

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL
ENGENHARIA SANITÁRIA E AMBIENTAL

Gabriel Anzolin

**DETERMINAÇÃO DAS CURVAS IDF PARA REGIÃO SUL DO BRASIL
UTILIZANDO MODELOS ESTACIONÁRIO E NÃO ESTACIONÁRIO**

Florianópolis

2019

Gabriel Anzolin

**DETERMINAÇÃO DAS CURVAS IDF PARA REGIÃO SUL DO BRASIL
UTILIZANDO MODELOS ESTACIONÁRIO E NÃO ESTACIONÁRIO**

Trabalho Conclusão do Curso de Graduação em Engenharia Sanitária e Ambiental do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Bacharel em Engenharia Sanitária e Ambiental.
Orientador: Prof. Pedro Luiz Borges Chaffe, Dr
Coorientadora: Debora Yumi de Oliveira

Florianópolis

2019

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Anzolin, Gabriel

Determinação das Curvas IDF para região sul do Brasil
utilizando modelos estacionário e não estacionário /
Gabriel Anzolin ; orientador, Pedro Luiz Borges Chaffe,
coorientador, Debora Yumi de Oliveira, 2019.

73 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia Sanitária e Ambiental,
Florianópolis, 2019.

Inclui referências.

1. Engenharia Sanitária e Ambiental. 2. Curvas IDF. I.
Chaffe, Pedro Luiz Borges. II. Oliveira, Debora Yumi de.
III. Universidade Federal de Santa Catarina. Graduação em
Engenharia Sanitária e Ambiental. IV. Título.

Gabriel Anzolin

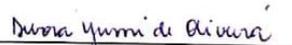
**DETERMINAÇÃO DAS CURVAS IDF PARA REGIÃO SUL DO BRASIL
UTILIZANDO MODELOS ESTACIONÁRIO E NÃO ESTACIONÁRIO**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia Sanitária e Ambiental” e aprovado em sua forma final pelo Curso de Engenharia Sanitária e Ambiental

Florianópolis, 03 de Dezembro de 2019.



Prof. Pedro Luiz Borges Chaffe, Dr.
Orientador



Debora Yumi de Oliveira
Coorientadora

Banca Examinadora:



Prof.ª Regina Rodrigues Rodrigues Dra.
Membro da Banca



Prof. Leonardo Hoinaski, Dr.
Membro da Banca

AGRADECIMENTOS

A Universidade Federal de Santa Catarina, por todas as oportunidades que tive ao longo da graduação.

Ao Professor Pedro, que durante as aulas de Hidrologia despertou meu interesse pelo mundo da pesquisa e me ajudou a encontrar algo pela qual tenho grande prazer em fazer. Pela oportunidade de realizar este trabalho, pelo incentivo, confiança, paciência e por estar sempre disposto a nos apresentar o que há de mais moderno na ciência. Por mostrar que sempre podemos fazer mais e melhor.

À Debora, que mesmo de muito longe sempre demonstrou grande entusiasmo, e cuja ajuda no dia a dia foi indispensável para a realização deste trabalho. Pela disponibilidade, paciência e por tudo que me ensinou.

À minha família, em especial, meus pais, Janete e Claudio. Pelo amor incondicional e por serem os maiores apoiadores das minhas ideias e motivo das minhas conquistas. Por me darem o suporte necessário para que minha única preocupação fossem os meus estudos. Aos meus irmãos, Matheus e Théo, por serem grandes fontes de motivação e inspiração.

Aos amigos do LabHidro, por toda ajuda, motivação e por tornarem os dias de trabalho muito mais divertidos. Em especial à Paula, que gentilmente emprestou seu computador para que eu pudesse rodar meus dados.

