a *RH I*.






(c)

Figura 17 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a *RH II*.

(a)

(b)



(c)

Figura 18 – Parâmetro α , β_1 e β_2 da distribuição exponencial mista para a *RH III*.

Na análise individual nas Figuras 16 a 18, verifica-se que os parâmetros de cada estação pluviométrica variam conforme o período seco e chuvoso, sendo que, a *RH I* e *RH III* foram as que apresentaram maiores variações. Em relação aos parâmetros (β_1 e β_2), ficou evidente que existe um comportamento de inter-relação de compensação entre eles, ou seja, a variação do parâmetro β_1 acompanha a de β_2 e vice-versa. No entanto, é percebido que a variação do parâmetro β_1 é maior para todos os meses.

Como verificado nos resultados apresentados, os parâmetros α , β_1 e β_2 possuem bastante variabilidade entre as estações e nos meses do ano. Portanto, com intuito de

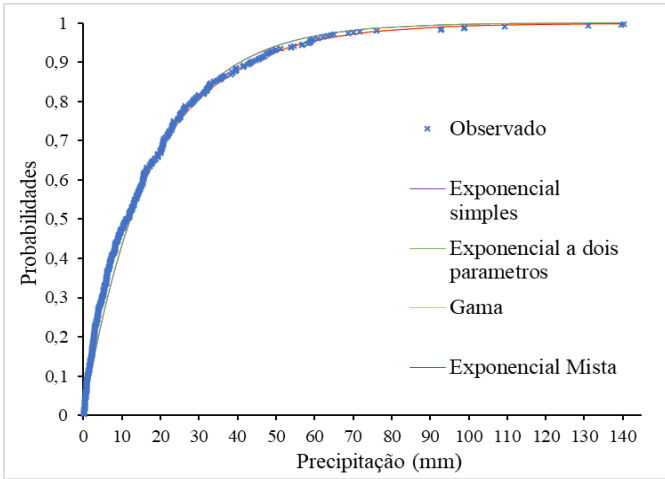
descrever o comportamento geral da distribuição exponencial mista nas *RH*, foi calculada a esperança matemática (Equação 25) para cada estação pluviométrica. Para a descrição do parâmetro μ para as três *RH*, foram calculados o valor médio e desvio padrão para cada *RH*, conforme a Tabela 11.

Tabela 11 – Valores médios (\bar{x}) e desvio padrão (σ) do parâmetro μ para as *RH*.


RH	Est.	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Agos	Set	Out	Nov	Dez
RI	\bar{x}	16,28	16,26	15,76	13,63	11,22	10,29	8,00	9,10	12,05	14,23	15,93	16,54
	σ	2,58	2,81	2,55	2,62	2,70	4,57	4,12	2,78	2,83	2,49	2,79	2,90
RII	\bar{x}	15,40	14,93	14,53	12,13	10,66	9,16	7,34	10,34	10,85	13,81	14,85	16,00
	σ	2,29	2,05	1,61	1,66	2,25	3,78	2,31	5,03	2,06	1,93	1,71	2,27
RIII	\bar{x}	15,27	16,27	17,01	16,16	13,39	9,68	8,88	7,98	7,55	8,56	11,00	12,36
	σ	2,71	2,58	2,33	2,52	1,95	1,99	1,48	1,67	1,43	2,30	3,25	2,42

A Tabela 11 mostra que as maiores médias do parâmetro μ ocorreram nos meses mais chuvosos para as três *RH*, principalmente para a *RH I* (fevereiro a abril). No entanto, a partir do mês de junho até agosto, as *RH II* e *RH III* apresentam valores médios superiores ao da *RH I*, essa característica foi mantida até o mês de janeiro. Essa inversão das maiores médias está atrelada à sazonalidade de precipitação da *RH I*, já que, segundo Menezes et al. (2015), cerca de 65% do regime pluviométrico nesta região concentra-se no quadrimestre de janeiro a abril. Além disso, é importante mencionar que, os maiores valores de média mencionados também são acompanhados pelos maiores valores do desvio padrão.


Prosseguindo com a análise das quantidades precipitadas, foram verificadas visualmente a qualidade do ajuste das FCPs analisadas em relação aos dados observados para os 12 meses, e estes foram considerados satisfatórios para todas as estações alvos. Mediante ao exposto, como exemplo, foram elaboradas as Figuras 19 e 20 tendo por objetivo mostrar o desempenho das FCPs na estação (48006) situada na *RH-I*. Reforça-se que, os períodos secos e chuvosos da respectiva estação foram definidos com base nas probabilidades P_{01} e P_{11} (Tabela 7).




janeiro



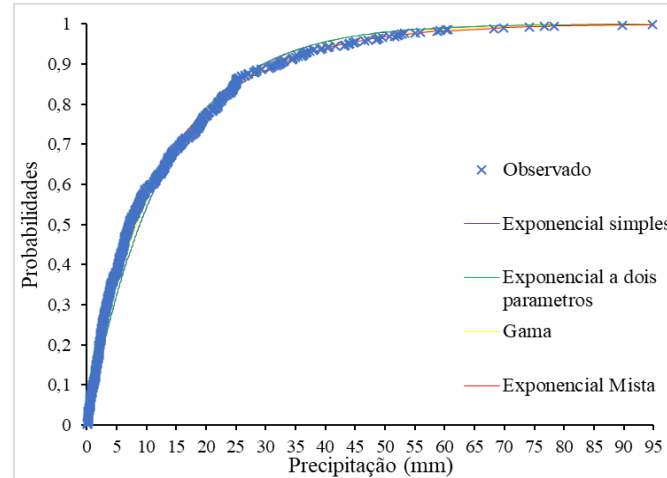
fevereiro




março



abril



maio



junho

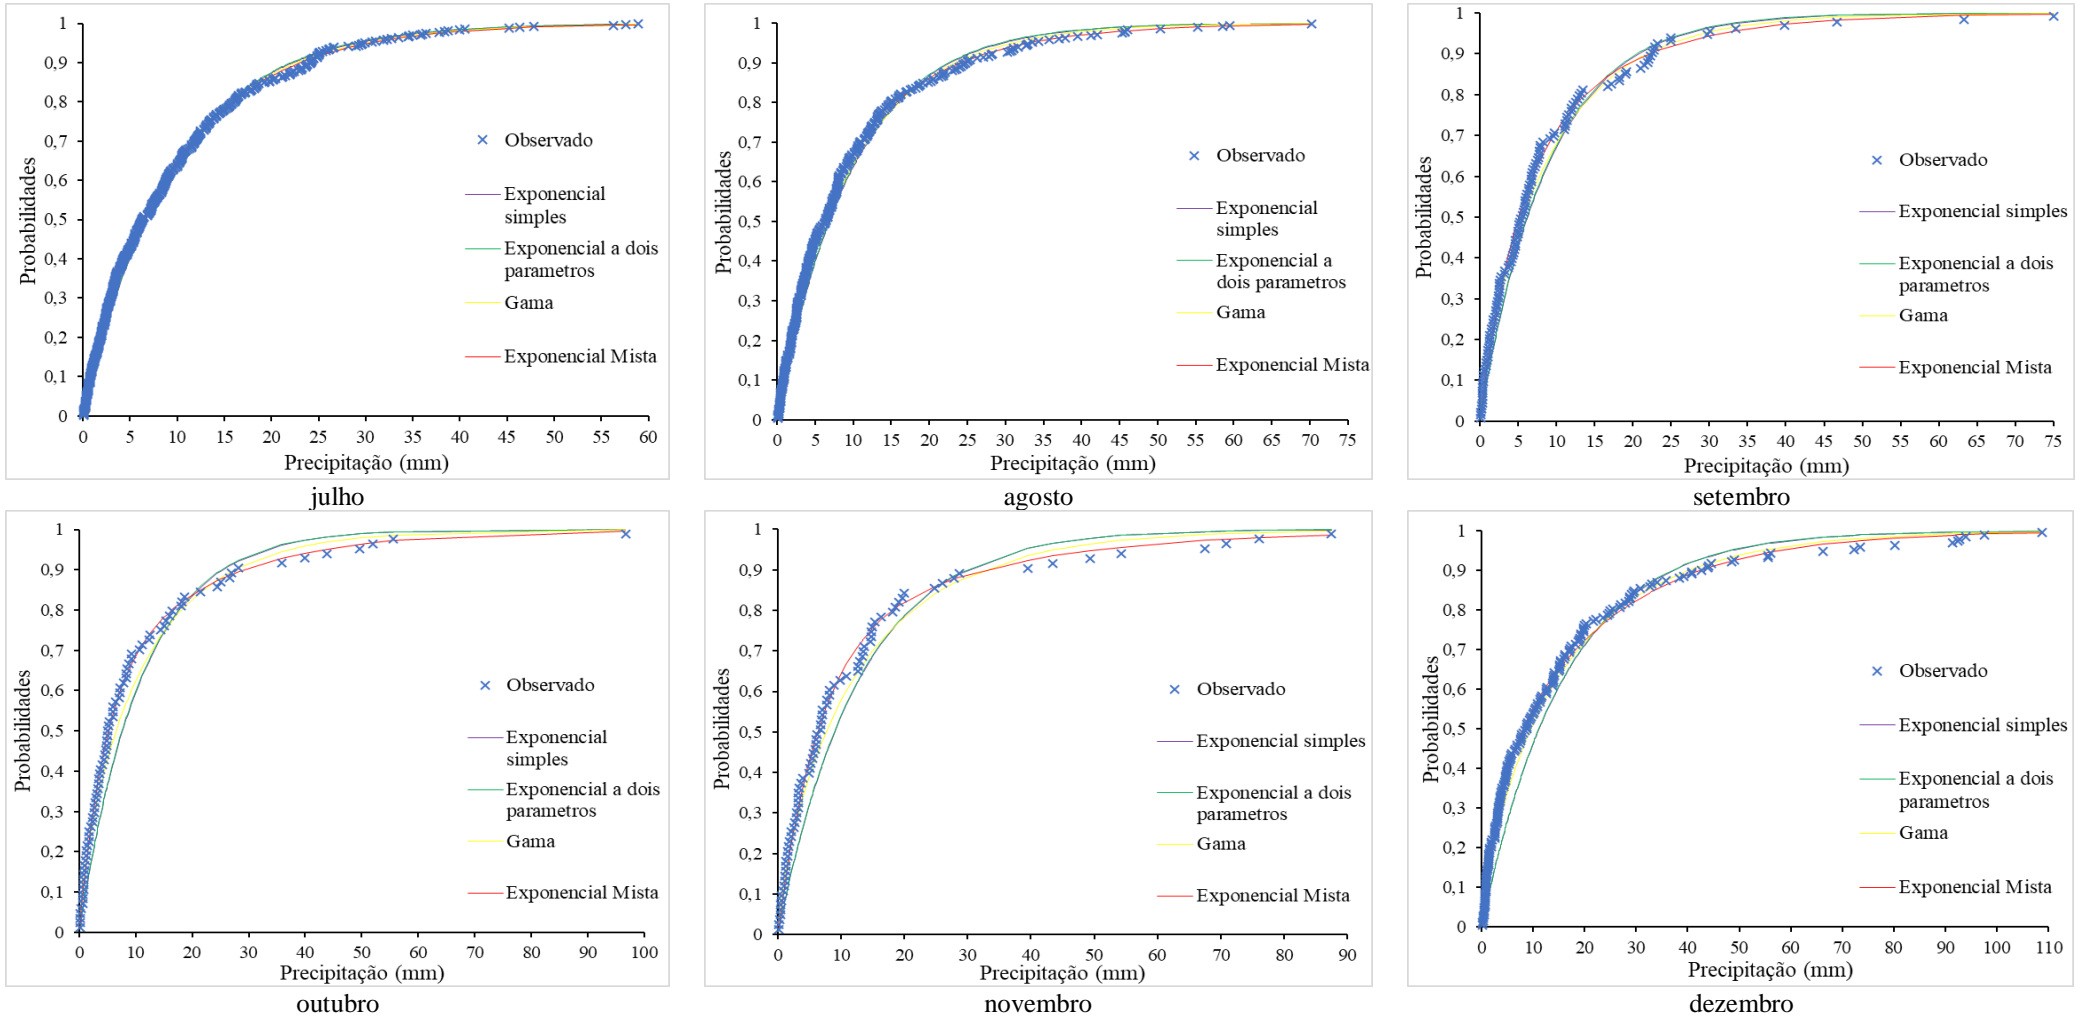
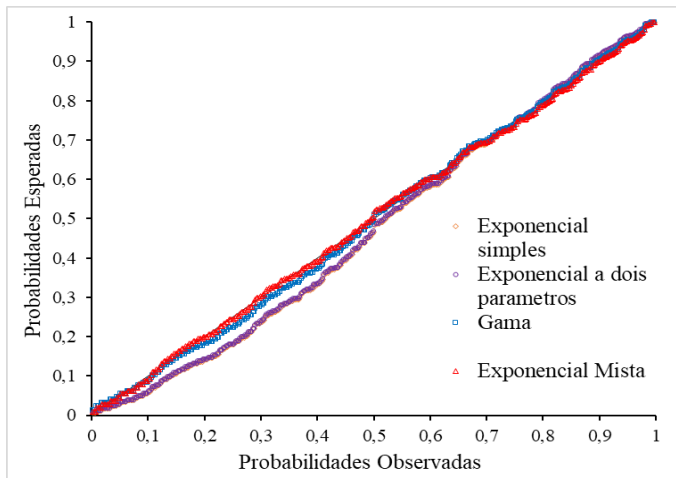



Figura 19 - Comparação entre as FCPs de precipitação diárias mensais em relação aos dados observados; *RH I* (48006).


Obs: Período menos chuvoso: agosto a janeiro e o Período chuvoso: fevereiro a julho.



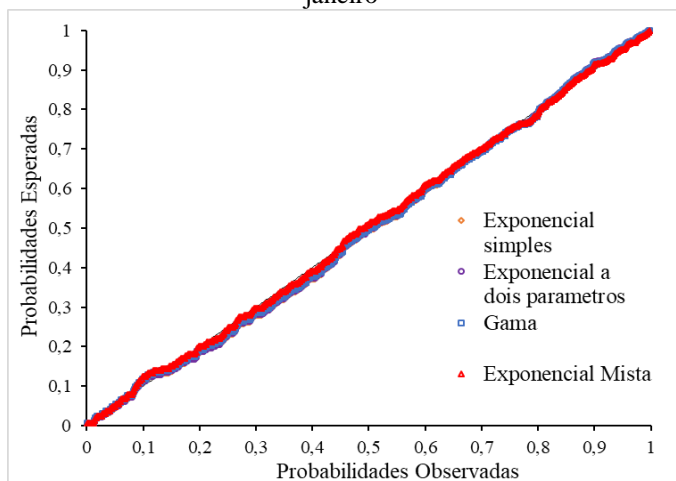
janeiro



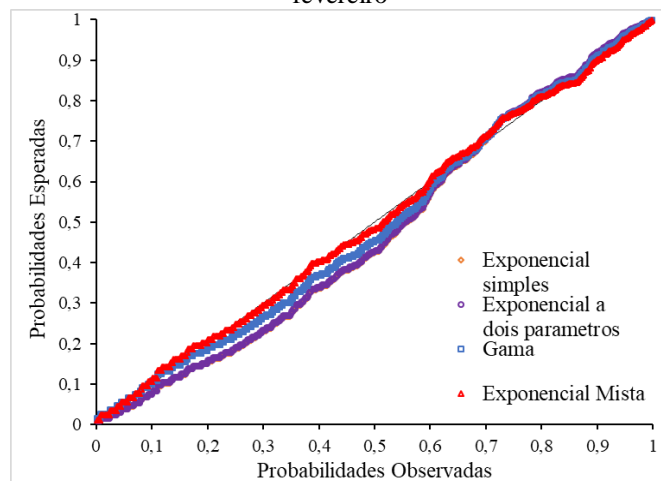
fevereiro




março



abril



maio



junho

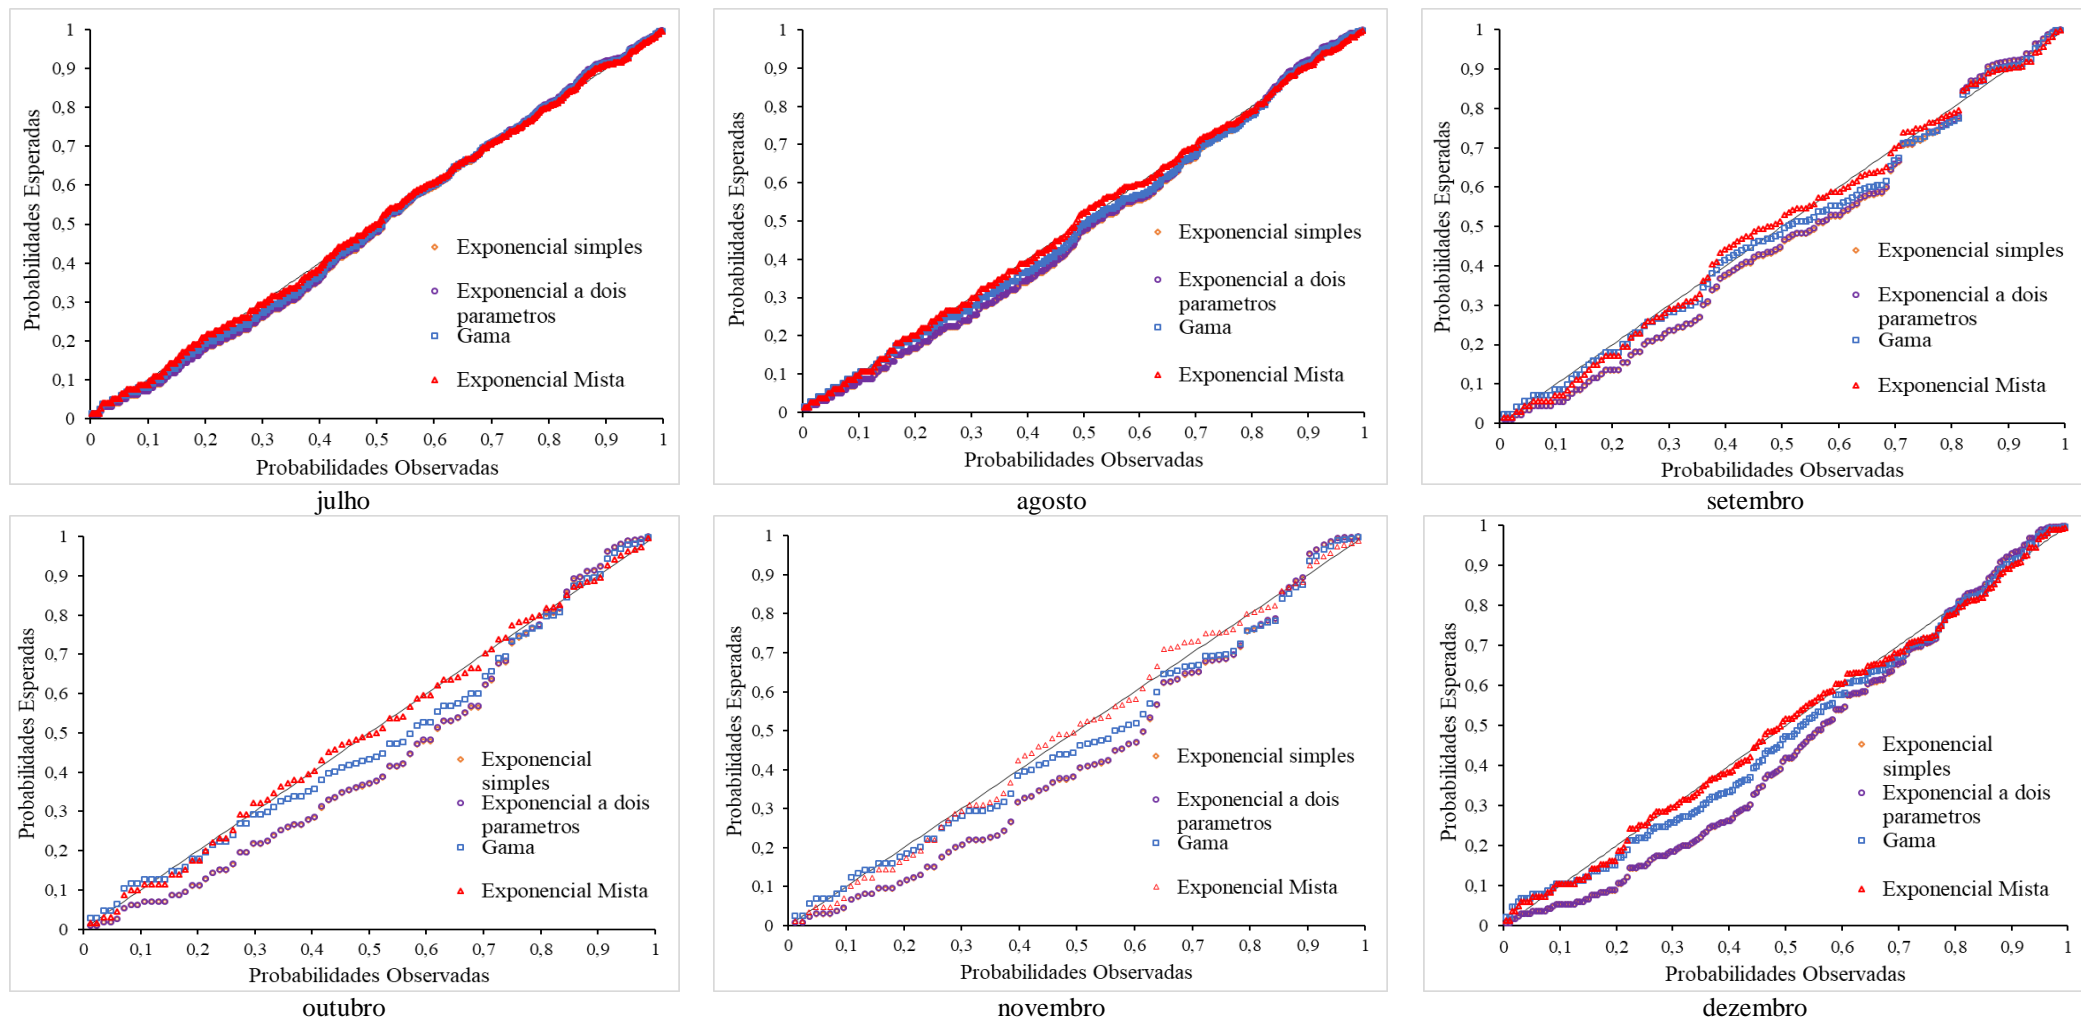


Figura 20 – Gráficos das probabilidades-probabilidades (P-P plot) de precipitações diárias mensais; *RH I* (48006).

Obs: Período menos chuvoso: agosto a janeiro e o Período chuvoso: fevereiro a julho.

Como observado nas Figuras 19 e 20, quanto menos chuvosos é o mês, menor é a capacidade da FCP em simular os dados de precipitação pluviométrica diária. No entanto, quando o cenário é o inverso, ou seja, quando existe grandes quantidades de dados de precipitação, os dados se aderem bem às FCPs.

Na Figura 20, os gráficos dos P-P plot reforçam ainda mais o melhor desempenho da exponencial mista sobre as demais, tanto para a estação menos chuvosa como para a mais chuvosa. Entretanto, nos meses de setembro, outubro e novembro, percebe-se que em alguns momentos a distribuição gama apresenta melhor aderência aos dados. Mas, no contexto geral, a exponencial mista ainda apresenta maior eficiência. Após a avaliação dos P-P plot, foram calculados os valores de MAE (Equação 41) e de RMSE (Equação 42) das FCPs para todos os meses (Figuras 21 e 22).

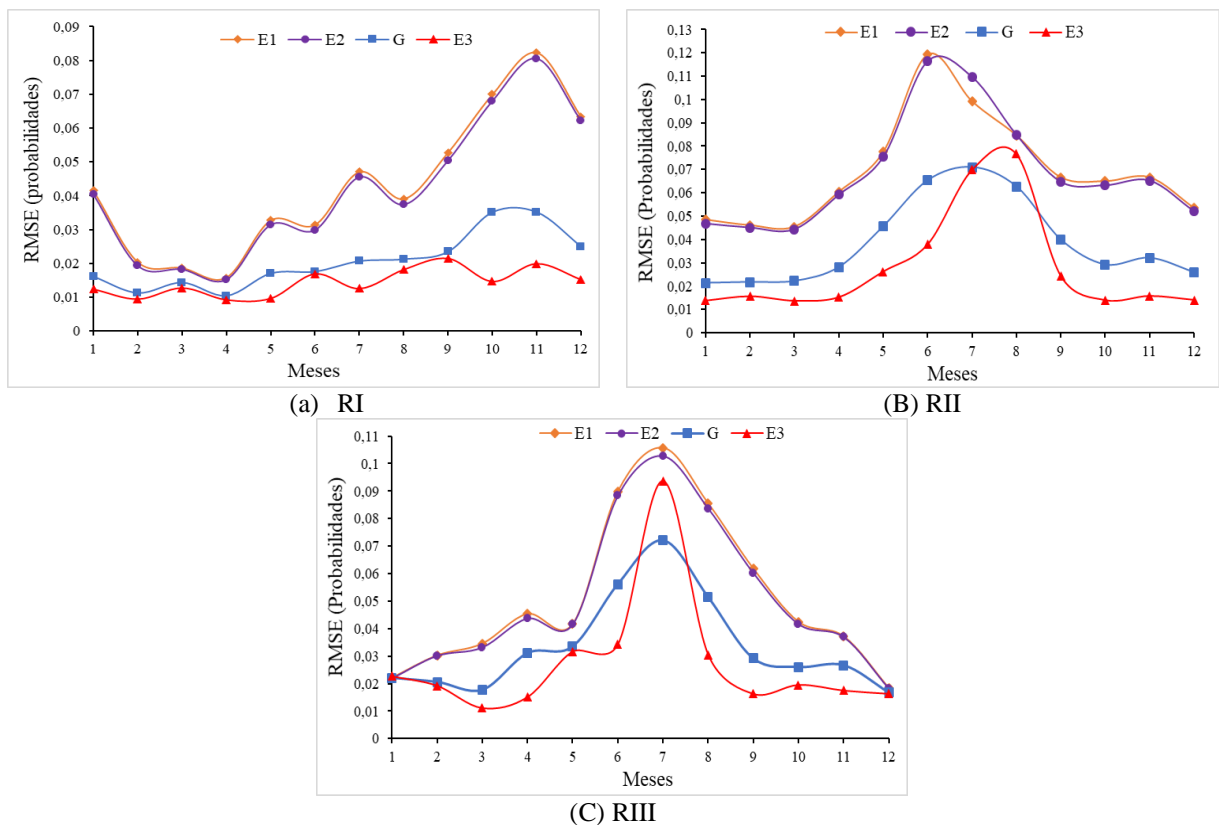


Figura 21 – Valores de RMSE das FCPs de precipitação diária mensal (E1-exponencial simples; E2-exponencial a dois parâmetros; E3-exponencial mista; G-gama) para as 12 estações alvos.

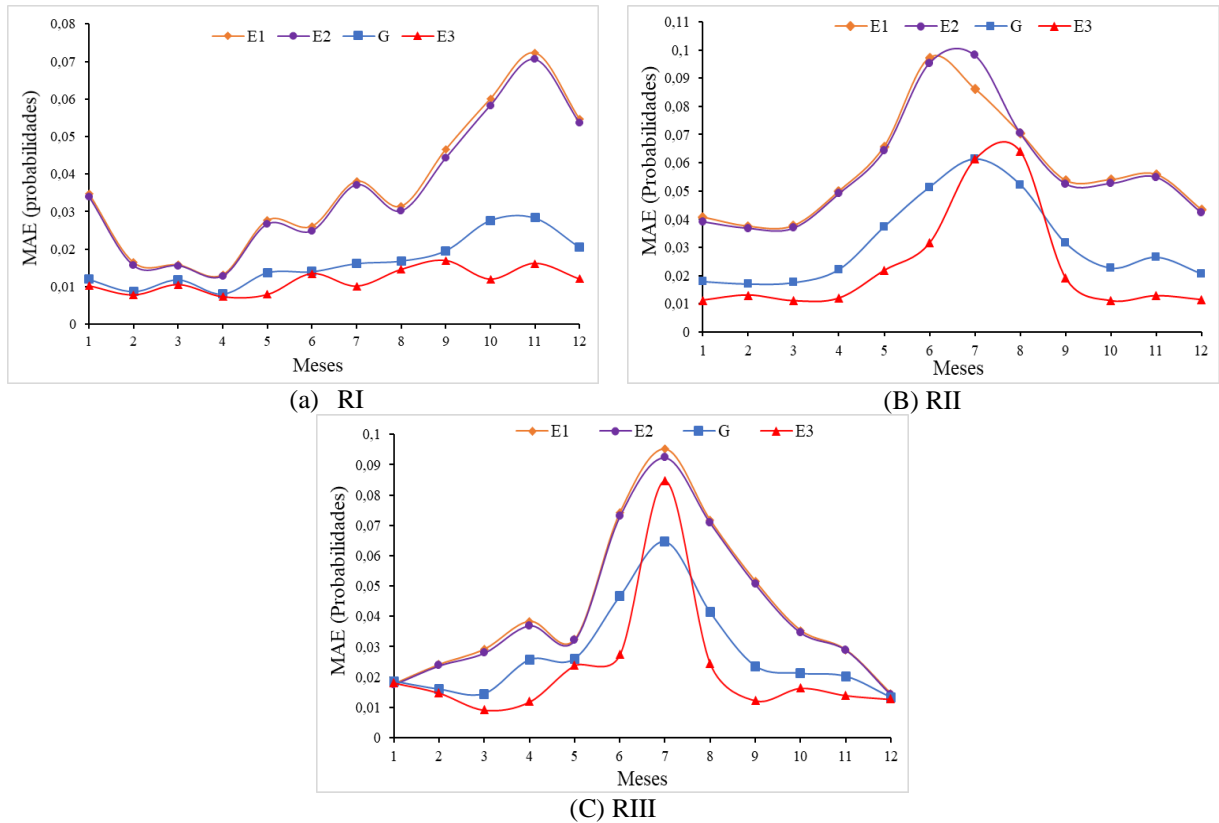


Figura 22 – Valores de MAE das FCPs de precipitação diária mensal (E1-exponencial simples; E2-exponencial a dois parâmetros; E3-exponencial mista; G-gama) para as 12 estações alvos.

Conforme as Figuras 21 e 22, a exponencial mista foi a que apresentou os menores valores médios de RMSE e MAE para todas as *RH*. Essa constatação corrobora com os resultados encontrados no P-P (plot). Neste contexto, podemos citar o ótimo desempenho da exponencial mista na *RH I*, a qual apresentou valor médio de RMSE (0,0144) e MAE (0,0116), em contrapartida, na *RH II* foi encontrado o menor desempenho das *RH*, mostrando valores de RMSE (0,0280) e MAE (0,0233). Entretanto, esses valores ainda são considerados valores satisfatórios.

Em todas as *RH* (Figuras 21 e Figuras 22) a distribuição exponencial simples foi a que apresentou maiores valores médios de RMSE e MAE, indicando a sua ineficiência, a qual pode ser observada na Figura 20, para representar os dados de precipitação pluviométrica, ressalva para aqueles meses extremamente secos, em que os dados apresentam altos valores de assimetria, como por exemplo, o mês de julho da estação (1447000) na *RH III*.

5.2.1 Validação

Com as etapas 1 e 2 do modelo finalizadas, segue-se para a etapa de validação, conforme descrito na Figura 7. Assim, foram estimadas 1000 séries de precipitações

pluviométricas para cada mês, em cada estação pluviométrica da *RHTA*, utilizando a *CM* de 1ª ordem aliadas as *FCPs* que obtiveram melhores ajustes no teste *KS*.

Adotando a estatística descritiva, comparou-se o valor médio das precipitações pluviométricas estimadas (*Est*) com a média dos valores observados na série histórica (*Obs*) em cada período analisado. Se a diferença entre os valores observados e estimados forem baixos, então se confirma o bom desempenho do modelo na estimativa das precipitações nas *RH*. A Tabela 12 mostra os resultados obtidos para 12 estações. Vale frisar que, em casos de não aderência aos dados por nenhuma *FCP* não houve geração de resultados (*ND*).

Tabela 12 – Estatística descritiva (méd-média diária; sd-desvio padrão diário; medi-mediana diária; tp-total precipitado mensal; ds-quantidades de dias secos e dc-quantidades de dias chuvosos) das séries de precipitações pluviométricas estimadas e observadas.

Cód.	Meses	Méd (mm)		SD (mm)		Medi (mm)		Máx (mm)		TP (mm)		DC		DS	
		Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est
<i>RH I</i>															
147011	Jan	14,43	14,46	17,17	17,50	8,30	8,19	105,70	126,57	7043,90	7085,83	488	490	225	224
	Fev	16,77	16,89	18,36	18,55	10,00	10,55	109,50	130,61	8835,50	8902,94	527	528	123	123
	Mar	16,96	17,07	19,48	19,03	10,20	10,92	216,10	148,25	10195,10	10258,33	601	601	112	113
	Abr	15,29	15,37	16,40	16,74	9,65	9,71	85,80	118,65	8809,90	8858,74	576	577	114	114
	Mai	13,19	13,30	15,16	15,34	8,40	8,31	101,70	121,32	7174,45	7240,60	544	545	169	169
	Jun	8,83	8,89	10,00	9,53	6,20	5,88	63,40	63,12	3684,00	3706,55	417	417	292	293
	Jul	9,48	9,58	11,04	11,17	5,10	5,47	63,60	74,67	3727,00	3754,97	393	392	351	353
	Agost	7,61	7,68	8,05	8,17	4,75	4,99	46,40	53,52	2405,10	2418,87	316	316	428	429
	Set	7,62	7,79	9,09	8,12	4,95	5,18	73,80	49,21	1600,50	1612,02	210	208	480	483
	Out	9,02	9,13	11,77	11,70	5,90	5,59	100,00	86,72	1487,80	1512,54	165	166	548	548
	Nov	9,06	9,17	12,97	12,77	5,20	4,83	100,00	84,23	1350,20	1368,47	149	150	541	541
	Dez	11,60	11,68	14,08	14,41	6,95	6,40	80,00	93,93	2853,70	2876,96	246	247	467	467
148010	Jan	14,29	14,37	17,60	17,06	8,70	8,56	144,80	128,62	7231,90	7262,49	506	506	269	270
	Fev	15,72	15,80	17,42	17,23	10,30	10,65	180,80	153,60	8362,00	8395,48	532	532	174	175
	Mar	17,27	17,36	16,08	16,73	11,70	12,36	123,80	115,81	10242,50	10252,07	593	591	182	185
	Abr	17,57	17,54	17,52	17,43	11,30	12,20	102,00	121,20	9929,30	9850,81	565	562	159	163
	Mai	14,51	14,59	15,98	15,65	10,00	9,38	142,50	110,82	7705,80	7740,95	531	531	212	213
	Jun	14,51	14,59	15,98	15,65	10,00	9,38	142,50	110,82	7705,80	7740,95	531	531	212	213
	Jul	10,21	10,32	12,46	11,73	6,40	6,27	101,30	76,58	3807,80	3862,09	373	375	402	401
	Agost	10,19	10,28	12,16	11,69	6,50	6,32	77,30	73,12	2945,40	2952,74	289	288	486	488
	Set	6,63	6,70	7,69	7,50	4,00	4,11	39,50	46,07	1672,00	1698,70	252	254	498	497
	Out	8,78	8,90	11,89	11,62	4,50	4,64	85,50	75,34	1783,10	1811,15	203	204	585	585
	Nov	9,31	9,38	12,88	12,48	4,40	4,65	96,50	79,07	1749,40	1775,03	188	190	562	561
	Dez	11,67	11,79	15,31	14,04	7,00	6,51	131,00	91,33	3826,20	3869,00	328	329	447	447
48006	Jan	17,73	17,9	20,63	19,8	11,1	11,1	140,3	133,19	7853,6	7910,94	443	444	270	270
	Fev	16,9	17	18,68	18,7	10,7	10,9	138,5	137,44	8991,9	9025,86	532	532	135	136
	Mar	19,1	19,3	20,92	21,2	12,6	12,4	132,9	162,19	11096	11200,15	581	582	163	163
	Abr	17,4	17,5	18,04	18,3	11,9	11,6	123,7	131,58	10405,8	10437,42	598	598	122	123

Mai	12,9	13	14,56	14,8	7,15	7,73	94,8	105,55	7582,4	7649,02	588	588	156	157
-----	------	----	-------	------	------	------	------	--------	--------	---------	-----	-----	-----	-----

Continua

Cód.	Meses	Méd (mm)		SD (mm)		Medi (mm)		Máx (mm)		TP (mm)		DC		DS	
		Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est
48006	Jun	10,08	10,2	10,72	10,7	6,6	6,82	86	79,38	5251,3	5305,62	521	521	199	200
	Jul	9,68	9,79	9,99	10,3	6,3	6,42	58,9	69,66	4715,5	4761,75	487	487	257	258
	Agost	9,89	9,99	11,3	11,5	6,35	6,05	70,2	79,1	3441,9	3476,93	348	348	393	394
	Set	9,01	9,08	11,48	11,1	5,45	5,23	75	65,78	1189	1188,02	132	131	558	560
	Out	11,04	11,2	15,68	15,5	5,1	5,41	96,7	85,22	916,2	936,8	83	84	628	628
	Nov	12,97	12,9	18,04	18,4	6,45	6,44	87,5	105,29	1063,4	1058,51	82	83	608	608
	Dez	16,14	16,2	21,12	20,2	8,7	8,21	108,7	120,53	3082	3110,63	191	193	522	521
	Jan	16,01	16,1	18,27	18	9,7	9,83	118	128,71	10372,7	10456,78	648	649	281	281
250000	Fev	18,64	18,7	20,07	19,9	12,4	12,3	147,6	151,19	13103,2	13146,04	703	703	144	145
	Mar	19,18	19,3	19,37	19,6	13,2	13,2	130,6	142,79	15098,1	15086,32	787	782	143	149
	Abr	17,54	17,7	18,09	18	12,4	12,1	146,7	129,35	13245,6	13323,65	755	755	145	146
	Mai	12,59	12,7	14,62	14,6	7,4	7,54	117,3	106,91	7564,2	7622,54	601	601	298	299
	Jun	9,1	9,2	12,02	11,7	5,5	5,29	100,6	89,99	3320,6	3353,18	365	365	505	506
	Jul	8,06	8,15	11,01	10,7	4,7	4,36	78	74,72	2120,7	2153,16	263	265	636	635
	Agost	6,91	7,1	8,45	7,58	4,2	4,63	70,3	45,16	1278,8	1282,68	185	181	683	688
	Set	7,31	7,66	11,7	8,85	4,05	4,58	96,9	53,63	1403,9	1403,71	192	184	648	657
	Out	10,06	10,1	13,41	13,9	4,5	4,54	66,5	88,35	2033	2036,98	202	202	666	667
	Nov	10,41	10,5	16,82	15,3	4,3	4,37	129,7	99,52	2278,9	2314,57	219	220	612	612
	Dez	12,54	12,9	14,64	14,8	7	7,8	84,3	102,81	5315,3	5324,05	424	414	475	486