Aos amigos da 14.2 e seus agregados, por serem as melhores pessoas e por tornarem meus dias na UFSC melhores. Por torcerem pelo meu sucesso e pela compreensão nos momentos de nervosismo e desespero. Menção honrosa aos meus grandes amigos que irei levar comigo para sempre: Pedro, por me manter motivado, principalmente na reta final do desenvolvimento deste trabalho, Bia, que desde o laboratório de química é a minha dupla em todos os trabalhos da faculdade e Luli, por sempre trazer esperança nos momentos difíceis. Passar por tudo isso sem vocês teria sido muito mais difícil.

À Professora Regina e ao Professor Leonardo, por terem aceitado fazer parte da banca avaliadora e pelas importantes contribuições para tornar este trabalho melhor.

Muito obrigado!

RESUMO

Curvas de Intensidade-Duração-Frequência (IDF) são amplamente utilizadas para a concepção de projetos hidráulicos de infraestrutura. Tradicionalmente, as técnicas desenvolvidas para este propósito são fundamentadas no conceito de estacionariedade das séries históricas de precipitação. Devido aos efeitos das mudanças climáticas no ciclo hidrológico, este conceito vem sendo questionado pela comunidade científica. Nesse contexto, a identificação de tendências em eventos extremos pluviométricos levou ao desenvolvimento e uso de modelos não estacionários para a análise de frequência de eventos extremos de precipitação. Contudo, devido à incerteza associada à detecção e estimativa de tendência nas séries históricas disponíveis, assim como à incerteza intrínseca ao se realizar qualquer previsão de cenários futuros, ainda não existe um consenso quanto à utilização de modelos estacionários ou modelos não estacionários. Neste trabalho, realizou-se uma comparação de desempenho entre o uso de modelos estacionário e não estacionário utilizando a distribuição Generalizada de Valor Extremo (GEV). Foram analisadas 696 estações pluviométricas relativas à região sul do Brasil. Estes dados são diários e foram disponibilizados pela Agência Nacional de Águas. Os valores dos parâmetros da distribuição GEV e a incerteza associada à sua estimativa foram obtidos a partir da Inferência Bayesiana. A seleção de modelos com base nos critérios de informação e com os valores da função de verossimilhança para o conjunto ótimo de parâmetros sugerem a escolha de um modelo não estacionário, principalmente para séries temporais em que há a presença de tendência significativa no período de calibração. Entretanto, quando a incerteza acerca da estimativa dos parâmetros da distribuição de extremos é considerada, o suporte ao modelo não estacionário decresce significativamente. Estes resultados indicam que o acréscimo de incerteza promovido pela adição de complexidade é uma das principais limitações do uso de modelos não estacionários na análise de frequência de extremos, e que a presença de tendência significativa em um registro histórico não é uma condição suficiente para justificar o uso de um modelo não estacionário.

Palavras-chave: Curvas IDF. Não estacionariedade. Inferência bayesiana.

ABSTRACT

Intensity-Duration-Frequency (IDF) curves are widely used for the design of hydraulic infrastructure projects. Traditionally, the techniques developed for this purpose are based on the concept of stationarity of historical precipitation series. Due to the effects of climate change on the hydrological cycle, this concept has been questioned by the scientific community. The identification of trends in extreme rainfall events led to the development and use of non-stationary models for frequency analysis of extreme precipitation events. However, due to the uncertainty associated with trend detection and estimation in the available historical series, as well as the intrinsic uncertainty in making any prediction of future scenarios, there is no consensus on the use of stationary or non-stationary models. In this work, a performance comparison was made between the use of stationary and non-stationary models using the Generalized Extreme Value distribution (GEV). A total of 696 rainfall stations from southern Brazil were analyzed. The data are in the daily timescale and are available from the Brazilian Water Agency. The values of the GEV distribution parameters and the uncertainty associated with their estimation were obtained using Bayesian Inference. The selection of models based on the information criteria and the likelihood function values for the optimal set of parameters suggests the choice of a non-stationary model, especially for time series where there is a significant trend in the fitting period. However, when uncertainty about the estimation of extreme distribution parameters is considered, support for the non-stationary model decreases significantly. These results indicate that the increased uncertainty promoted by the addition of complexity is one of the main limitations of the use of non-stationary models in the extreme frequency analysis, and the presence of significant trend in a historical record is not a sufficient condition to justify the use of non-stationary models.