RH II

649000	Jan	16,59	16,69	20,48	20,28	10,20	10,31	170,00	160,32	5277,00	5319,46	318	319	364	364
	Fev	17,16	17,20	18,03	17,97	11,00	11,49	99,70	118,77	5491,90	5493,61	320	320	305	306
	Mar	15,24	15,32	16,70	16,75	10,00	9,96	127,50	121,47	6369,10	6386,67	418	417	295	297
	Abr	15,05	15,10	15,92	15,79	10,30	10,12	98,20	108,00	5177,80	5191,03	344	344	346	347
	Mai	11,36	11,41	12,48	11,28	7,80	7,95	79,00	67,21	2488,20	2483,96	219	218	484	486
	Jun	8,85	9,01	8,80	9,42	7,05	5,96	39,50	47,22	655,00	656,27	74	73	614	616
	Jul	9,27	9,40	10,92	11,27	6,20	5,30	44,40	49,70	342,90	348,84	37	38	660	660
	Agost	9,74	9,86	10,81	10,93	5,50	6,13	48,70	50,67	457,60	467,46	47	48	666	666
	Set	11,53	11,70	12,79	12,22	7,90	7,79	69,00	64,77	1176,17	1178,02	102	101	588	590
	Out	17,26	17,27	18,49	18,98	10,10	10,76	100,40	109,60	2830,90	2851,00	164	166	545	544
	Nov	17,26	17,33	17,36	18,48	11,30	11,22	92,20	107,73	3226,80	3244,29	187	188	503	503
	Dez	17,26	17,33	17,36	18,48	11,30	11,22	92,20	107,73	3226,80	3244,29	187	188	503	503
1248000	Jan	14,22	14,37	16,57	15,74	8,65	9,32	130,40	96,68	3868,40	3928,31	272	274	164	163
	Fev	13,62	13,79	15,07	15,75	8,00	8,16	79,00	98,04	3650,10	3697,86	268	269	156	156
	Mar	12,12	12,27	15,07	15,36	6,60	6,71	82,00	102,81	3261,10	3306,60	269	270	216	216
	Abr	10,33	10,43	14,33	14,12	4,50	4,54	87,40	84,56	1870,10	1900,46	181	183	299	298
	Mai	8,98	8,94	15,33	14,23	3,10	3,56	76,30	71,60	467,10	465,68	52	53	443	443
	Jun	5,75	5,83	10,00	8,63	1,20	1,91	38,00	30,93	109,30	111,87	19	20	456	456
	Jul	13,70	13,60	18,14	11,81	6,10	10,75	34,40	30,40	41,10	58,77	3	5	480	479
	Agost	5,79	6,35	6,39	6,95	3,70	4,06	18,00	20,81	57,90	58,56	10	10	486	487
Set	10,07	10,21	12,03	12,74	5,60	5,28	51,20	61,83	583,90	597,86	58	59	422	422	

	Out	11,67	11,78	15,29	14,20	6,00	6,34	131,80	83,82	2252,40	2275,90	193	194	296	296
	continua														
Cód.	Meses	Méd (mm)		SD (mm)		Medi (mm)		Máx (mm)		TP (mm)		DC		DS	
124800 0		Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est
	Nov	15,61	15,62	19,22	20,84	6,80	6,80	93,40	127,09	3433,70	3443,22	220	221	200	200
	Dez	13,25	13,37	15,42	15,40	8,00	7,97	89,60	94,95	3458,40	3495,50	261	262	204	204
82765	Jan	14,06	14,1	19,47	17,1	7,2	7,67	138,5	125,21	9966,5	10257,32	709	726	333	345
	Fev	14,83	14,9	19,2	17,9	7,8	8,18	153,9	129,99	9863,2	10193,14	665	684	310	317
	Mar	13,79	14,1	16,77	16	8	8,64	127,3	121	10276,1	10503,95	745	746	331	358
	Abr	13,1	13,2	17,42	15,9	6,6	7,15	130,5	111,89	7045,7	7195,27	538	545	507	526
	Mai	11,05	11,1	14,64	14	4,9	5,62	84,2	88,95	2994,8	2978,14	271	268	816	833
	Jun	6,49	6,53	9,64	8,82	2,2	2,77	45,2	42,65	415,5	424,31	64	65	994	1000
	Jul	8,42	8,34	11,6	10,9	2,85	3,8	41,1	44,31	252,5	259,73	30	32	1077	1078
	Agost	8,95	9,29	10,2	10,4	3,65	5,75	31,6	44,48	340,1	336,37	38	37	1058	1065
	Set	8,6	8,69	11,56	11,7	3,5	3,65	60,5	68,51	1427,6	1461,43	166	169	890	899
	Out	12,86	12,9	17,47	16,8	5,35	5,95	98,7	111,38	4681,1	4828,79	364	374	721	732
	Nov	12,88	13	17,49	16,3	6,15	6,51	105	110,37	5590,2	5677,29	434	438	589	612
	Dez	13,5	13,6	17,85	16,6	6,8	7,38	135,3	117,14	8397	8707,32	622	641	476	480
1048001	Jan	17,44	17,6	17,07	17,4	11,7	12,2	108,4	120,66	10777,1	10854,72	618	619	467	467
	Fev	18,62	18,7	19,09	19,3	11,7	12,6	132	138,38	11077,8	11172,42	595	597	365	364
	Mar	17,15	17,2	16,45	17,1	12,4	12	107,5	121,12	10892,1	10936,65	635	635	450	451
	Abr	16,02	16,1	16,86	17,5	10,4	10,2	91,2	117,05	6808,5	6859,73	425	426	625	625
	Mai	12,97	13,1	15,9	16,3	6,8	6,99	89	95,84	1880,1	1889,84	145	145	940	941
	Jun	10,59	10,7	15,93	14,8	4,2	5,11	63,4	54,47	180	181,32	17	18	1000	1000
	Jul	10,63	10,7	11,08	10,2	6,2	7,78	36,2	35,71	159,4	160,82	15	16	1070	1070
	Agost	11,76	11,8	13,48	13,3	6,9	7,42	50,2	55,61	423,5	436,01	36	37	1018	1018
	Set	11,65	11,8	13,27	13,5	6,9	7,31	73,1	83,23	1748	1763,49	150	151	840	840
	Out	14,69	14,8	15,01	15,1	8,85	10,1	100	100,34	5170,2	5216,25	352	353	640	640
	Nov	18,69	18,8	20,2	20,4	12	12,1	119	142,28	8074,2	8117,77	432	433	558	558
	Dez	19,42	19,4	20,17	19,3	14	13,5	148,2	135,3	11961	11920,63	616	614	456	459
83368	Jan	15,08	15,2	18,97	18,2	8	8,25	147,1	125,94	7193,1	7283,61	477	481	228	232
	Fev	13,05	13,2	15,54	15,4	8	7,57	107,2	99,88	4997,4	5042,95	383	383	267	268
	Mar	13,33	13,4	15,82	16,2	7,6	7,39	94,4	105,28	4892,3	4946,43	367	369	343	345
	Abr	10,53	10,6	13,76	14,2	4,2	4,89	68,4	86,52	1948,5	1969,99	185	186	512	515
	Mai	11,49	11,7	16,04	16,6	4,5	5,3	83,2	82,74	632,2	640,43	55	55	672	673
	Jun	14,27	14,3	22,01	17,7	7	7,54	95,1	64,25	285,3	290,87	20	21	675	675
	Jul	10,51	10,6	12,8	11,9	5,7	6,58	49,3	42,35	157,7	160,64	15	16	698	698
	Agost	7,47	7,66	7,57	7,23	5,55	5,55	32	26,45	134,4	140,76	18	19	725	725
	Set	7,36	7,46	9,21	8,9	3,7	4,1	48,2	47,26	735,8	753,55	100	102	619	619
	Out	12,2	12,3	16,97	17,3	4,9	5,21	97,1	109,29	2671,1	2697,72	219	220	511	514
	Nov	13,04	13,2	17,72	17,2	5,8	6,25	121	115,77	4627,6	4751,46	355	361	357	359
	Dez	12,39	12,5	14,2	14,3	7,6	7,42	85,6	96,53	5898,6	6009,6	476	482	263	261
<i>RH III</i>															
144 700 0	Jan	14,67	14,74	15,03	14,03	10,30	10,58	131,40	90,83	5133,90	5150,25	350	350	301	302
	Fev	14,66	14,71	17,31	16,61	8,20	8,83	119,10	105,51	4427,30	4465,35	302	304	291	290

	Mar	13,74	13,84	14,84	15,18	9,00	8,75	82,40	100,26	4218,90	4266,86	307	309	344	343
	continua														
Cód.	Meses	Méd (mm)		SD (mm)		Medi (mm)		Máx (mm)		TP (mm)		DC		DS	
		Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est	Obs	Est
1447000	Abr	12,50	12,62	16,14	16,57	6,90	6,70	100,00	106,74	2262,80	2300,13	181	183	449	448
	Mai	8,92	8,99	8,16	9,32	4,70	6,02	31,20	45,53	597,40	605,03	67	68	584	584
	Jun	9,11	9,08	9,59	9,91	5,15	5,58	28,00	34,51	145,80	146,03	16	17	614	614
	Jul	5,81	6,15	6,83	6,34	5,00	4,16	24,70	19,85	63,90	65,46	11	11	640	641
	Agost	6,63	6,70	9,97	10,09	2,85	2,94	43,20	44,26	185,70	190,00	28	29	623	623
	Set	11,80	11,87	15,08	14,35	6,30	6,43	101,00	77,36	1227,20	1243,25	104	105	526	526
	Out	14,41	14,55	18,02	17,65	8,00	8,10	142,10	115,05	3833,00	3859,56	266	266	385	386
	Nov	14,27	14,31	15,60	15,93	8,00	8,78	100,30	105,76	5207,10	5240,07	365	367	294	293
	Dez	16,22	16,37	17,63	16,66	10,50	11,15	116,00	110,83	6583,90	6591,66	406	403	276	280
	1555005	Jan	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND	ND
Fev		14,42	14,4	14,77	14,2	10	10,1	91	86,05	3446,3	3411,95	239	238	143	145
Mar		13,37	13,5	14,81	14,9	9	8,46	84	90,68	3248,2	3277,95	243	243	191	192
Abr		12,95	13,1	12,93	13,8	9,8	8,65	74,2	78,32	2161,9	2176,21	167	167	240	241
Mai		10,34	10,5	11,74	11	7,25	7,01	67,3	57,12	910,3	912,11	88	87	315	317
Jun		6,46	6,56	9,37	9,23	1,5	2,35	40	36,19	187,3	192,66	29	30	369	369
Jul		5,14	5,42	7,22	5,58	1,85	3,67	20,6	16,96	51,4	51,15	10	10	424	425
Agost		8,37	8,56	9,28	8,87	5,8	5,75	35	36,08	242,7	246,18	29	29	405	406
Set		8,57	8,64	9,97	10,3	5	4,77	53	52,68	771,7	777,08	90	91	330	330
Out		13,56	13,6	13,06	13,5	10	9,49	59,5	74,07	1736,1	1761,51	128	130	306	305
Nov		14,1	14,2	12,66	13,3	9,8	10,3	59,5	76,95	2566	2572,88	182	182	208	209
Dez		14,64	14,8	14,6	14,7	10	10,3	103	89,72	3558,6	3571,65	243	243	160	161
1853000	Jan	14,18	14,2	14,99	14,1	9,5	9,9	130	94,88	6465,4	6424,13	456	453	253	257
	Fev	13,42	13,5	12,99	12,5	9,1	9,83	78	81,67	5475,2	5477,5	408	408	241	242
	Mar	13,29	13,4	15,15	15,1	8	8,08	117,6	100,58	5184,4	5219,31	390	391	289	289
	Abr	12,29	12,4	14,96	15	6,4	7,31	113,4	101,8	3010,1	3038,19	245	245	445	446
	Mai	11,7	11,7	12,75	12,7	7,95	7,48	79,8	67,61	1310,1	1298,64	112	111	601	603
	Jun	6,91	6,98	6,87	6,76	5,2	4,93	29,9	30,86	338,6	340,21	49	49	641	642
	Jul	7,6	7,92	9,02	8,71	4,1	5,06	37,4	36,31	235,5	236,02	31	30	682	684
	Agost	11,89	12	14,6	14,2	6,55	6,63	73,6	64,48	570,6	576,34	48	49	665	665
	Set	13,61	13,7	16,11	15,8	7,65	7,95	97	89,19	1823,4	1848,57	134	136	556	555
	Out	13,03	13,1	17,78	17	7,05	7,94	168	136,98	3100	3113,9	238	238	475	476
	Nov	15,06	15,1	16,83	17,3	8,65	8,9	101,1	111,3	4879,3	4896,69	324	324	345	346
	Dez	14,74	14,9	14,94	14,6	10	10,4	117,3	96,31	5866,8	5863,06	398	395	253	257

A Tabela 12 mostra que o modelo proposto produziu resultados consistentes, uma vez que após aplicação da Equação 43 foi encontrado o maior erro absoluto entre as médias de 0,35 mm na estação (250000) na *RH I* nos meses de dezembro, enquanto para o desvio padrão e a mediana, também em valores absolutos, a diferença máxima foi de 6,33 mm e 4,65 mm na estação (1248000) na *RH I*, nos meses de junho. Percebe-se que as maiores discrepâncias

entre as séries foram encontradas nos meses menos chuvosos. Esse fato é reflexo da menor quantidade de dados com precipitação nas séries, conseqüentemente, o modelo possui menos informações para determinar os parâmetros, o que reflete diretamente na sua eficiência.

Em um aspecto geral, os valores do desvio padrão das precipitações estimadas foram inferiores as observadas das séries históricas (Tabela 12). Acrescentando-se que, essa característica foi encontrada para a maioria das estações pluviométricas das *RH I* (62,11%), *RH II* (58,50%) e *RH III* (57,87%). Este tipo de deficiência nos modelos estocásticos de precipitação é conhecido como o fenômeno de “*overdispersion*” (KATZ; PARLANGE, 1998). De acordo com Wilks e Wilby (1999), a causa mais possível para este fenômeno são as variações climáticas interanuais que, por sua vez, causam mudanças de forma sistemática nas propriedades estatísticas das variáveis climáticas.

Em relação à precipitação máxima diária, o modelo apresentou resultados aceitáveis nas *RH I, II e III*, dado que, nessas regiões os valores de erros médios absolutos foram de 18,18 mm, 12,14 mm e 12,11 mm, respectivamente. Entretanto, para alguns casos, como por exemplo, nos meses de março da estação (147011) na *RH I*, o erro absoluto encontrado foi de 67,84 mm, esse alto valor indica que o modelo não conseguiu reproduzir os eventos extremos máximos com eficiência. As precipitações de grande intensidade são causadas por dinâmicas atmosféricas pouco comuns. Como a estrutura do modelo proposto não contempla esse tipo de ocorrência e está baseada inteiramente na série histórica observada, a reprodução de fenômenos de baixa frequência (eventos extremos máximos de precipitação) fica desfavorecida.

A falha de modelos estocásticos em reproduzir os eventos de baixa frequência (eventos máximos) é comum na literatura (DETZEL et al. 2011b; LIU et al. 2011; NG et al. 2017; SUHAILA et al. 2011). Fato esse que tem motivado o uso de modelos condicionados a variáveis exógenas (GRONDONA et al. 2000; MORENO-PÉREZ et al. 2014, ROCHA FILHO, 2016; WOOLHISER et al. 2008) e modelos que utilizam FCPs mistas mais flexíveis (COSTA et al. 2015; EVIN et al. 2018; HUNDECHA et al. 2009; LI et al. 2012; LI et al. 2014).

A utilização da CM de 1ª ordem para a estimativa da quantidade de dias secos e chuvosos, quando comparados com os valores observados por meio dos erros absolutos (E_{abs}), foi satisfatória. Assim, a média do erro absoluto para os dias chuvosos foram de 2 dias para a *RH I*, 3 dias para a *RH II* e 1 dia para a *RH III*. Para os dias secos foram de 2, 4 e 1 dias para *RH I, RH II e RH III*, respectivamente. Esses valores, quando comparados ao tamanho da amostra, são desprezíveis.

Contudo, quando é considerado o maior valor de erro absoluto (E_{abs}), este foi encontrado na estação (82765), tendo-se para dias secos, um erro absoluto de 27 dias para o mês de março, enquanto para dias chuvosos um erro absoluto de 19 dias para os meses de fevereiro e dezembro. Esta constatação não é um caso atípico, visto que, essa estação pluviométrica é marcada pelos maiores erros absolutos das estações analisadas (Tabela 12). Deste modo, a justificativa para tal comportamento está na sua maior dependência de dias anteriores (2ª e 3ª ordem), conforme indicado pelo critério BIC (Tabela 13) nos casos em que a 1ª ordem foi sugerida nos meses de junho a agosto, os erros absolutos foram menores.

Silva et al. (2016) em sua análise da precipitação no período de 1977 a 2014, verificaram que a estação (82765) apresenta tendência de diminuição e aumento na precipitação para o período seco e chuvoso, respectivamente. Este mesmo resultado também foi encontrado no estudo realizado por Souza et al. (2017). Além disso, Zeri et al. (2018) constataram que essa região que está localizada ao norte da *RH II* sofre maior influência da variabilidade interanual nos eventos de seca. Os resultados indicaram que algumas estações dessa região são afetadas por eventos contínuos de seca de 2,6 meses em média. Dessa forma, fica evidente que a precipitação nesta região é influenciada por comportamentos não estacionários.

Tabela 13 – Valores do critério BIC para indicação da ordem ótima (em vermelho) até a 4ª ordem da cadeia de Markov.