Keywords: IDF curves. Nonstationarity. Bayesian inference.

LISTA DE FIGURAS

Figura 1 – Explicação do conceito de estacionariedade e de não-estacionariedade de séries temporais a partir de um processo estocástico univariado considerando diferentes tamanhos da série. (A) Ilustra os primeiros 200 anos de observações, conclusão preliminar: série não estacionária; (B) Ilustra a série em sua totalidade (2000 anos), em que se conclui que a série é estacionária. As linhas em azul são os valores da série sintética gerada a partir de um processo estocástico univariado, e a linha vermelha representa uma média do sistema de 100 anos. 22

Figura 2 - Área de estudo, região sul do Brasil; disposição das estações pluviométricas selecionadas neste estudo. 30

Figura 3 - Exemplo de comparação entre os valores de média durante o período de inferência dos parâmetros e validação para os modelos estacionário (ST), estacionário atualizado (uST) e não estacionário (NS), respectivamente, para a estação pluviométrica 02349033, que apresentou tendência significativa de sinal positivo (quando avaliada para a série completa). O x em preto representa o final do período utilizado para inferência dos parâmetros. A linha contínua representa a média da distribuição GEV, e as linhas tracejadas representam o intervalo de credibilidade de 95% da estimativa da média. 38

Figura 4 – Comparação entre os valores de $\Delta AIC (= AIC_{c,s} - AIC_{c,min})$ e $\Delta BIC (= BIC_s - BIC_{min})$ para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₁. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC). 40

Figura 5 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₁. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte para o modelo ST. 41

Figura 6 - Comparação entre os valores de $\Delta AIC (= AIC_{c,s} - AIC_{c,min})$ e $\Delta BIC (= BIC_s - BIC_{min})$ para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₇. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC). 42

Figura 7 - Valores de (a) ΔAIC e (b) ΔBIC para séries AMS₇. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte

utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte para o modelo ST.

..... 43

Figura 8 – (a) Média da distribuição GEV obtida através do conjunto ótimo de parâmetros para os modelos ST (azul), uST (dourado) e NS (vermelho), inferidos a partir da primeira metade da série AMS₁ (linha preta) – estação pluviométrica 02849004, que apresentou tendência significativa de sinal positivo (quando avaliada para o período de inferência dos parâmetros). As faixas sombreadas em azul, dourado e vermelho representam um intervalo de credibilidade de 95% da estimativa da média para os modelos ST, uST e NS, respectivamente. (b-d) Histogramas em preto representam a densidade empírica para os dados utilizados durante o período de validação, e as linhas contínuas ilustram a densidade dos modelos ST (azul), uST (dourado) e NS (vermelho, ano de 2010) para o conjunto ótimo de parâmetros..... 46

Figura 9 – Exemplo de comparação entre modelos (a) ST, (b) uST e (c) NS na estimativa de intensidade de precipitação para diferentes períodos de retorno para estação pluviométrica 02849004. Linhas contínuas representam as intensidades de precipitação associada a diferentes conjuntos de parâmetros. Linhas tracejadas representam intervalos de credibilidade de 95%, e as bolas pretas são os valores empíricos (d) Densidade de probabilidade para intensidade de 100 anos de período de retorno para modelos ST (azul), uST (dourado) e NS (vermelho). OBS: modelo NS com extrapolação para o ano final da série AMS₁ (2010). 47