Cod.	Or.	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
<i>RH I</i>													
48006	0	952,6	678,5	788,9	661,8	770,7	855,5	965,7	1031,1	680,1	519,0	509,7	835,3
	1	854,9	655,7	774,6	663,5	770,0	852,4	968,8	1002,5	667,6	498,4	502,4	731,6
	2	854,5	656,1	778,3	668,8	778,4	863,2	980,9	1011,5	678,2	508,4	510,3	740,8
	3	874,2	675,4	791,4	688,3	797,4	887,2	1001,0	1025,3	697,6	525,4	532,9	753,4
	4	920,2	725,4	834,2	728,7	844,7	928,9	1046,9	1069,0	748,6	577,5	587,6	801,5
250000	0	1145,7	779,0	805,1	801,5	1148,9	1190,2	1093,5	906,2	909,8	948,6	965,2	1250,2
	1	1112,7	772,6	797,3	783,4	1098,5	1159,1	1075,6	889,8	906,6	944,5	939,9	1195,0
	2	1118,8	783,3	806,5	791,4	1109,1	1168,1	1085,8	895,6	912,1	950,5	951,6	1199,2
	3	1138,0	800,4	828,0	812,3	1121,7	1190,5	1104,1	921,7	936,1	974,2	976,4	1215,2
	4	1171,5	832,0	876,4	857,2	1167,3	1234,3	1147,6	968,2	984,4	1026,1	1012,3	1259,7
147011	0	895,7	637,1	626,6	625,1	787,5	967,3	1035,6	1021,1	854,6	778,0	726,5	925,4
	1	788,9	626,8	614,3	612,2	762,6	960,1	1021,8	1001,4	823,5	752,6	708,6	826,8
	2	796,1	637,8	620,9	623,0	768,8	962,2	1027,1	1011,9	824,9	759,3	712,9	835,4
	3	819,8	658,3	638,6	641,2	777,8	976,2	1049,4	1026,6	847,4	782,9	729,9	854,6
	4	865,6	704,6	690,3	690,1	816,7	1021,7	1093,8	1067,7	887,2	816,9	764,5	903,6
148010	0	1007,4	795,0	851,5	768,8	895,1	996,9	1079,9	1030,4	964,1	905,9	851,2	1062,7
	1	977,7	782,2	835,7	752,0	886,7	981,4	1040,5	1010,4	956,5	901,5	838,6	1022,2

	2	974,9	784,6	843,6	756,1	890,5	982,4	1050,7	1016,6	960,4	909,8	843,5	995,8
	3	995,9	806,8	860,3	777,3	903,2	1002,0	1068,9	1024,9	970,5	934,7	859,0	1011,9
	4	1039,5	846,7	892,7	802,2	931,8	1028,9	1110,2	1065,5	1015,9	966,8	904,8	1058,4

RH II

82765	0	1368,0	1275,6	1388,5	1504,1	1253,7	502,1	286,7	347,2	947,6	1431,1	1452,9	1553,3
	1	1277,5	1150,0	1294,9	1357,7	1104,0	465,9	262,2	332,7	881,3	1347,3	1347,5	1470,1
	2	1257,7	1132,6	1274,7	1320,8	1093,1	470,9	271,8	344,6	882,2	1334,6	1324,0	1441,4
	3	1252,1	1126,8	1272,1	1311,2	1100,2	497,4	296,9	381,7	901,2	1335,3	1324,1	1438,2
	4	1270,8	1143,8	1287,6	1320,1	1136,5	561,9	370,5	457,5	942,2	1355,6	1347,0	1461,1
1048001	0	1490,0	1282,1	1479,4	1424,2	860,3	179,8	165,2	320,9	849,1	1297,3	1363,3	1469,1
	1	1484,5	1272,5	1485,3	1378,6	802,0	181,9	166,3	280,8	808,9	1293,2	1365,4	1468,0
	2	1493,0	1272,3	1496,6	1364,8	796,9	197,5	181,3	288,5	814,1	1298,7	1372,3	1475,2
	3	1508,9	1281,2	1521,2	1386,7	815,8	226,9	210,3	316,3	837,4	1319,5	1397,1	1495,1
	4	1555,8	1329,9	1569,6	1426,7	869,6	304,6	273,7	385,8	886,2	1364,3	1448,5	1545,3
83368	0	908,0	886,8	996,0	819,2	396,3	187,9	152,1	176,1	588,5	904,5	1007,6	974,8
	1	863,2	866,0	955,7	759,7	380,8	167,4	149,4	158,3	581,6	896,8	982,1	933,8
	2	855,1	874,0	953,0	760,2	390,7	185,2	163,8	177,6	584,7	903,6	978,2	935,7
	3	857,3	896,0	969,2	778,6	415,4	220,1	197,0	212,3	611,7	920,8	989,4	954,9
	4	890,0	943,5	1010,4	817,6	489,8	298,8	275,0	282,6	652,6	962,9	1025,9	997,6
649000	0	948,9	872,5	973,7	963,1	878,7	476,3	295,8	353,0	584,6	773,5	812,8	926,6
	1	951,8	874,0	977,3	949,6	875,8	474,2	289,6	359,4	581,3	772,3	817,9	931,1
	2	959,4	868,4	985,8	943,7	879,3	484,5	301,1	369,2	589,1	783,7	826,5	938,1
	3	979,7	885,1	991,1	962,6	903,8	511,3	334,9	404,8	613,7	805,9	849,7	960,2
	4	1018,9	926,3	1029,0	1004,5	947,6	573,6	403,3	457,2	664,4	852,6	887,6	1009,8
1248000	0	583,5	563,9	672,7	642,3	338,9	165,7	42,6	104,1	360,0	662,2	587,3	643,8
	1	562,6	541,2	657,6	620,1	329,3	154,1	53,3	104,0	362,0	662,2	591,6	648,2
	2	570,4	529,1	654,5	617,8	340,0	164,6	72,9	112,6	368,8	660,9	601,4	658,7
	3	587,3	550,6	668,8	641,3	362,4	187,2	110,3	151,3	383,7	682,9	622,7	677,6
	4	620,9	587,6	710,6	678,6	419,6	257,6	183,6	225,8	443,5	722,9	661,2	715,0

RH III

1555005	0	584,9	511,1	601,5	557,1	429,0	213,7	101,3	219,0	442,5	532,5	544,9	547,5
	1	566,6	510,7	592,4	533,4	401,8	207,2	105,6	211,4	421,1	520,3	534,8	530,1
	2	574,9	521,0	599,7	535,0	404,8	218,5	126,1	216,6	432,4	530,5	542,8	536,4
	3	596,0	532,7	617,6	555,2	414,9	246,6	164,4	234,5	448,8	548,1	563,2	555,9
	4	640,0	572,8	655,4	597,5	458,7	314,9	238,0	293,5	486,2	594,5	602,7	590,1
1853000	0	930,5	862,7	932,7	904,3	626,6	360,2	261,6	358,3	685,9	914,7	933,3	876,4
	1	921,4	856,3	920,0	870,9	610,5	343,2	249,6	335,2	679,5	914,9	926,9	860,8
	2	914,9	860,7	928,8	880,7	617,2	354,0	260,1	340,1	689,9	917,5	935,6	852,7
	3	936,1	883,4	938,5	900,7	639,4	380,2	291,6	362,5	711,3	941,6	956,7	867,7
	4	983,6	926,9	975,6	945,0	689,8	445,1	363,8	422,9	763,8	980,5	999,5	904,8
1447000	0	905,3	828,3	906,9	762,1	438,0	155,6	118,1	237,4	570,9	887,1	912,4	927,0
	1	845,6	765,8	881,5	736,9	418,2	149,1	118,0	218,1	543,0	842,9	855,4	873,7
	2	852,1	771,2	869,9	744,8	428,6	162,7	140,1	221,5	545,5	842,5	864,6	880,6
	3	864,5	789,8	892,2	766,5	447,7	195,6	181,1	248,4	562,3	861,1	888,7	898,7
	4	907,2	829,8	939,3	808,5	508,4	263,3	259,1	310,6	607,7	894,7	929,7	937,9

Como mostrado na Tabela 13, para os meses, nos quais o critério BIC indicou a 1ª ordem, os erros absolutos (E_{abs}) encontrados foram menores (Tabela 12). Mas, em alguns casos como na estação pluviométrica (250000-*RH I*) nos meses de agosto, setembro e dezembro os resultados não foram muito satisfatórios, a causa deste problema pode estar atrelada a limitação do modelo markoviano em representar os fenômenos não estacionários. Diversos autores (Almeida et al. 2017; Gonçalves et al. 2018 e 2016; Penereiro et al. 2018) defendem que a precipitação na região Amazônia sofre influência de eventos não estacionários como o El Niño e La Niña.

Existem situações em que o modelo conseguiu reproduzir de forma eficiente os dias secos e chuvosos, mesmo quando o critério BIC indicava a ordem 0 (zero) e 2ª, como por exemplo, nas estações (1048001) e (83368) na *RH II* (Tabela 13). Neste aspecto, nos cenários de ordem 0 (zero), os resultados gerados foram ainda melhores. Entretanto, em casos de 3ª ordem, os resultados não foram bons.

Li et al. (2014) em simulações de precipitação para a Platô de Loess da China, em um clima semi-árido, também obtiveram resultados similares aos encontrados neste trabalho, aonde os autores mostraram que o modelo de *CM* de 1ª ordem apresentou melhor desempenho que as ordens mais altas. Embora na maioria dos casos, a ocorrência de precipitação diária poderia ser descrita pela modelo de 1ª ordem, no entanto, em alguns outros casos, este modelo não conseguiu ajustar os dados observados.

No contexto dos totais precipitados, percebe-se que o modelo mostrou ótimo desempenho na estimativa de precipitação quando comparados aos dados das séries observadas (Tabela 12), registrando médias de erros absolutos (E_{abs}) de *RH I* (34,47 mm), *RH II* (35,86 mm) e *RH III* (16,91 mm). Esses valores diminuem por dois aspectos: o primeiro está relacionado à qualidade da modelagem das ocorrências, já que alguns dias que não são simulados pelo modelo impactam diretamente no total precipitado, como o exemplo a estação (82765) na *RH II*, já o segundo está relacionado à simulação ineficiente dos eventos máximos de precipitação, como foi o caso da estação (250000) na *RH I*.

5.2.2 Análise de sensibilidade do Modelo em relação ao tamanho da amostra

Seguindo o passo a passo da análise de sensibilidade proposto no (Tópico 4.3.8), foram calculados os coeficientes de Pearson (r), willmont (d) e índice de Camargo (c) para cada ano das três estações selecionadas, conforme descrito na Tabela 14.

Tabela 14 – Análise de sensibilidade do modelo em relação ao tamanho da amostra por RH.

<i>RH I</i>									
Anos	Dias Chuvosos			Dias Secos			Quantidade Precipitada (mm)		
	r	w	C	r	W	C	r	W	C
30	0,9994	0,9996	0,9990	0,9993	0,9994	0,9987	0,9999	0,9997	0,9997
29	0,9990	0,9994	0,9984	0,9993	0,9989	0,9982	0,9994	0,9996	0,9989
28	0,9993	0,9995	0,9987	0,9996	0,9991	0,9987	0,9993	0,9996	0,9990
27	0,9990	0,9994	0,9984	0,9992	0,9985	0,9976	0,9988	0,9994	0,9982
26	0,9983	0,9987	0,9971	0,9990	0,9975	0,9965	0,9988	0,9993	0,9981
25	0,9988	0,9991	0,9979	0,9993	0,9978	0,9972	0,9991	0,9995	0,9987
24	0,9974	0,9987	0,9961	0,9986	0,9981	0,9968	0,9990	0,9994	0,9985
23	0,9971	0,9983	0,9953	0,9983	0,9974	0,9957	0,9920	0,9953	0,9874
22	0,9967	0,9979	0,9946	0,9982	0,9967	0,9949	0,9982	0,9988	0,9970
21	0,9970	0,9979	0,9949	0,9983	0,9963	0,9946	0,9982	0,9986	0,9968
20	0,9963	0,9981	0,9944	0,9978	0,9973	0,9950	0,9980	0,9986	0,9966
19	0,9956	0,9977	0,9933	0,9970	0,9971	0,9942	0,9961	0,9975	0,9936
18	0,9945	0,9972	0,9917	0,9961	0,9965	0,9926	0,9945	0,9961	0,9906
17	0,9859	0,9925	0,9785	0,9937	0,9937	0,9874	0,9931	0,9951	0,9883
16	0,9920	0,9957	0,9878	0,9946	0,9953	0,9899	0,9955	0,9962	0,9917
15	0,9914	0,9946	0,9860	0,9938	0,9930	0,9869	0,9954	0,9950	0,9904
14	0,9949	0,9972	0,9922	0,9968	0,9963	0,9932	0,9966	0,9965	0,9931
13	0,9905	0,9948	0,9854	0,9937	0,9943	0,9880	0,9963	0,9935	0,9898
12	0,9910	0,9949	0,9860	0,9941	0,9941	0,9882	0,9949	0,9935	0,9884
11	0,9859	0,9914	0,9774	0,9900	0,9910	0,9811	0,9903	0,9898	0,9802
10	0,9860	0,9914	0,9776	0,9903	0,9904	0,9807	0,9867	0,9859	0,9728
9	0,9941	0,9949	0,9890	0,9963	0,9925	0,9888	0,9852	0,9849	0,9703
8	0,9856	0,9896	0,9754	0,9899	0,9879	0,9779	0,9814	0,9803	0,9621
7	0,9837	0,9893	0,9732	0,9882	0,9879	0,9762	0,9779	0,9655	0,9442
6	0,9869	0,9902	0,9773	0,9897	0,9875	0,9773	0,9717	0,9456	0,9188
5	0,9737	0,9795	0,9537	0,9768	0,9757	0,9531	0,9398	0,9255	0,8698
4	0,9617	0,9690	0,9320	0,9673	0,9667	0,9351	0,9444	0,9168	0,8658
3	0,8786	0,8836	0,7763	0,8866	0,8829	0,7827	0,8985	0,8949	0,8041
2	0,9621	0,9452	0,9094	0,9649	0,9392	0,9062	0,9082	0,9062	0,8230
1	0,9257	0,8618	0,7978	0,9347	0,8532	0,7975	0,9463	0,9258	0,8761

<i>RH II</i>									
30	1,0000	0,9999	0,9998	1,0000	0,9999	0,9998	1,0000	0,9996	0,9996
29	0,9985	0,9987	0,9972	0,9997	0,9996	0,9993	0,9986	0,9982	0,9968
28	0,9984	0,9983	0,9968	0,9995	0,9997	0,9992	0,9979	0,9969	0,9948
27	0,9983	0,9982	0,9964	0,9996	0,9998	0,9994	0,9976	0,9960	0,9937
26	0,9984	0,9984	0,9968	0,9996	0,9997	0,9993	0,9986	0,9971	0,9957
25	0,9984	0,9985	0,9968	0,9995	0,9996	0,9991	0,9982	0,9975	0,9956
24	0,9982	0,9985	0,9967	0,9993	0,9995	0,9988	0,9979	0,9969	0,9948
23	0,9978	0,9982	0,9960	0,9976	0,9976	0,9951	0,9971	0,9968	0,9939
22	0,9965	0,9978	0,9943	0,9990	0,9992	0,9982	0,9977	0,9959	0,9935

21	0,9973	0,9984	0,9957	0,9990	0,9990	0,9980	0,9964	0,9961	0,9925
20	0,9974	0,9986	0,9960	0,9987	0,9987	0,9974	0,9955	0,9960	0,9916
19	0,9977	0,9985	0,9962	0,9985	0,9988	0,9973	0,9935	0,9937	0,9873
18	0,9962	0,9978	0,9940	0,9976	0,9984	0,9960	0,9900	0,9913	0,9813
17	0,9962	0,9979	0,9941	0,9973	0,9980	0,9954	0,9874	0,9897	0,9772
16	0,9957	0,9977	0,9934	0,9979	0,9981	0,9960	0,9813	0,9872	0,9687
15	0,9797	0,9947	0,9746	0,9980	0,9982	0,9963	0,9797	0,9857	0,9657
14	0,9970	0,9984	0,9954	0,9983	0,9985	0,9968	0,9773	0,9839	0,9616
13	0,9977	0,9986	0,9963	0,9983	0,9987	0,9970	0,9816	0,9858	0,9676
12	0,9981	0,9989	0,9970	0,9985	0,9986	0,9971	0,9795	0,9870	0,9668
11	0,9985	0,9991	0,9976	0,9980	0,9982	0,9962	0,9858	1,0000	0,9858
10	0,9970	0,9981	0,9952	0,9987	0,9987	0,9974	0,9847	0,9891	0,9739
9	0,9952	0,9970	0,9923	0,9975	0,9976	0,9951	0,9678	0,9813	0,9497
8	0,9577	0,9724	0,9313	0,9746	0,9825	0,9576	0,9292	0,9539	0,8864
7	0,9860	0,9920	0,9781	0,9920	0,9938	0,9858	0,9455	0,9677	0,9149
6	0,9860	0,9918	0,9779	0,9920	0,9930	0,9851	0,9288	0,9607	0,8923
5	0,9850	0,9906	0,9757	0,9923	0,9952	0,9875	0,9212	0,9518	0,8768
4	0,9875	0,9912	0,9788	0,9932	0,9950	0,9882	0,9240	0,9551	0,8825
3	0,9755	0,9818	0,9577	0,9866	0,9896	0,9764	0,8201	0,8983	0,7366
2	0,9604	0,9547	0,9169	0,9745	0,9735	0,9486	0,7587	0,8025	0,6088
1	0,8241	0,8858	0,7300	0,8510	0,9123	0,7764	0,6765	0,7657	0,5180

RH III

30	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	0,9999	0,9999
29	0,9999	0,9999	0,9999	0,9999	0,9999	0,9999	0,9996	0,9997	0,9993
28	0,9997	0,9998	0,9996	0,9996	0,9998	0,9994	0,9988	0,9994	0,9982
27	0,9998	0,9999	0,9997	0,9998	0,9999	0,9997	0,9992	0,9995	0,9987
26	0,9997	0,9999	0,9996	0,9998	0,9999	0,9997	0,9989	0,9989	0,9977
25	0,9992	0,9996	0,9988	0,9994	0,9997	0,9990	0,9985	0,9985	0,9970
24	0,9989	0,9994	0,9983	0,9991	0,9995	0,9986	0,9972	0,9979	0,9951
23	0,9989	0,9994	0,9983	0,9990	0,9995	0,9986	0,9969	0,9974	0,9943
22	0,9972	0,9986	0,9958	0,9923	0,9952	0,9876	0,9969	0,9981	0,9950
21	0,9980	0,9990	0,9971	0,9983	0,9992	0,9975	0,9955	0,9965	0,9920
20	0,9973	0,9986	0,9959	0,9977	0,9988	0,9965	0,9934	0,9962	0,9896
19	0,9971	0,9985	0,9955	0,9975	0,9987	0,9962	0,9867	0,9930	0,9798
18	0,9965	0,9980	0,9946	0,9971	0,9983	0,9954	0,9872	0,9934	0,9806
17	0,9964	0,9979	0,9944	0,9969	0,9982	0,9952	0,9818	0,9908	0,9727
16	0,9967	0,9982	0,9949	0,9972	0,9985	0,9957	0,9823	0,9906	0,9731
15	0,9956	0,9969	0,9925	0,9962	0,9974	0,9936	0,9805	0,9899	0,9706
14	0,9968	0,9969	0,9937	0,9972	0,9973	0,9946	0,9841	0,9919	0,9761
13	0,9921	0,9924	0,9847	0,9932	0,9936	0,9869	0,9758	0,9877	0,9638
12	0,9912	0,9903	0,9816	0,9923	0,9918	0,9842	0,9848	0,9919	0,9769
11	0,9924	0,9872	0,9797	0,9935	0,9891	0,9827	0,9741	0,9849	0,9594
10	0,9866	0,9762	0,9631	0,9884	0,9799	0,9686	0,9590	0,9755	0,9354
9	0,9838	0,9684	0,9528	0,9861	0,9734	0,9598	0,9293	0,9572	0,8894
8	0,9766	0,9620	0,9395	0,9799	0,9680	0,9486	0,9186	0,9520	0,8745

7	0,9795	0,9662	0,9464	0,9827	0,9715	0,9547	0,9246	0,9551	0,8831
6	0,9762	0,9770	0,9538	0,9798	0,9806	0,9608	0,9430	0,9673	0,9122
5	0,9503	0,9579	0,9103	0,9570	0,9650	0,9235	0,9040	0,9414	0,8509
4	0,9426	0,9459	0,8916	0,9501	0,9552	0,9075	0,8998	0,9318	0,8385
3	0,8740	0,8714	0,7615	0,8960	0,8925	0,7997	0,8697	0,8999	0,7826
2	0,8812	0,7542	0,6647	0,8996	0,7953	0,7154	0,8279	0,8674	0,7181
1	0,9317	0,6192	0,5769	0,9407	0,6548	0,6159	0,6677	0,7101	0,4741

Sabe-se que o coeficiente de desempenho (C) apresenta valores no intervalo de $0 \leq C \leq 1$, deste modo, quanto mais próximo de 1, maior é o ajuste entre as séries estimadas e observadas. Como critério neste estudo, foi escolhido número de anos no qual, tanto as ocorrências quanto as quantidades precipitadas apresentassem valores iguais ou superiores a 0,95 em relação à série histórica de 30 anos.

Conforme descrito na Tabela 14, as amostras mínimas para as *RH I, II e III* foram de 8, 10 e 11 anos, respectivamente. Portanto, percebe-se que quanto menos úmido é o clima da *RH*, maior é o tamanho da amostra mínima para aplicação do modelo, uma vez que, os climas menos úmidos apresentam maior ocorrência de zeros nas séries históricas de precipitação, tal característica diminuem a capacidade de estimativa das quantidades de precipitações pelas FCPs. As estações pluviométricas com séries históricas inferiores aos limiares estabelecidos aqui, não foram utilizadas neste estudo. Vale ressaltar, que as quantidades de precipitação se mostraram mais sensíveis ao tamanho da amostra, uma vez que o tamanho mínimo das amostras para estimativa das ocorrências, sempre foi menor (Tabela 14).

6 CONCLUSÃO

O modelo estocástico de precipitação pluviométrica desenvolvido mostrou-se eficiente na estimativa de precipitações médias diárias nas três *RH* da *RHTA*. Além disso, o uso de mais de um tipo de FCPs proporcionou ao modelo maior capacidade de estimar as precipitações em diferentes locais e estações do ano. Entretanto, nas áreas fortemente influenciadas por longas séries de estiagem, os resultados não foram satisfatórios.

As *RH* da *RHTA* apresentam estações secas e chuvosas definidas, sendo que na *RH II* e *III* a estação seca vai de maio a setembro, e a chuvosa de novembro a março, sendo os meses de abril e outubro caracterizados como períodos de transição. No caso da *RH I*, a estação seca é prorrogada, ocorrendo de julho a novembro, enquanto a estação chuvosa é iniciada no mês de janeiro e termina em maio, e os meses de transição vão de junho e dezembro.

A localização geográfica e a variabilidade temporal de cada estação pluviométrica mostraram forte relação na determinação dos valores dos parâmetros necessários para definição do processo markoviano e das FCPs em cada *RH*. Além disso, algumas dinâmicas em relação a disposição destes parâmetros dentro de cada *RH* foram evidenciadas, mostrando processos atmosféricos de precipitação na escala diária, que na escala anual e mensal até então eram desconhecidos. Assim, a inclusão dessas características que estão subentendidas na precipitação diária aumenta a eficiência da sua estimativa em locais desprovidos de estações pluviométricas.

Na estimativa da quantidade de precipitação média diária, a função exponencial mista foi a que apresentou melhor aderência aos dados observados de precipitação pluviométrica para as três *RH*. Além disso, o uso da exponencial mista foi essencial para estimativa das precipitações na *RH I*, já que em alguns locais desta região, as demais FCPs não conseguiram capturar os mecanismos físicos geradores de precipitações mais intensas. No entanto, nos casos em que a exponencial mista não obteve o melhor desempenho, sugere-se o uso da distribuição gama, seguida pela distribuição exponencial a dois parâmetros para serem utilizadas como alternativa para a estimativa de precipitação pluviométrica na *RHTA*.

Os resultados gerados neste trabalho poderão ser utilizados como subsídio para criação de novos cenários não observados nas séries históricas de precipitação, além de contribuir como dados de entrada em modelos hidrológicos para a caracterização de estiagens ou cheias. Estas informações irão auxiliar no planejamento e na tomada de decisão de atividades dependentes da precipitação, como por exemplo, as atividades agrícolas e agroindustriais.

7.0 SUGESTÕES E RECOMENDAÇÕES

Como sugestões para trabalhos futuros, deixa-se o seguinte:

- Para as regiões situadas nos Ecótonos, sugere-se testar a aplicação de ordens mais altas da cadeia de Markov, como indicado pelo critério BIC.
- Testar outras FCPs mais flexíveis, como o caso da distribuição híbrida de gama com pareto generalizado utilizada no estudo de Evin et al. (2018) para os casos em que não ocorreram as aderências aos dados observados de precipitação pluviométrica.
- Avaliar as sequências de dias secos e chuvosos consecutivos nas *RH* através da CM aliada a distribuição geométrica ou a distribuição binomial negativa truncada.
- Identificar *RH* de precipitação através da inclusão de mais características de precipitação, tais como: precipitação máxima diária, média diária e comprimento máximo de dias consecutivos não chuvosos e chuvosos.
- Condicionar o modelo proposto às variáveis exógenas para avaliar a sua performance na redução do fenômeno de *overdispersion*.
- O modelo univariado pode ser expandido para um modelo multivariado, ou seja, a estimativa de precipitação média diária para múltiplas localidades utilizando a correlação espacial entre as estações pluviométricas. Para este modelo, aconselha-se utilizar apenas a exponencial mista como distribuição para estimativa das precipitações, visto que, o uso de mais FCPs aumentaria o número de parâmetros a serem estimados.

REFERÊNCIAS

ABAS, N; DAUD, Z. M; YUSOF, F. A comparative study of mixed exponential and Weibull distributions in a stochastic model replicating a tropical rainfall process. **Theoretical and applied climatology**, v. 118, n. 3, p. 597-607, 2014.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Caderno da Região Hidrográfica Tocantins Araguaia**. Ministério do Meio Ambiente, Secretaria de Recursos Hídricos. – Brasília ANA, MMA, 2006.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Conjuntura dos Recursos Hídricos no Brasil**. 2013. Disponível em: www.arquivos.ana.gov.br/institucional/spr/conjuntura/webSite_relatorioConjuntura/projeto/index.html> Acessado em: 04/04/2018.

AGÊNCIA NACIONAL DE ÁGUAS (ANA). **Plano Nacional de Recursos Hídricos da Região Hidrográfica Tocantins Araguaia**. 2009. Disponível:<<http://www.ana.gov.br>> Acesso em: 4 de fevereiro de 2018.

AILLIOT, P; MONBET, V. Markov-switching autoregressive models for wind time series. **Environmental Modelling & Software**, v. 30, p. 92-101, 2012.

AILLIOT, P; THOMPSON, C; THOMSON, P. Space-time modelling of precipitation by using a hidden Markov model and censored Gaussian distributions. **Journal of the Royal Statistical Society: Series C (Applied Statistics)**, v. 58, n. 3, p. 405-426, 2009.

AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automatic Control**, Brookline, AC-19, 6, p. 716-723, 1974.

ALAM, J. A. T. M; RAHMAN, S. M; SAADAT, A. H. M. Monitoring meteorological and agricultural drought dynamics in Barind region Bangladesh using standard precipitation index and Markov chain model. **International Journal of Geomatics and Geosciences**, v. 3, n. 3, p. 511, 2013.

ALMEIDA, C. T; OLIVEIRA-JÚNIOR, J. F; DELGADO, R. C; CUBO, P; RAMOS, M. C. Spatiotemporal rainfall and temperature trends throughout the Brazilian Legal Amazon, 1973–2013. **International Journal of Climatology**, v. 37, n. 4, p. 2013-2026, 2017.

ALVARES, C. A; STAPE, J. L; SENTELHAS, P. C; MORAES, G; LEONARDO, J; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013b.

ALVARES, C. A; STAPE, J. L; GONÇALVES, J. L. M. Modeling monthly mean air temperature for Brazil. **Theoretical and applied climatology**, v. 113, n. 3-4, p. 407-427, 2013a.

ALVES, É. S; SAAD, J. C. C; SCHIMIDT, A. P. R. A; ARAÚJO, L. M; GOMES, M. D. A; SANTOS, J. É. O. Characterization of irrigation system by conventional aspersion sized with economic flow and practice and different hydraulic configurations. **Revista Brasileira de Agricultura Irrigada**, v. 11, n. 8, p. 2172, 2017.

ALY, A; PATHAK, C; TEEGAVARAPU, R. S; AHLQUIST, J; FUELBERG, H. Evaluation of improvised spatial interpolation methods for infilling missing precipitation records. In: **World Environment Water Resources Congress 2009 : Great Rivers**. 2009. p. 1-10.

- ANDRADE JÚNIOR, A. S; FRIZZONE, J. A; BASTOS, E. A; CARDOSO, M. J; RODRIGUES, B. H. N. Estratégias ótimas de irrigação para a cultura da melancia. **Pesquisa Agropecuária Brasileira**, v. 36, p. 301-305, 2001.
- ARAÚJO, E. M; SILVA, I. N; OLIVEIRA, J. B; JUNIOR, E. G. C; ALMEIDA, B. M. Aplicação de seis distribuições de probabilidade a séries de temperatura máxima em Iguatu-CE. **Revista Ciência Agronômica**, v. 41, n. 1, 2010.
- ARAÚJO, W. S; SOUSA, F. D. A. S; BRITO, J. I. B; LIMA, L. M. Aplicação do Modelo Estocástico Cadeia de Markov a Dados Diários de Precipitação dos Estados da Bahia e Sergipe. **Revista Brasileira de Geografia Física**, v. 5, n. 3, p. 509-523, 2012.
- AYALA, L. M; EUPEN, M. V; ZHANG, G; PÉREZ-SOBA, M; MARTORANO, L. G; LISBOA, L. S; BELTRAO, N. E. Impact of agricultural expansion on water footprint in the Amazon under climate change scenarios. **Science of the Total Environment**, v. 569, p. 1159-1173, 2016.
- AZEVEDO, P. V; LEITÃO, M. M. V. B. R. Aplicação de processos em cadeia de Markov às precipitações diárias no estado da Paraíba. **Revista Brasileira de Meteorologia**, São José dos Campos, 5, 1, p. 389-402, 1990.
- BACK, Á. J; MIGUEL, L. P. Analysis of the stochastic model of the Markov chain on daily rainfall occurrence in the state of Santa Catarina, Brazil. **Management of Environmental Quality: An International Journal**, v. 28, n. 1, p. 2-16, 2017.
- BARGAOUI, Z. K; CHEBBI, A. Comparison of two kriging interpolation methods applied to spatiotemporal rainfall. **Journal of Hydrology**, v.365, n. 1-2, p. 56-73, 2009.
- BARKOTULLA, M. A. B. Agricultural drought analysis of Chapai Nawabganj district in Bangladesh. **Journal of Biodiversity and Environmental Sciences (JBES)**. v. 2, n. 9, p. 60-67, 2012.
- BARRON, J; ROCKSTRÖM, J; GICHUKI, F; HATIBU, N. Dry spell analysis and maize yields for two semi-arid locations in east Africa. **Agricultural and forest meteorology**, v. 117, n. 1-2, p. 23-37, 2003.
- BAÚ, A. L; DE AZEVEDO, C. A. V; BRESOLIN, A. A. Modelagem da precipitação pluvial diária intra-anual da Bacia Hidrográfica Paraná III associada aos eventos ENOS. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, v. 17, n. 8, 2013.
- BAXEVANI, A; LENNARTSSON, J. A spatiotemporal precipitation generator based on a censored latent Gaussian field. **Water Resources Research**, v. 51, n. 6, p. 4338-4358, 2015.
- BECERRA, J. A. B; SHIMABUKURO, Y; ALVALÁ, R. Relação do padrão sazonal da vegetação com a precipitação na região de Cerrado da Amazônia Legal, usando índices espectrais de vegetação. **Revista Brasileira de Meteorologia**, v. 24, n. 2, p. 125-134, 2009.
- BEIJO, L. A; MUNIZ, J. A; VOLPE, C. A; PEREIRA, G. T. Estudo da precipitação máxima em Jaboticabal (SP) pela distribuição de Gumbel utilizando dois métodos de estimação dos parâmetros. **Revista Brasileira de Agrometeorologia**, v. 11, n. 1, p.141-147, 2003.
- BIER, A. A; FERRAZ, S. E. T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. **Revista Brasileira de Meteorologia**, v. 32, n. 2, 215-226, 2017.

- BLAIN, G. C; PIEDADE, S. D. S; CAMARGO, M. D; GIAROLLA, A. Distribuição temporal da precipitação pluvial mensal observada no posto meteorológico do instituto agrônomo, em Campinas, SP. **Bragantia**, v. 66, n. 2, p. 347-355, 2007.
- BLANCO, C. J. C; SANTOS, S. S. M; QUINTAS, M. C; VINAGRE, M. V. A; MESQUITA, A. L. A. Contribution to hydrological modelling of small Amazonian catchments: application of rainfall–runoff models to simulate flow duration curves. **Hydrological sciences journal**, v. 58, n. 7, p. 1423-1433, 2013.
- BORGES, G. M. R; THEBALDI, M. S. Estimativa da precipitação máxima diária anual e equação de chuvas intensas para o município de Formiga, MG, Brasil. **Ambiente & Água-An Interdisciplinary Journal of Applied Science**, v. 11, n. 4, 2016.
- BOULANGER, J. P; MARTINEZ, F; PENALBA, O; SEGURA, E. C. Neural network based daily precipitation generator (NNGENP). **Climate Dynamics**, Berlin / Heidelberg, v. 28, p. 307-324, 2007.
- BRAGA, R. N. S; LYRA, G. B; NASCENTES, A. L. Determinação e interpolação dos coeficientes das equações de chuvas intensas para cidade do Rio de Janeiro, **Revista Ambiente e Água**, v. 13, n. 1, 2018.
- BRISSETTE, F. P; KHALILI, M; LECONTE, R. Efficient stochastic generation of multisite synthetic precipitation data. **Journal of Hydrology**, Amsterdam, v. 345, p. 121-133, 2007.
- BUIHAND, T. A; BRANDSMA, T. Multisite simulation of daily precipitation and temperature in the Rhine basin by nearest-neighbor resampling. **Water Resources Research**, Washington, DC, v. 37, n. 11, p. 2761-2776, 2001.
- CALDEIRA, T. L; BESKOW, S; MELLO, C. R; FARIA, L. C; SOUZA, M. R; GUEDES, H. A. Modelagem probabilística de eventos de precipitação extrema no estado do Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, v. 19, n. 3, 2015.
- CALGARO, M; ROBAINA, A. D; PEITER, M. X; BERNARDON, T. Variação espaço-temporal dos parâmetros para a modelagem estocástica da precipitação pluvial diária no Rio Grande do Sul. **Engenharia Agrícola**, v. 29, p. 196-206, 2009.
- CAMARGO, A.P; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo. **Revista Brasileira de Agrometeorologia**, São José dos Campos, v.5, p.89-97, 1997.
- CARGNELUTTI FILHO, A; MATZENAUER, R; TRINDADE, J. K. D. A. Ajustes de funções de distribuição de probabilidade a radiação solar global no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v. 39, n. 12, p. 1157-1166, 2004.
- CARVALHO, A. L. D; SOUZA, J. L. D; LYRA, G. B; WANDERLEY, H. S. Markov Chain Application for Dry and Rainy Days. **Revista Brasileira de Meteorologia**, v. 32, n. 2, p. 207-214, 2017a.
- CARVALHO, J. R. P; MONTEIRO, J. E. B. A; NAKAI, A. M; ASSAD, E. D. Model for Multiple Imputation to Estimate Daily Rainfall Data and Filling of Faults. **Revista Brasileira de Meteorologia**, v. 32, n. 4, p. 575-583, 2017b.

- CASTELLVÍ, F; MORMENEO, I; PEREZ, P. J. Generation of daily amounts of precipitation from standard climatic data: a case study for Argentina. **Journal of Hydrology**, Amsterdam, v. 289, n. 1-4, p. 286-302, 2004.
- CHAI, T; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. **Geoscientific model development**, v. 7, n. 3, p. 1247-1250, 2014.
- CHAPPELL, N. A; JONES, T. D; TYCH, W; KRISHNASWAMY, J. Role of rainstorm intensity underestimated by data-derived flood models: Emerging global evidence from subsurface-dominated watersheds. **Environmental Modelling & Software**, v. 88, p. 1-9, 2017.
- CHATFIELD, C. **The analysis of time series: An introduction**. 6th ed. Chapman & Hall/CRC. Florida, 2004.
- CHEN, J.; BRISSETTE, F. P. Comparison of five stochastic weather generators in simulating daily precipitation and temperature for the Loess Plateau of China. **International Journal of Climatology**, v. 34, n. 10, p. 3089-3105, 2014.
- CHEN, J; BRISSETTE, F. P; LCONTE, R. WeaGETS—a Matlab-based daily scale weather generator for generating precipitation and temperature. **Procedia Environmental Sciences**, v. 13, p. 2222-2235, 2012.
- CHEN, S; SHIN, J. Y; KIM, TAE-WOONG. Probabilistic forecasting of drought: a hidden Markov model aggregated with the RCP 8.5 precipitation projection. **Stochastic Environmental Research and Risk Assessment**, v. 31, n. 5, p. 1061-1076, 2017.
- CHOU, CHIEN-MING. Random modeling of daily rainfall and runoff using a seasonal model and wavelet denoising. **Mathematical Problems in Engineering**, v. 2014, 2014.
- CHRISTOFFERSEN, B. O; RESTREPO-COUBE, N; ARAIN, M. A; BAKER, I. T; CESTARO, B. P; CIAIS, P; FISHER, J. B; GALBRAITH, D; GUAN, X; GULDEN, L; HURK, B. D; ICHII, K; IMBUZEIRO, H; JAIN, A; LEVINE, N; MIGUEZ-MACHO, G; POULTER, B; ROBERTI, D. R; SAKAGUCHI, K; SAHOO, A; SCHAEFER, K; SHI, M; VERBEECK, H; YANG, ZONG-LIANG; ARAÚJO, A. C; KRUIJT, B; MANZI, A. O; ROCHA, H. R; RANDOW, C; MUZA, M. N; BORAK, J; , M. H; GONÇALVES, L. G. G; ZENG, X; SALESKA, S. R. Mechanisms of water supply and vegetation demand govern the seasonality and magnitude of evapotranspiration in Amazonia and Cerrado. **Agricultural and Forest meteorology**, v. 191, p. 33-50, 2014.
- COAN, B. P; BACK, Á. J; BONETTI, A. V. Precipitação mensal e anual provável no Estado de Santa Catarina. **Revista Brasileira de Climatologia**, v. 15, p. 122-142, 2014.
- COLLISCHONN, W; TASSI, R. **Introduzindo hidrologia**, 2008.
- CORREIA, T. P; DOHLER, R. E; DAMBROZ, C. S; BINOTI, D. H. B. Aplicação de redes neurais artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Geociências (São Paulo)**, v. 35, n. 4, p. 560-567, 2016.
- COSTA, C. E. A. S; BLANCO, C. J. C. Influência da Variabilidade Climática sobre a Erosividade em Belém (PA). **Revista Brasileira de Meteorologia**, 2018.
- COSTA, V; FERNANDES, W; NAGHETTINI, M. A Bayesian model for stochastic generation of daily precipitation using an upper-bounded distribution function. **Stochastic Environmental Research and Risk Assessment**. v. 29, n. 2, p. 563-576, 2015.

- DASH, P. R. A Markov Chain modelling of daily precipitation occurrences of Odisha. **International Journal of Advanced Computer and Mathematical Sciences**. v. 3, p 482-486, 2012.
- DASTIDAR, A. G; GHOSH, D; DASGUPTA, S; DE; U. K. Higher order Markov chain models for monsoon rainfall over West Bengal, India. **Indian Journal of Radio & Space Physics**. v. 39, p. 39-44, 2010.
- DEMPSTER, A.P; LAIRD, N. M.; RUBIN, D. B. Maximum likelihood from incomplete data via the EM algorithm, **Journal of the Royal Statistical Society, Series B**, v. 39, n. 1, p. 1-38, 1977.
- DENI, S. M; JEMAIN, A. A; IBRAHIM, K. Fitting optimum order of Markov chain models for daily rainfall occurrences in Peninsular Malaysia. **Theoretical and applied climatology**, v. 97, n. 1-2, p. 109-121, 2009.
- DETZEL, D. H. M; MINE, M. R. M. Generation of daily synthetic precipitation series: analyses and application in La Plata river Basin. **Open Hydrology Journal**, v. 5, p. 69-77, 2011b.
- DETZEL, D. H. M; MINE, M. R. M. Modelagem de quantidades precipitadas em escala diária: Uma análise comparativa. **Revista Brasileira de Recursos Hídricos**, v. 16, n. 2, p. 101-110, 2011a.
- DOURADO NETO, D; ASSIS, J; TIMM, L. C; MANFRON, P. A; SPAROVEK, G; MARTIN, T. N. Ajuste de modelos de distribuição de probabilidade a séries históricas de precipitação pluvial diária em Piracicaba-SP. **Revista Brasileira de Agrometeorologia**, v. 13, n. 2, p. 273-283, 2005.
- FALCK, A. S; VILA, D; TOMASELLA, J; MAGGIONI, V; DINIZ, F. L. Avaliação de um Modelo Estocástico de Erro Multidimensional Aplicado a Estimativas de Precipitação por Satélite. **Revista Brasileira de Meteorologia**, v. 31, n. 1, p. 52-63, 2016.
- FALCK, A. S; MAGGIONI, V; TOMASELLA, J; VILA, D. A; DINIZ, F. L. Propagation of satellite precipitation uncertainties through a distributed hydrologic model: A case study in the Tocantins–Araguaia basin in Brazil. **Journal of Hydrology**, v. 527, p. 943-957, 2015.
- FERREIRA, C. C. M. Estudo do comportamento do período chuvoso em Juiz de Fora–Minas Gerais. **Revista Geonorte**, v. 1, n. 5, p. 953-963, 2012.
- FIGUEIREDO, N. M; BLANCO, C. J. C. Water level forecasting and navigability conditions of the Tapajós River - Amazon – Brazil. **La Houille Blanche**, n. 3, p. 53-64, 2016.
- FOUFOULA-GEORGIU, E; LETTENMAIER, D. P. A Markov renewal model for rainfall occurrences. **Water Resources Research**, v. 23, n. 5, p. 875-884, 1987.
- FRANCISCO, CAMPOS-ARANDA. D. Modelación del proceso precipitación-escorrentamiento mensual por medio de regresiones. **Ingeniería, investigación y tecnología**, v. 15, n. 4, p. 625-636, 2014.
- FRANCISCO, P. R. M; MEDEIROS, R. M; SILVA MELO, V; SANTOS, D. Probabilidades de ocorrência de chuvas para o estado da Paraíba. **Revista Brasileira de Climatologia**, v. 17, 2015.

GENOVEZ, A. M. **Avaliação da regularização de vazões em pequenas bacias com dados esparsos**. Tese (Doutorado em Engenharia Civil) - Universidade de São Paulo, Escola de Engenharia de São Carlos, São Carlos, 1987.

GOMES, E. P; BLANCO, C. J. C; PESSOA, F. C. L. Identification of homogeneous precipitation regions via Fuzzy c-means in the hydrographic region of Tocantins–Araguaia of Brazilian Amazonia. **Applied Water Science**, v. 9, n. 1, p. 6, 2019.

GOMES, E. P; BLANCO, C. J. C; PESSOA, F. C. L. Regionalization of precipitation with determination of homogeneous regions via fuzzy c-means. **Revista Brasileira de Recursos Hídricos**, v. 23, p. 1-19, 2018.

GONÇALVES, M. F; BLANCO, C. J. C; SANTOS, V. C; SANTOS OLIVEIRA, L. L. Homogenous regions and rainfall probability models considering El Niño and La Niña in the State of Pará in the Amazon. **Acta Scientiarum Technology**, v. 40, p. e37742, 2018.

GONÇALVES, M. F; BLANCO, C. J. C; SANTOS, V. C; SANTOS OLIVEIRA, L. L; PESSOA, F. C. L. Identification of Rainfall Homogenous Regions taking into account El Niño and La Niña and Rainfall Decrease in the state of Pará, Brazilian Amazon. **Acta Scientiarum. Technology**, v. 38, n. 2, p. 209-216, 2016.

GREEN, J. R. A model for rainfall occurrence. **Journal of the Royal Statistical Society. Series B (Methodological)**, p. 345-353, 1964.

GRONDONA, M. O; PODESTÁ, G. P; BIDEGAIN, M; MARINO, M; HORDIJ, H. A stochastic precipitation generator conditioned on ENSO phase: a case study in southeastern South America. **Journal of Climate**, v. 13, n. 16, p. 2973-2986, 2000.

HAAN, C. T; ALLEN, D. M; STREET, J. O. A Markov Chain Model of Daily Rainfall. **Water Resources Research**, Washington, DC, v.12, n. 3, p. 443-449, 1976.

HABIBI, B; MEDDI, M; TORFS, P. J; REMAOUN, M; VAN LANEN, H. A. Characterisation and prediction of meteorological drought using stochastic models in the semi-arid Chélif–Zahrez basin (Algeria). **Journal of Hydrology: Regional Studies**, v. 16, p. 15-31, 2018.

Haidar, R. F; FAGG, J. M. F; PINTO, J. R. R; DIAS, R. R; DAMASCO, G; SILVA, L. D. C. R; FAGG, C. W. Florestas estacionais e áreas de ecótono no estado do Tocantins, Brasil: parâmetros estruturais, classificação das fitofisionomias florestais e subsídios para conservação. **Acta Amazonica**, v. 43, n. 3, p. 261-290, 2013.

HANSEN, J. W; INES, A. V. M. Stochastic disaggregation of monthly rainfall data for crop simulation studies. **Agricultural and Forest Meteorology**, v. 131, n. 3-4, p. 233-246, 2005.

HARROLD, T. I; SHARMA, A; SHEATHER, S. J. A nonparametric model for stochastic generation of daily rainfall occurrence. **Water Resources Research**, Washington, DC, v. 39, n. 10, p. 1300, 2003a.

HARROLD, T. I; SHARMA, A; SHEATHER, S. J. A nonparametric model for stochastic generation of daily rainfall amounts. **Water Resources Research**, Washington, DC, v. 39, n. 12, p. 1343, 2003b.

HONG, H; PANAHI, M; SHIRZADI, A; MA, T; LIU, J; ZHU, A. X; KOUGIAS, I; KAZAKIS, N. Flood susceptibility assessment in Hengfeng area coupling adaptive neuro-

fuzzy inference system with genetic algorithm and differential evolution. **Science of The Total Environment**, v. 621, p. 1124-1141, 2017.

HUNDECHA, Y; PAHLOW, M; SCHUMANN, A. Modeling of daily precipitation at multiple locations using a mixture of distributions to characterize the extremes. **Water resources research**, v. 45, n. 12, 2009.

IBGE, Instituto Brasileiro de Geografia e Estatística. *Cobertura do uso da terra do Brasil, 2014*. Disponível em: <https://www.ibge.gov.br/geociencias-novoportal/informacoes-ambientais/cobertura-e-uso-da-terra>.

JIMÉNEZ, K. Q; COLLISCHONN, W. Método de combinação de dados de precipitação estimados por satélite e medidos em pluviômetros para a modelagem hidrológica. **Revista Brasileira de Recursos Hídricos**, v. 20, n. 1, p. 202-217, 2015.

JOHNSON, G. L; HANSON, C. L; HARDEGREE, S. P; BALLARD, E. B. Stochastic weather simulation: Overview and analysis of two commonly used models. **Journal of Applied Meteorology**, v. 35, n. 10, p. 1878-1896, 1996.

JONES, PETER G.; THORNTON, PHILIP K. Spatial and temporal variability of rainfall related to a third-order Markov model. **Agricultural and Forest Meteorology**, v. 86, n. 1-2, p. 127-138, 1997.

KATZ, R. W. Precipitation as a chain-dependent process. **Journal of Applied Meteorology**, Boston, v.16, n. 7, p. 671-676, 1977.

KATZ, R. W; PARLANGE, M. B. Overdispersion phenomenon in stochastic modeling of precipitation. **Journal of Climate**, v. 11, n. 4, p. 591-601, 1998.

KELLER FILHO, T; ASSAD, E. D; LIMA, P. R. S. R. Rainfall homogeneous areas in Brazil. **Pesquisa Agropecuária Brasileira**, v. 40, n. 4, p. 311-322, 2005.

KELLER FILHO, T; ZULLO JUNIOR, J; LIMA, P. R. S. R. Análise da transição entre dias secos e chuvosos por meio da Cadeia de Markov de terceira ordem. **Pesquisa Agropecuária Brasileira**, v. 41, n. 9, p. 1341-1349, 2006.

KIDD, C; HUFFMAN, G. J. Global precipitation measurement. **Meteorological Applications**, v 18, p. 334-353. 2011.

KIST, A; VIRGENS FILHO, J. S. Análise probabilística da distribuição de dados diários de chuva no estado do Paraná. **Ambiente & Água-An Interdisciplinary Journal of Applied Science**, v. 10, n. 1, 2015.

KRUEGER, T; FREER, J; QUINTON, J. N; MACLEOD, C. J; BILOTTA, G. S; BRAZIER, R. E; HAYGARTH, P. M. Ensemble evaluation of hydrological model hypotheses. **Water Resources Research**, v. 46, n. 7, 2010.

LALL, U; RAJAGOPALAN, B; TARBOTON, D. G. A nonparametric wet/dry spell model for resampling daily precipitation. **Water Resources Research**, Washington, DC, v. 32, n. 9, p. 2803-2823, 1996.

Journal of earth system science, v. 124, n. 1, p. 61-70, 2015.

- LEE, H; KANG, K. Interpolation of Missing Precipitation Data Using Kernel Estimations for Hydrologic Modeling. **Advances in Meteorology**, v. 2015, 2015.
- LEONARD, M; LAMBERT, M. F; METCALFE, A. V; COWPERTWAIT, P. S. P. Space-time Neyman–Scott rainfall model with defined storm extent. **Water Resources Research**, v. 44, n. 9, 2008.
- LI, C; SINGH, V. P; MISHRA, A. K. Simulation of the entire range of daily precipitation using a hybrid probability distribution. **Water resources research**, v. 48, n. 3, 2012.
- LI, Z; BRISSETTE, F; CHEN, J. Assessing the applicability of six precipitation probability distribution models on the Loess Plateau of China. **International Journal of Climatology**, v. 34, n. 2, p. 462-471, 2014.
- LI, Z; BRISSETTE, F; CHEN, J. Finding the most appropriate precipitation probability distribution for stochastic weather generation and hydrological modelling in Nordic watersheds. **Hydrological Processes**, v. 27, n. 25, p. 3718-3729, 2013.
- LIAO, Y; ZHANG, Q; CHEN, D. Stochastic modeling of daily precipitation. **Journal of Geographical Sciences**, v. 14, n. 1. p. 417-426, 2004.
- LISBOA, E. G; BLANCO, C. J. C; MAIA, R. O. P; BELLO, L. A. L. A stochastic estimation of sediment production in an urban catchment using the USLE model. **Hydrological Sciences Journal**, v. 62, n. 15, p. 2571-2586, 2017.
- LIU, Y; ZHANG, W; SHAO, Y; ZHANG, K. A comparison of four precipitation distribution models used in daily stochastic models. **Advances in Atmospheric Sciences**, v. 28, n. 4, p. 809-820, 2011.
- LIU, Y; YE, L; QIN, H; HONG, X; YE, J; YIN, X. Monthly streamflow forecasting based on hidden Markov model and Gaussian Mixture Regression. **Journal of Hydrology**, v. 561, p. 146-159, 2018.
- LOUREIRO, G. E; FERNANDES, L. L; ISHIHARA, J. H. Spatial and temporal variability of rainfall in the Tocantins-Araguaia hydrographic region. **Acta Scientiarum. Technology**, v. 37, n. 1, p. 89, 2015.
- LYRA, G. B; GARCIA, B. I. L; PIEDADE, S. M. D. S; SEDIYAMA, G. C; SENTELHAS, P. C. Regiões homogêneas e funções de distribuição de probabilidade da precipitação pluvial no estado de Táchira, Venezuela. **Pesquisa Agropecuária Brasileira**, v. 41, n. 2, p. 205-215, 2006.
- MANDAL, K. G; PADHI, J; KUMAR, A; GHOSH, S; PANDA, D. K; MOHANTY, R. K; RAYCHAUDHURI, M. Analyses of rainfall using probability distribution and Markov chain models for crop planning in Daspalla region in Odisha, India. **Theoretical and applied climatology**, v. 121, n. 3-4, p. 517-528, 2014.
- MARCUZZO, F. F. N; MELO, D. C. D. R; ROCHA, H. M. Distribuição espaço-temporal e sazonalidade das chuvas no Estado do Mato Grosso. **Revista Brasileira de Recursos Hídricos**, v. 16, n. 4, p. 157-167, 2011.
- MARENGO, J. A. Interdecadal Variability and Trends of Rainfall Across the Amazon Basin, **Theoretical and Applied Climatology**, v. 78, n. 1-3, p. 79-96, 2004.

- MARINHO FILHO, G. M; ANDRADE, R. S; ZUKOWSKI, J. C; MAGALHÃES, L. L. Modelos hidrológicos: conceitos e aplicabilidades. **Revista de Ciências Ambientais**, v. 6, n. 2, p. 35-47, 2013.
- MARTIN, T. N; NETO, D. D; JUNIOR, P. A. V; MANFRON, P. A. Homogeneidade espaço temporal e modelos de distribuição para a precipitação pluvial no estado de São Paulo. **Revista Ceres**, v. 55, n. 5, 2008.
- MARTINS, J. A; DALLACORT, R; HIROKO INOUE, M; SANTI, A; KOLLING, E. M; COLETTI, A. J. Probabilidade de precipitação para a microregião de Tangará da Serra, estado do Mato Grosso. **Pesquisa Agropecuária Tropical**, v. 40, n. 3, 2010.
- MATTOS, C. A. C; ABUD, G. M. B; COSTA, N. L; SANTANA, A. C. A competitividade da agroindústria de laticínios: uma investigação no estado do Pará. **Revista em Agronegócio e Meio Ambiente**, v. 10, n. 4, p. 1029-1050, 2017.
- MCMILLAN, H; KRUEGER, T; FREER, J. Benchmarking observational uncertainties for hydrology: rainfall, river discharge and water quality. **Hydrological Processes**, v. 26, n. 26, p. 4078-4111, 2012.
- MEHROTRA, R.; SHARMA, Ashish. A semi-parametric model for stochastic generation of multi-site daily rainfall exhibiting low-frequency variability. **Journal of Hydrology**, v. 335, n. 1-2, p. 180-193, 2007.
- MELLO, C. R; SILVA, A. M. **Hidrologia: Princípios e aplicações em sistemas agrícolas**. Lavras: UFLA, 2013. 455p.
- MELLO, C. R; SILVA, A. M. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.1, p.68-74, 2009.
- MENEZES, F. P; FERNANDES, L. L; ROCHA, E. J. P. O uso da estatística para regionalização da precipitação no Estado do Pará, Brasil. **Revista Brasileira de Climatologia**, v. 16, p. 64-71, 2015.
- MORAIS, A. D; BOTELHO, V. A. V. A; CARVALHO, L. D; MUNIZ, J. A; LAGE, G. Estimativa da precipitação provável em Lavras (MG) através da distribuição Gama. **Revista Brasileira de Agrometeorologia**, v. 9, n. 2, p. 305-310, 2001.
- MORENO-PÉREZ, M. F; WOOLHISER, D. A; ROLDÁN-CAÑAS, J. Effects of parameter perturbation on daily precipitation models in Southern Spain using the NAO index. **International Journal of Climatology**, v. 34, n. 8, p. 2556-2572, 2014.
- MORMENEO, I; CASTELLVI, F. Aplicacion de um modelo em la generación de precipitaciones diarias. **Revista Brasileira de Agrometeorologia**, v. 9, n. 2, p. 311-315, 2001.
- NAGHETTINI, M; PINTO, E. J. A. **Hidrologia estatística**. CPRM, 2007.
- NALBANTIS, I; TSAKIRIS, G. Assessment of hydrological drought revisited. **Water Resources Management**, v. 23, n. 5, p. 881-897, 2009.
- NASCIMENTO, C. E. S; KELMAN, J. Um modelo para geração estocástica de chuvas diárias. **RBE-Caderno de Recursos Hídricos**, v. 13, n. 2, p. 19-36, 1995.

NG, J. L; AZIZ, S. A; HUANG, Y. F; WAYAYOK, A; ROWSHON, M. K. Generation of a stochastic precipitation model for the tropical climate. **Theoretical and Applied Climatology**, p. 1-21, 2017.

OCKENDEN, M. C; TYCH, W; BEVEN, K. J; COLLINS, A. L; EVANS, R; FALLOON, P. D; FORBER, K. J; HISCOCK, K. M; HOLLAWAY, M. J; KAHANA, R; MACLEOD, C. J. A; VILLAMIZAR, M. L; WEARING, C; WITHERS, P. J. A; ZHOU, J. G; BENSKIN, C. MC. W. H; BURKE, S; COOPER, R. J; FREER, J. E; HAYGARTH, P. M. Prediction of storm transfers and annual loads with data-based mechanistic models using high-frequency data. **Hydrology and Earth System Sciences**, v. 21, n. 12, p. 6425, 2017.

OLIVEIRA, L. F; FIOREZE, A. P; MEDEIROS, A. M; SILVA, M. A. Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi**, v. 14, n. 11, 2010.

OLIVEIRA, L. F; JORGE, C. D. A; FIOREZE, A. P; SILVA, M. A. Métodos de estimativa de precipitação máxima para o Estado de Goiás. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, n. 6, p. 620-625, 2008.

OLIVEIRA, V. P. S; ZANETTI, S. S; PRUSKI, F. F. CLIMABR parte II: geração do perfil de precipitação. **Revista brasileira de engenharia agrícola e ambiental**, v. 9, n. 3, 2005.

OLIVEIRA-JÚNIOR, J. F; XAVIER, F. M. G; TEODORO, P. E; GOIS, G; DELGADO, R. C. Cluster analysis identified rainfall homogeneous regions in Tocantins state, Brazil. **Bioscience Journal**, v. 33, n. 2, 2017.

Organização Mundial de Meteorologia - OMM. Guia de Práticas Hidrológicas. Adquisición y Proceso de datos, análisis, predicción y otras aplicaciones. 5ª edição, nª-158, Genebra – Suíça, 1994.

PAIVA, E. M. C. D; CLARKE, R. T. Modelagem estocástica da precipitação na Amazônia. **Revista Brasileira de Recursos Hídricos**, v. 2, n. 2, p. 157-171, 1997.

PAPALEXIOU, S. M.; KOUTSOYIANNIS, D. A global survey on the seasonal variation of the marginal distribution of daily precipitation. **Advances in Water Resources**, v. 94, p. 131-145, 2016.

PAPALEXIOU, S. M; KOUTSOYIANNIS, D. Battle of extreme value distributions: A global survey on extreme daily rainfall. **Water Resources Research**, v. 49, n. 1, p. 187-201, 2013.

PAPALEXIOU, S. M; KOUTSOYIANNIS, D. Entropy based derivation of probability distributions: A case study to daily rainfall. **Advances in Water Resources**, v. 45, p. 51-57, 2012.

PEDRON, I. T; KLOSOWSKI, E. S. Distribuição de frequência de chuvas diárias no Estado do Paraná. **Scientia Agraria Paranaensis**, p. 55-63, 2008.

PENEREIRO, J. C; BADINGER, A; MACCHERI, N. A; MESCHIATTI, M. C. Distributions of Seasonal Average Temperature and Precipitation Trends in Brazilian Biomes. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 97-113, 2018.

PIZZATO, J. A; DALLACORT, R; TIEPPO, R. C; MODOLO, A. J; CREMON, C; MOREIRA, P. S. P. Distribuição e probabilidade de ocorrência de precipitação em Cáceres (MT). **Pesquisa Agropecuária Tropical**, Goiânia, v. 42, n. 2, p. 137-142, 2012.

QUINTAS, M. C; BLANCO, C. J. C; MESQUITA, A. L. A. A non-linear rainfall-runoff model applied to Amazon small catchments with limited data to simulate the flow duration curves. **International Journal of Hydrology Science and Technology**, v. 1, n. 1-2, p. 19-36, 2011.

RACSKO, P; SZEIDL, L; SEMENOV, M. A serial approach to local stochastic weather models. **Ecological modelling**, v. 57, n. 1-2, p. 27-41, 1991.

RAJAGOPALAN, B; LALL, U; TARBOTON, D. G. Nonhomogeneous Markov model for daily precipitation. **Journal of Hydrologic Engineering**, v. 1, n. 1, p. 33-40, 1996.

RASMUSSEN, P. F. Multisite precipitation generation using a latent autoregressive model. **Water Resources Research**, v. 49, n. 4, p. 1845-1857, 2013.

RICHARDSON, C. W. Stochastic Simulation of Daily Precipitation, Temperature, and Solar Radiation. **Water Resources Research**, Washington, DC, v.17, n.1, p. 182-190, 1981.

RICKLI, L.I.; CATANEO, A.; VIRGENS FILHO J.S.V. Comparação de Três Métodos para Estimativa dos Parâmetros da Distribuição Gama em dados Diários de Precipitação Pluviométrica. **Revista Energia na Agricultura**, Botucatu. v.23, n.2, 2008, p.53-61.

ROCHA FILHO, J. V. **Gerador estocástico de precipitação diária bipartido condicionado às fases Enos aplicado à região sul do Brasil**. Dissertação de Mestrado – Universidade Federal de Minas Gerais. Programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos, Belo Horizonte, 2016.

ROLDÁN, J; WOOLHISER, D. A. Stochastic Daily Precipitation Models - 1. A Comparison of Occurrence Processes. **Water Resources Research**, Washington, DC, v. 18, 5, p. 1451-1459, 1982.

ROLDÁN, J; WOOLHISER, D. A. Stochastic Daily Precipitation Models - 1. A Comparison of Occurrence Processes. **Water Resources Research**, Washington, DC, v. 18, n. 5, p. 1451-1459, 1982a.

ROLIM, G. D. S; CAMARGO, M. B. P. D; LANIA, D. G; MORAES, J. F. L. D. Climatic classification of Köppen and Thornthwaite systems and their applicability in the determination of agroclimatic zoning for the state of São Paulo, Brazil. **Bragantia**, v. 66, n. 4, p. 711-720, 2007.

SANTOS, C. A. C; BRITO, J. I. B; RAO, T. V. R; MENEZES, H. E. A. Tendências dos índices de precipitação no Estado do Ceará. **Revista Brasileira de Meteorologia**, v. 24, p. 39-47, 2009.

SANTOS, R. F; BASSEGIO, D. Comportamento histórico da precipitação e ocorrências de dias secos e chuvosos em Cascavel, Paraná. **Revista Thêma et Scientia**, v. 1, n. 1, p. 172-181, 2011.

SANTOS, R. S; VIEIRA, P. D; EVANGELISTA, D. H. R; OLIVEIRA, L. J. C; NONATO, D. Caracterização de extremos mensais de precipitação em Cacoal (RO). **Revista Brasileira de Climatologia**, v. 22, p. 267-280, 2018.

SANTOS, S; BRAGA, C. C; SANSIGOLO, C. A; SANTOS, A. Determinação de regiões homogêneas do índice de precipitação normalizada (SPI) na Amazônia Oriental. **Revista Brasileira de Meteorologia**, v. 32, n. 1, p. 111-122, 2017b.

- SANTOS, V. C. **Probabilidade de ocorrência de chuvas e sua variação espacial e temporal na Bacia Hidrográfica do Rio Tapajós**. Dissertação de Mestrado – Universidade Federal do Pará. Instituto de Tecnologia. Programa de Pós-Graduação em Engenharia Civil, Belém, 2017a.
- SANUSI, W; JEMAIN, A. A; ZIN, W. Z. W; ZAHARI, M. The drought characteristics using the first-order homogeneous Markov chain of monthly rainfall data in peninsular Malaysia. **Water resources management**, v. 29, n. 5, p. 1523-1539, 2015.
- SARMAH, T; DAS, S. Urban flood mitigation planning for Guwahati: a case of Bharalu basin. **Journal of environmental management**, v. 206, p. 1155-1165, 2018.
- SCHWARZ, G. Estimating the Dimension of a Model. **The Annals of Mathematical Statistics**, Bethesda, v. 6, n. 2, p. 461-464, 1978.
- SEDIYAMA, G. C; MELO, J. S. P; ALVES, A. R; COELHO, D. T. Dependência temporal e espacial das probabilidades de dias secos e, ou, chuvosos em dias consecutivos, para intervalos mensais. **Revista Ceres**, v. 43, n. 247, p. 267-280, 1996.
- SELKER, J. S; HAITH, D. A. Development and Testing of Single-Parameter Precipitation Distributions. **Water resources research**, v. 26, n. 11, p. 2733-2740, 1990.
- SEMENOV, M. A; BROOKS, R. J; BARROW, E. M; RICHARDSON, C. W. Comparison of the WGEN and LARS-WG stochastic weather generators for diverse climates. **Climate Research**, Oldendorf/Luhe, v. 10, p. 95-107, 1998.
- SEMENOV, M. A. Simulation of weather extreme events by stochastic weather generator. **Climate Research**, Oldendorf/Luhe, v. 35, p. 203-212, 2008.
- SHARMA, T. C. A Markov-Weibull rain-sum model for designing rain water catchment systems. **Water resources management**, v. 10, n. 2, p. 147-162, 1996.
- SHOAIB; SHAMSELDIN, A. Y; MELVILLE, B. W. Comparative study of different wavelet based neural network models for rainfall–runoff modeling. **Journal of hydrology**, v. 515, p. 47-58, 2014.
- SILVA, F. B; SANTOS, J. R. N., FEITOSA, F. E. C. S; SILVA, I. D. C; ARAÚJO, M. D; GUTERRES, C. E; SANTOS, J. S; RIBEIRO, C. V; BEZERRA, D. S; NERES, R. L. Evidências de mudanças climáticas na região de transição Amazônia-Cerrado no estado do Maranhão. **Revista Brasileira de Meteorologia**, v. 31, n. 3, p. 330-336, 2016.
- SILVA, Í. N; OLIVEIRA, J. B; FONTES, L. O; ARRAES, F. D. D. Distribuição de frequência da chuva para região Centro-Sul do Ceara, Brasil. **Revista Ciência Agronômica**, v. 44, n. 3, p. 481, 2013.
- SILVA, J. C; HELDWEIN, A. B; MARTINS, F. B; TRENTIN, G; GRIMM, E. L. Análise de distribuição de chuva para Santa Maria, RS. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 11, n. 1, p. 67-72, 2007.
- SILVA, M. A. V; FERREIRA, W. P. M; ANDRADE, V. M. S; ARAUJO, S. G. A. Época de semeadura do milho para a região de Sete Lagoas, MG, baseada na probabilidade de ocorrência de períodos secos e chuvosos. **Ceres**, v. 57, n. 4, 2010.
- SILVA, V. S. V. **Estimativa de precipitação pontual em diferentes escalas para uso em modelo concentrado chuva-vazão**. Dissertação (Mestrado em Recursos Hídricos e

Saneamento Ambiental) - Instituto de Pesquisas Hidráulicas, Instituto de Pesquisas Hidráulicas, Porto Alegre, 2011.

SOARES, A. S. D; PAZ, A. R; PICCILLI, D. G. A. Assessment of rainfall estimates of TRMM satellite on Paraíba state. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 2, p. 288-299, 2016.

SONNADARA, D. U. J.; JAYEWARDENE, D. R. A Markov chain probability model to describe wet and dry patterns of weather at Colombo. **Theoretical and applied climatology**, v. 119, n. 1-2, p. 333-340, 2014.

SOUSA, A. M. L; ROCHA, E. J. P; VITORINO, M. I; SOUZA, P. J. O; BOTELHO, M. N. Variabilidade Espaço-Temporal da Precipitação na Amazônia Durante Eventos Enos. **Revista Brasileira de Geografia Física**, v. 8, n^a 1, p.013-024, 2015.

SOUZA, E. B; FERREIRA, D. B. S; GUIMARÃES, J. T. F; FRANCO, V. S; AZEVEDO, F. T. M; MORAES, B. C. Padrões climatológicos e tendências da precipitação nos regimes chuvoso e seco da Amazônia oriental. **Revista Brasileira de Climatologia**, v. 21, p. 81-93, 2017.

SRIKANTHAN, R; HARROLD, T. I; SHARMA, A; MCMAHON, T. Comparison of two approaches for generation of daily rainfall data. **Stochastic Environmental Research and Risk Assessment**, Berlin / Heidelberg, v. 19, p. 215-226, 2005.

SPERA, S. A; GALFORD, G. L; COE, M. T; MACEDO, M. N; MUSTARD, J. F. Land-use change affects water recycling in Brazil's last agricultural frontier. **Global change biology**, v. 22, n. 10, p. 3405-3413, 2016.

STEPHENS, M. A. EDF statistics for goodness of fit and some comparisons. **Journal of the American statistical Association**, v. 69, n. 347, p. 730-737, 1974.

STOWASSER, M. Modelling rain risk: a multi-order Markov chain model approach. **The Journal of Risk Finance**, v. 13, p. 45 – 60, 2012.

SUHAILA, J; CHING-YEE, K; FADHILAH, Y; HUI-MEAN, F. Introducing the mixed distribution in fitting rainfall data. **Open Journal of Modern Hydrology**, v. 1, n. 02, p. 11, 2011.

SZYNISZEWSKA, A. M; WAYLEN, P. R. Determining the daily rainfall characteristics from the monthly rainfall totals in central and northeastern Thailand. **Applied Geography**, v. 35, p. 377-393, 2012.

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, n. 1, p. 191-206, 2005.

TEIXEIRA-GANDRA, C. F. A. et al. Cadeia de Markov no preenchimento de falhas de dados diários de precipitação no RS. **Magistra**, v. 28, n. 2, p. 157-167, 2016.

TEIXEIRA-GANDRA, C. F. A; DAMÉ, R. C. F; SILVA, G. M. Stochastic modeling using Markov chain on the forecast standardized precipitation index. **Científica**, v. 45, n. 2, p. 137-144, 2017.

THOM, H. C. S. A note on the gamma distribution. **Monthly Weather Review**, v. 86, p. 117-22, 1958.

- TODOROVIC, P; WOOLHISER, D. A. A Stochastic Model of n-Day Precipitation. **Journal of Applied Meteorology**, Boston, v.14, n. 1, p. 17-24, 1975.
- TSAKIRIS, G. Stochastic modelling of rainfall occurrences in continuous time. **Hydrological sciences journal**, v. 33, n. 5, p. 437-447, 1988.
- TUCCI, C. E. M. Ciclo hidrológico e bacia hidrográfica. In: TUCCI, C. E. M. (org.). **Hidrologia: ciência e aplicação**. 4.ed. Porto Alegre: ABRH/UFRGS, p. 35-40, 2015.
- VALENTE, C. R; LATRUBESSE, E. M; FERREIRA, L. G. Relationships among vegetation, geomorphology and hydrology in the Bananal Island tropical wetlands, Araguaia River basin, Central Brazil. **Journal of South American Earth Sciences**, v. 46, p. 150-160, 2013.
- VASCONCELLOS, S. L. B; ANDRÉ, R. G. B; PERECIN, D. Probabilidade de ocorrência de dias secos para a região de Jaboticabal-SP. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 11, n. 2, p. 321-325, 2003.
- VIALI, L. **Testes de hipóteses paramétricos e não paramétricos**. Instituto de Matemática. Departamento de Estatística. UFRGS, p. 43, 2008.
- VIANA, T. V. D. A; AZEVEDO, B. M. D; BONFIM, G. V. D; ANDRADE JUNIOR, A. S. D. Probabilidade de ocorrência de períodos secos e chuvosos, em Pentecoste, CE. **Irriga (Botucatu)**, Botucatu, v. 7, n. 3, p. 226-229, 2002.
- VIEIRA, J. P. G; SOUZA, M. J. H; TEIXEIRA, J. M; CARVALHO, F. P. Estudo da precipitação mensal durante a estação chuvosa em Diamantina, Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.7, 2010.
- WAN, H; ZHANG, X; BARROW, E. M. Stochastic modelling of daily precipitation for Canada. **Atmosphere-Ocean**, v. 43, n. 1, p. 23-32, 2005.
- WANG, S; WANG, H. Extending the Rational Method for assessing and developing sustainable urban drainage systems. **Water research**, v. 144, p. 112-125, 2018.
- WANDERLEY, H. S; AMORIM, R. F. C; CARVALHO, F. O. variabilidade espacial e preenchimento de falhas de dados pluviométricos para o estado de alagoas. **Revista Brasileira de Meteorologia**, v.27, n.3, 347 - 354, 2012.
- WESTIN, F. F; SANTOS, M. A; MARTINS, I. D. Hydropower expansion and analysis of the use of strategic and integrated environmental assessment tools in Brazil. **Renewable and Sustainable Energy Reviews**, v. 37, p. 750-761, 2014.
- WILKS, D. S. Interannual variability and extreme-value characteristics of several stochastic daily precipitation models. **Agricultural and Forest Meteorology**, v. 93, n. 3, p. 153-169, 1999.
- WILKS, D. S. Multisite generalization of a daily stochastic precipitation generation model. **Journal of Hydrology**, v. 210, n. 1-4, p. 178-191, 1998.
- WILKS, D. S. Statistical Methods in the atmospheric sciences second edition. **International geophysics series**, v. 91, 2006.
- WILKS, D. S; WILBY, R. L. The weather generation game: a review of stochastic weather models. **Progress in physical geography**, v. 23, n. 3, p. 329-357, 1999.

WOOLHISER, D. A. Combined effects of the Southern Oscillation index and the Pacific decadal oscillation on a stochastic daily precipitation model. **Journal of Climate**, v. 21, n. 5, p. 1139-1152, 2008.

WOOLHISER, D. A; PEGRAM, G. G. S. Maximum likelihood estimation of Fourier coefficients to describe seasonal variations of parameters in stochastic daily precipitation models. **Journal of Applied Meteorology**, v. 18, n. 1, p. 34-42, 1979.

WOOLHISER, D. A; ROLDÁN, J. Stochastic Daily Precipitation Models - 2. A Comparison of Distribution Amounts. **Water Resources Research**, Washington, DC, v.18, n. 5, p. 1461-1468, 1982b.

WUNSCH, A; LIESCH, T; BRODA, S. Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX). **Journal of Hydrology**, 2018.

XINCHUN, C; MENG YANG, W; RUI, S; LA, Z; DAN, C; GUANGCHENG, S; XIANGPING, G; WEIGUANG, W; SHUHAI, T. Water footprint assessment for crop production based on field measurements: A case study of irrigated paddy rice in East China. **Science of the Total Environment**, v. 610, p. 84-93, 2018.

XU, Z; ZHAO, Y; DONG, X; DU, P. Assessing Cost-Effectiveness of Different System Structural Characteristics in Enhancing Resilience of Urban Drainage Systems. In: **International Conference on Urban Drainage Modelling**. Springer, Cham, 2018. p. 485-489.

YOO, C; LEE, J; RO, Y. Markov chain decomposition of monthly rainfall into daily rainfall: Evaluation of climate change impact. **Advances in Meteorology**. Article ID 7957490, 10 pages, 2016.

ZAKARIA, N. Z; DENI, S. M. Application of Alternative Geometric Distribution and Markov Chain Models for Fitting Sequences of Wet and Dry Days in Peninsular Malaysia. **International Journal of Engineering and Management Research (IJEMR)**, v. 6, n. 1, p. 110-119, 2016.

ZERI, M; CUNHA-ZERI, G; GOIS, G; LYRA, G. B; OLIVEIRA-JÚNIOR, J. F. Exposure assessment of rainfall to interannual variability using the wavelet transform. **International Journal of Climatology**, v. 39, n. 1, p. 568-578, 2018.

ZHANG, J. C; DEANGELIS, D. L; ZHUANG, J. Y. Theory and practice of soil loss control in eastern China. **Springer Science & Business Media**, 2011.

APÊNDICES

Apêndice A-Estações pluviométricas selecionados com limiar de 1,8% de falhas.

ID	CÓD.	ESTAÇÕES	LAT.	LONG.	INICIO	FINAL	ANOS	(%)
E1	1346007	FAZENDA PRAINHA	-13,31	-46,06	01/10/1982	04/03/1995	12,43	0,94
E2	1451000	ARUANÃ	-14,93	-51,08	13/05/1970	31/12/2006	36,66	1,65
E3	1350000	BANDEIRANTES	-13,69	-50,80	22/09/1973	31/12/2006	33,30	1,01
E4	1551000	BRITÂNIA	-15,25	-51,16	19/09/1973	31/12/2006	33,30	1,59
E5	1346004	CAMPOS BELOS	-13,04	-46,78	23/01/1974	31/12/1991	18,78	1,006
E6	1449003	CRIXAS	-14,53	-49,96	28/01/1983	31/12/2006	23,94	1,37
E7	1446000	DAMIANÓPOLIS	-14,56	-46,18	07/01/1969	30/04/1980	11,32	0
E8	1652003	DOVERLÂNDIA	-16,72	-52,32	01/01/1989	31/12/2006	18,01	0,03
E9	1349003	ENTRONCAMENTO SÃO MIGUEL	-13,10	-49,20	16/10/1974	29/09/1990	15,96	0,085
E10	1346002	FAZENDA INGAZEIRO	-13,69	-46,57	01/01/1969	30/04/1988	19,34	1,31
E11	1250000	FAZENDA PIRATININGA	-12,82	-50,34	24/09/1973	17/02/1990	16,41	0,8
E12	1447001	FLORES DE GOIÁS	-14,45	-47,05	01/10/1970	31/01/1991	20,35	0,41
E13	1450002	GOVERNADOR LEÔNINO	-14,10	-50,33	18/08/1976	31/12/2006	30,39	1,09
E14	1651001	IPORÁ	-16,43	-51,08	15/09/1973	28/02/1997	23,47	0,49
E15	1549002	ITAPURANGA	-15,56	-49,94	16/01/1969	31/12/2007	38,98	0,26
E16	1550001	JEROAQUARA	-15,37	-50,50	16/05/1973	30/11/2006	33,56	1,54
E17	1450000	LAGOA DA FLECHA	-14,33	-50,73	27/09/1973	30/09/1993	20,02	0,39
E18	1549009	URUANA	-15,50	-49,69	22/09/1971	31/12/1994	23,29	0,36
E19	1549000	UHE SERRA DA MESA CERES	-15,28	-49,55	01/01/2000	31/12/2011	12,01	0,02
E20	1550002	TRAVESSÃO	-15,54	-50,70	16/01/1981	31/12/2006	25,97	1,37
E21	1346005	SÃO VICENTE	-13,55	-46,47	20/10/1974	18/09/1990	15,92	0,34
E22	1651003	SÃO FERREIRA	-16,31	-51,47	01/10/1973	31/12/2006	33,27	0,21
E23	1346000	SÃO DOMINGOS	-13,40	-46,32	01/01/1969	31/12/1994	26,01	0,98
E24	1449002	SANTA TEREZINHA DE GOIÁS	-14,43	-49,72	25/09/1973	31/12/2006	33,29	0,92
E25	1551003	SANTA FÉ	-15,77	-51,10	18/09/1973	31/12/2006	33,22	1,17
E26	1348001	SAMA	-13,53	-48,23	01/01/1969	31/12/1994	26,01	1,34
E27	1350001	RIO PINTADO(FAZ.PONTAL)	-13,53	-50,19	01/01/1976	31/12/1987	12,01	0,22
E28	1349002	PORANGATU(DESCOBERTO)	-13,41	-49,16	22/01/1974	20/01/1991	17,01	0,46
E29	1449000	PILAR DE GOIÁS	-14,76	-49,58	14/08/1973	31/12/2007	34,40	0,24
E30	1349001	NOVO PLANALTO	-13,24	-49,50	21/09/1973	29/02/1992	18,45	0
E31	1346001	NOVA ROMA(FAZ.SUCURI)	-13,74	-46,88	01/11/1970	31/12/1991	21,18	0,77
E32	1549004	NOVA AMÉRICA	-15,02	-49,89	15/08/1980	31/12/2006	26,39	1,03
E33	1450001	MOZARLÂNDIA(CHAC. FOGUEIRA)	-14,74	-50,58	18/01/1974	31/10/2006	32,81	1,27
E34	1346003	MONTE ALEGRE DE GOIÁS	-13,09	-46,89	01/01/1969	31/12/1987	19,01	1,08
E35	747000	CAROLINA	-7,32	-47,46	01/10/1969	31/01/1992	22,35	0,96
E36	1452004	ÁGUA BOA	-14,08	-52,15	23/02/1994	30/11/2007	13,78	0,079
E37	1452000	XAVANTINA	-14,67	-52,35	19/12/1968	30/04/1989	20,38	0,41
E38	1652002	TORIXOREU	-16,20	-52,55	28/11/1974	31/07/1991	16,68	1,51
E39	1552002	TORIQUEJE	-15,25	-53,06	23/03/1971	30/09/1986	15,53	1,07

E40	1653000	TESOURO	-16,08	-53,55	25/04/1971	29/02/1988	16,86	0,17
E41	1150001	SÃO FÉLIX DO ARAGUAIA	-11,62	-50,66	01/02/1974	30/04/1989	15,25	0,017
E42	1250001	SANTO ANTÔNIO DO LEVERGER	-12,29	-50,97	04/09/1969	31/12/1988	19,34	0,53
E43	1652001	PONTE BRANCA	-16,77	-52,84	15/08/1973	31/05/1990	16,80	0,065
E44	1552006	PINDAÍBA	-15,04	-52,24	01/09/1992	31/12/2006	14,34	0,11
E45	1653002	GUIRATINGA	-16,35	-53,76	19/06/1969	31/08/1990	21,21	0
E46	1552001	GENERAL CARNEIRO	-15,71	-52,75	01/01/1990	31/12/2006	13,84	0
E47	1653005	CAFELÂNDIA DO LESTE	-16,67	-53,45	18/11/1992	11/04/2006	13,40	0,75
E48	950001	BARREIRA DO CAMPO	-9,23	-50,21	01/12/1992	31/10/2006	13,92	0
E49	649002	ELDORADO	-6,11	-49,38	01/11/1991	30/11/2006	15,09	0
E50	650001	FAZENDA CAIÇARA	-6,82	-50,54	10/10/1991	30/11/2006	15,15	1,44
E51	350000	FAZENDA ESTRELA DO NORTE	-3,87	-50,46	01/09/1992	31/07/2006	13,92	0,551
E52	348001	FAZENDA MARINGA	-3,15	-48,09	25/11/1990	31/12/2002	12,11	1,47
E53	649001	FAZENDA SANTA ELISA	-6,79	-49,55	27/02/1984	31/12/2006	22,86	0,011
E54	649000	FAZENDA SURUBIM	-6,43	-49,42	25/02/1984	31/12/2006	22,86	0,39
E55	549008	ITUPIRANGA	-5,13	-49,32	01/10/1993	31/12/2006	13,26	0,22
E56	549007	KM 60 PA-150	-5,80	-49,18	17/01/1988	30/11/2006	18,88	0,69
E57	549002	MARABÁ	-5,37	-49,13	29/05/1976	30/06/1998	21,93	0,84
E58	850000	REDENÇÃO	-8,04	-50,00	07/03/1984	31/12/2006	22,83	0,13
E59	448000	RONDON DO PARÁ	-4,80	-48,07	23/08/1980	30/09/2005	25,12	1,71
E60	650002	SERRA DOS CARAJÁS	-5,93	-50,07	01/04/1985	30/11/2006	21,68	0,44
E61	949000	ABREULÂNDIA	-9,62	-49,16	30/08/1973	31/01/1992	18,43	0,46
E62	1147000	ALMAS	-11,58	-47,17	20/09/1973	30/09/2006	33,05	0,75
E63	1249000	ALVORADA	-12,48	-49,12	16/12/1971	29/02/1992	20,22	1,4
E64	648001	ANANAS	-6,36	-48,07	24/08/1974	29/02/1992	17,53	1,56
E65	849002	ARAGUACEMA(CHAC. ARAGUAIA)	-8,80	-49,56	01/12/1992	31/10/2006	13,93	0
E66	1249001	ARAGUAÇU	-12,93	-49,83	23/09/1973	29/02/1992	18,45	0
E67	548000	ARAGUATINS	-5,65	-48,13	01/12/1992	30/06/2006	13,59	0
E68	749000	ARAPOEMA	-7,66	-49,07	01/11/1992	31/12/2006	14,17	0
E69	1246001	AURORA DO NORTE	-12,71	-46,41	28/08/1973	31/12/1994	21,36	1,18
E70	749001	BOA VISTA DO ARAGUAIA	-7,32	-49,22	01/11/1992	30/06/2006	12,02	0,62
E71	847002	CAMPOS LINDOS	-7,97	-46,81	01/12/1992	31/12/2006	14,09	0,038
E72	950000	CASEARA	-9,27	-49,96	01/12/1992	31/10/2006	13,92	0,33
E73	848000	COLINAS DO TOCANTINS	-8,05	-48,48	16/12/1971	31/01/1992	20,14	0,91
E74	1248001	COLONHA	-12,39	-48,71	26/08/1974	30/09/1989	15,11	1,45
E75	748001	COLÔNIA	-7,88	-48,88	30/09/1973	31/01/1992	18,35	1,04
E76	1247000	CONCEIÇÃO DO TOCANTINS	-12,23	-47,32	25/08/1973	31/12/1994	21,36	0,051
E77	1146000	DIANÓPOLIS	-11,63	-46,81	07/12/1971	12/12/1987	16,02	0,25
E78	949001	DOIS IRMÃOS DO TOCANTINS	-9,26	-49,06	01/12/1992	31/08/2006	13,76	0
E79	1149000	DUERE	-11,34	-49,27	01/09/1973	29/02/1992	18,51	0,68
E80	1048000	FÁTIMA	-10,76	-48,90	11/12/1971	30/06/1991	19,56	0,77
E81	1148000	FAZENDA LOBEIRA	-11,53	-48,29	05/08/1969	30/09/2006	37,18	1,47
E82	1150000	FAZENDA TELESFORO	-11,92	-50,67	25/08/1969	05/11/1980	11,21	1,68
E83	1149001	FORMOSO DO ARAGUAIA	-11,80	-49,53	22/09/1973	29/02/1992	18,45	0,029
E84	747001	GOIATINS	-7,71	-47,32	21/11/1971	31/01/1992	20,21	0,067

E85	848001	GUARAI	-8,83	-48,82	22/11/1992	31/12/2006	14,12	1,76
E86	1149002	GURUPI	-11,74	-49,14	16/12/1971	31/08/1989	17,72	0,44
E87	847001	ITACAJA	-8,39	-47,76	28/08/1973	31/12/2006	33,36	0,11
E88	547002	ITAGUATINS	-5,72	-47,50	25/09/1969	31/08/1990	20,95	0,79
E89	848002	ITAPORÁ DO TOCANTINS	-8,57	-48,69	01/11/1992	30/11/2006	14,09	0,019
E90	1047000	JATOBÁ (FAZENDA BOA NOVA)	-9,99	-47,48	16/08/1973	31/07/1993	19,97	0,98
E91	946003	LIZARDA	-9,60	-46,67	29/01/1984	31/12/2006	22,94	0,023
E92	947001	MANSINHA	-9,46	-47,33	22/01/1983	31/12/2006	23,96	0,14
E93	948000	MIRACEMA DO TOCANTINS	-9,56	-48,39	29/08/1969	31/12/2006	37,36	0,98
E94	748003	MURICILÂNDIA	-7,15	-48,60	01/11/1992	30/06/2006	13,67	0,1
E95	1147001	NATIVIDADE	-11,70	-47,73	21/08/1973	26/10/1995	22,19	1,37
E96	1047001	NOVO ACORDO	-9,96	-47,67	10/12/1971	15/10/1990	18,86	0,81
E97	1048001	PARAÍSO DO TOCANTINS	-10,17	-48,89	13/12/1971	31/08/2006	34,74	1,7
E98	1348002	PCH ENGENHO NOVO SÃO FÉLIX	-13,53	-48,14	17/03/1974	31/05/1990	16,22	0
E99	1248000	PEIXE	-12,03	-48,54	11/03/1970	31/10/1985	15,65	1,48
E100	1147002	PINDORAMA DO TOCANTINS	-11,14	-47,58	28/09/1973	31/12/2006	33,28	0
E101	648002	PIRAQUÊ	-6,67	-48,47	27/03/1975	31/10/1987	12,61	1,49
E102	1246000	PONTE ALTA DO BOM JESUS	-12,09	-46,48	17/01/1978	31/12/1994	16,96	0,096
E103	1147003	PORTO ALEGRE	-11,61	-47,05	26/08/1975	31/12/1989	14,36	0
E104	1047002	PORTO GILÂNDIA	-10,76	-47,76	01/01/1971	31/12/2006	36,02	1,76
E105	649003	PORTO LEMOS	-6,87	-49,10	01/11/1992	30/06/2006	13,67	0
E106	948001	PORTO REAL	-9,31	-47,93	16/09/1969	31/12/2006	37,32	1,28
E107	1249002	PROJETO RIO FORMOSO	-11,84	-49,77	06/12/1980	29/02/1992	11,24	0,68
E108	1247002	RIO DA PALMA (FAZ. CHUV. MANGA)	-12,42	-47,20	26/03/1974	31/12/1994	20,78	1,77
E109	1047003	RIO DAS BALSAS	-10,00	-47,90	22/08/1975	31/07/1991	15,95	0,7
E110	548001	SÃO SEBASTIÃO DO TOCANTINS	-5,26	-48,21	01/12/1992	31/12/2006	14,09	0,6
E111	1048005	TAQUARUSSU DO PORTO	-10,31	-48,16	17/06/1976	31/07/1992	16,13	0,37
E112	647000	TOCANTINÓPOLIS	-6,29	-47,39	09/08/1969	09/06/1990	20,85	0,37
E113	848003	TUPIRATINS	-8,40	-48,13	27/08/1969	15/07/1991	21,90	1,12
E114	647001	WANDERLÂNDIA-RD BELÉM-BRASÍLIA	-6,84	-47,97	01/12/1992	03/02/2005	12,18	0
E115	648000	XAMBIOÁ	-6,41	-48,53	01/12/1970	29/02/1992	21,26	0,83
E116	83368	ARAGARÇAS	-15,90	-52,23	01/04/1994	31/12/2017	23,77	1,28
E117	83374	GOIÁS	-15,91	-50,13	01/04/1994	02/10/2017	23,52	0,047
E118	83319	NOVA XAVANTINA	-14,70	-52,35	01/01/1998	31/12/2017	20,01	0,64
E119	83235	TAGUATINGA	-12,40	-46,41	01/01/1995	31/12/2017	23,01	0,14
E120	83228	PEIXE	-12,01	-48,35	02/05/1975	31/12/2017	42,70	1,1
E121	83064	PORTO NACIONAL	-10,71	-48,41	01/02/1997	31/12/2017	20,92	0,68
E122	83033	PALMAS	-10,19	-48,30	14/05/1994	31/12/2017	23,65	0,92
E123	82863	PEDRO AFONSO	-8,96	-48,18	01/03/1994	31/12/2017	23,85	0,14
E124	82861	CONCEIÇÃO DO ARAGUAIA	-8,26	-49,26	02/06/1968	31/12/2017	49,61	1,62
E125	82659	ARAGUAÍNA	-7,20	-48,20	01/01/1995	31/12/2017	23,01	0,048
E126	82765	CAROLINA	-7,33	-47,46	21/11/1981	31/12/2017	36,13	1,79
E127	82564	IMPERATRIZ	-5,53	-47,48	11/05/2000	21/04/2017	16,96	1,79
E128	82562	MARABÁ	-5,36	-49,13	11/05/1982	31/12/2017	35,66	0,9

E129	1348003	TROMBAS	-13,51	-48,75	15/09/1973	30/04/1993	19,64	0
E130	1653004	ALTO GARÇAS	-16,94	-53,53	01/12/1992	31/12/2006	14,09	0
E131	1447000	ALTO PARAÍSO DE GOIÁS	-14,13	-47,51	01/11/1970	31/12/1991	21,18	0
E132	1650000	CACHOEIRA DE GOIÁS	-16,67	-50,65	14/09/1973	31/12/2006	33,32	1,78
E133	1753001	CACHOEIRA GRANDE	-17,17	-53,13	01/01/1969	26/04/1990	21,33	0
E134	1348000	CAMPINAÇU	-13,79	-48,57	01/01/1971	31/12/1994	24,01	0,034
E135	1347000	CAVALCANTE	-13,80	-47,46	01/01/1969	31/12/1994	26,01	0
E136	1448000	COLINAS DO SUL	-14,15	-48,07	12/07/1968	31/12/2007	39,50	0,21
E137	1349000	ESTRELA DO NORTE	-13,87	-49,07	13/12/1971	31/12/2007	36,07	0,46
E138	1753002	FAZENDA BABILÔNIA	-17,35	-53,09	01/01/1995	31/12/2006	12,01	0,18
E139	1752000	FAZENDA JOAQUIM CARRIJO	-17,57	-52,78	01/01/1970	31/12/1982	12,81	1,56
E140	1547001	FAZENDA SANTA SÉ	-15,22	-47,16	09/01/1969	31/12/1994	25,99	0,94
E141	1649007	ITABERAI	-16,03	-49,80	01/10/1973	31/12/2007	34,27	0,38
E142	1549003	JARAGUÁ	-15,76	-49,34	10/07/1964	31/12/1994	30,50	0
E143	1448009	UHE SERRA DA MESA MUQUEM VAU DA ONÇA	-14,55	-48,17	01/01/2000	31/12/2011	12,01	0
E144	1449005	UHE SERRA DA MESA FAZ. CAJUPIRA	-14,80	-49,17	01/01/2000	31/12/2011	12,01	0,068
E145	1348004	UHE SERRA DA MESA BARRAMENTO	-13,83	-48,33	01/01/2000	31/12/2011	12,01	0,29
E146	1446004	SÍTIO D'ABADIA	-14,80	-46,25	21/01/1984	31/10/1996	12,79	0,74
E147	1447002	SÃO JOÃO DALIANÇA	-14,71	-47,52	29/12/1968	24/08/1990	21,67	0,75
E148	1449001	PORTO URUAÇU	-14,56	-49,14	01/01/1969	30/11/1993	24,71	0,86
E149	1448003	PORTO RIO BAGAGEM	-14,37	-48,20	01/03/1970	31/12/1994	24,85	0,99
E150	1448002	PONTE QUEBRA LINHA	-14,97	-48,67	01/12/1970	31/12/1987	17,09	0
E151	1548002	PADRE BERNARDO	-15,17	-48,28	23/02/1991	31/12/2007	16,86	0,97
E152	1448001	NIQUELÂNDIA	-14,48	-48,46	17/07/1969	31/12/1994	25,47	0,24
E153	1548001	MIMOSO	-15,06	-48,17	20/03/1973	31/12/1994	21,80	0,75
E154	1753000	ALTO ARAGUAIA	-17,30	-53,22	01/01/1969	30/04/2006	37,35	1,7
E155	1555005	SÃO JOSÉ DA SERRA	-15,84	-55,32	22/06/1976	17/04/1990	13,83	1,54
E156	1853000	FAZENDA TAQUARI	-17,81	-53,29	01/01/1969	20/11/1991	22,90	0,94
E157	83376	PIRENÓPOLIS	-15,85	-48,96	01/04/1994	31/12/2017	23,77	1,1
E158	83377	BRASILIA	-15,78	-47,93	22/08/1961	31/12/2017	56,40	1,46
E159	250003	ACANGATA	-2,25	-50,63	01/06/1989	27/03/1999	9,82	1,11
E160	148001	BELÉM	-1,45	-48,50	01/10/1973	31/12/1981	8,25	0
E161	349001	CACHOEIRA TRACAMBEUA	-3,51	-49,22	01/12/1990	05/08/2000	9,68	0,056
E162	148013	CPATU	-1,47	-48,45	01/01/1980	31/12/1988	9,01	0,031
E163	148018	IGARAPÉ-MIRI	-1,97	-48,93	15/07/1995	31/05/2005	9,88	0,83
E164	348002	TAILÂNDIA	-2,95	-48,97	07/08/1994	31/10/2005	11,24	0,99
E165	249004	VILA DO CARMO	-2,45	-49,44	17/12/1994	31/03/2004	9,29	0
E166	147015	VILA SANTA LUZIA	-1,77	-47,07	01/01/1980	31/12/1988	9,01	0,03
E167	250001	VILA SÃO BENEDITO	-1,99	-50,37	13/02/1982	31/08/1992	10,55	0,41
E168	148010	ABAETETUBA	-1,75	-48,87	18/10/1980	31/10/2005	25,05	1
E169	151001	ACAMPAMENTO IBDF	-1,79	-51,43	20/06/1980	30/11/1992	12,45	0
E170	148009	ACARÁ	-1,96	-48,21	17/08/1980	31/08/2005	25,05	1,49
E171	247000	BADAJÓS	-2,51	-47,77	17/10/1992	31/05/2005	12,63	0
E172	249003	BAIÃO	-2,79	-49,67	05/03/1990	31/08/2006	16,50	0,73
E173	148002	BELÉM	-1,44	-48,44	01/07/1966	31/12/1980	14,51	0

E174	249001	CAMETÁ	-2,25	-49,50	02/07/1978	31/12/1998	20,51	0,28
E175	147007	CASTANHAL	-1,30	-47,94	01/07/1972	31/12/1984	12,51	0,87
E176	250000	CIPOAL	-2,79	-50,45	25/11/1977	31/07/2006	28,70	0,13
E177	147011	COLÔNIA SANTO ANTÔNIO	-1,66	-47,49	11/06/1982	31/08/2005	23,24	0
E178	47003	CURUÇA	-0,74	-47,85	06/03/1992	31/12/2006	14,83	0,018
E179	247003	FAZENDA JAUARÁ	-2,04	-47,75	26/08/1990	31/05/2005	14,77	0,35
E180	247004	FAZENDA SÃO RAIMUNDO	-2,43	-47,52	18/10/1991	31/08/2005	13,88	1,14
E181	248001	FAZENDA URUCURE	-2,45	-48,58	18/09/1982	31/08/2005	22,97	0,93
E182	349002	GOIANÉSIA	-3,83	-49,09	30/03/1985	31/10/2005	20,60	0,71
E183	351000	GRANJA GAZELA	-3,42	-51,26	28/11/1977	31/03/1989	11,35	0,96
E184	250002	IRAPURU	-2,45	-50,92	23/01/1986	31/07/2006	20,53	0
E185	349003	JOANA PERES	-3,02	-49,80	25/07/1994	30/11/2006	12,36	0,64
E186	251000	MARACACUERA FLORESTAL	-2,25	-51,18	23/11/1977	31/07/2006	28,45	1,14
E187	148003	SANTA ISABEL DO PARÁ	-1,30	-48,17	01/06/1972	31/08/2005	33,27	0,57
E188	147008	SÃO DOMINGOS DO CAPIM	-1,68	-47,77	04/10/1975	20/12/1989	14,22	0,17
E189	248003	TOMÉ-AÇU	-2,42	-48,15	22/04/1984	31/08/2005	21,37	0,75
E190	48006	VIGIA	-0,87	-48,11	11/02/1982	31/08/2005	23,57	0,058
E191	148011	VILA DO CONDE	-1,57	-48,77	30/06/1990	31/10/2005	15,35	1,64
E192	249002	VILA ELIM	-2,80	-49,38	24/10/1980	31/07/1998	17,78	0,1
E193	82361	TUCURUÍ	-3,76	-49,66	09/02/1999	31/12/2017	18,90	1,04
E194	82263	CAMETÁ	-2,25	-49,50	14/11/1978	31/12/2017	39,15	0,65
E195	82191	BELÉM	-1,43	-48,43	02/01/1967	31/12/2017	51,03	0,75
E196	449001	NOVA JACUNDA	-4,46	-49,12	06/08/1994	31/10/2005	11,24	0