Figura 10 – (a) Média da distribuição GEV obtida através do conjunto ótimo de parâmetros para os modelos ST (azul), uST (dourado) e NS (vermelho), inferidos a partir da primeira metade da série AMS₁ (linha preta) – estação pluviométrica 02755001, que apresentou tendência significativa de sinal negativo (quando avaliada para o período de inferência dos parâmetros). As faixas sombreadas em azul, dourado e vermelho representam um intervalo de credibilidade de 95% da estimativa da média para os modelos ST, uST e NS, respectivamente. (b-d) Histogramas em preto representam a densidade empírica para os dados utilizados durante o período de validação, e as linhas contínuas ilustram a densidade dos modelos ST (azul), uST (dourado) e NS (vermelho, ano de 2010) para o conjunto ótimo de parâmetros..... 49

Figura 11 - Exemplo de comparação entre modelos (a) ST, (b) uST e (c) NS na estimativa de intensidade de precipitação para diferentes períodos de retorno para estação pluviométrica 02755001. Linhas contínuas representam as intensidades de precipitação associada a diferentes conjuntos de parâmetros. Linhas tracejadas representam intervalos de credibilidade de 95%, e as bolas pretas são os valores empíricos (d) Densidade de probabilidade

para intensidade de 100 anos de período de retorno para modelos ST (azul), uST (dourado) e NS (vermelho). OBS: modelo NS com extrapolação para o ano final da série AMS₁ (2015). 50

Figura 12 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₂. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.....62

Figura 13 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₃. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.....63

Figura 14 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₄. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.....64

Figura 15 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₅. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.....65

Figura 16 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS₆. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.....66

Figura 17 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência

significativa para séries AMS₂. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,mín}$ ($BIC_{mín}$) é o menor valor de AIC_c (BIC). 67

Figura 18 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,mín}$) e ΔBIC ($= BIC_s - BIC_{mín}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₃. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,mín}$ ($BIC_{mín}$) é o menor valor de AIC_c (BIC). 67

Figura 19 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,mín}$) e ΔBIC ($= BIC_s - BIC_{mín}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₄. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,mín}$ ($BIC_{mín}$) é o menor valor de AIC_c (BIC). 68

Figura 20 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,mín}$) e ΔBIC ($= BIC_s - BIC_{mín}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₅. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,mín}$ ($BIC_{mín}$) é o menor valor de AIC_c (BIC). 68

Figura 21 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,mín}$) e ΔBIC ($= BIC_s - BIC_{mín}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₆. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,mín}$ ($BIC_{mín}$) é o menor valor de AIC_c (BIC). 69

LISTA DE TABELAS

Tabela 1 – Trabalhos relacionados a chuvas intensas no Brasil (continua).	25
Tabela 2 - Intervalos dos parâmetros dos modelos estacionário e não estacionário utilizados na inferência dos parâmetros.....	34
Tabela 3 - Número de séries com melhor desempenho na validação para cada um dos modelos (estacionário – ST, estacionário atualizado – uST e não estacionário – NS) considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança (L_{MED}) de todas estações pluviométricas, para séries AMS de 1 a 7 dias.	44
Tabela 4 - Número de séries com melhor desempenho na validação para cada um dos modelos (estacionário – ST, estacionário atualizado – uST e não estacionário – NS) considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança (L_{MED}) de estações pluviométricas com tendência no período de calibração, para séries AMS de 1 a 7 dias.	59

SUMÁRIO

1	INTRODUÇÃO	17
1.1	OBJETIVOS	18
1.1.1	Objetivo Geral.....	18
1.1.2	Objetivos Específicos	18
2	REVISÃO BIBLIOGRÁFICA	19
2.1	CURVAS IDF.....	19
2.2	ANÁLISE DE FREQUÊNCIA.....	20
2.3	CHUVAS INTENSAS NO BRASIL	22
3	MATERIAIS E MÉTODOS	29
3.1	ÁREA DE ESTUDO	29
3.2	DADOS PLUVIOMÉTRICOS.....	31
3.3	ANÁLISE DE TENDÊNCIA	31
3.4	ANÁLISE DE FREQUÊNCIA.....	33
3.4.1	Distribuição Generalizada de Valor Extremo (GEV)	33
3.4.2	Inferência dos parâmetros	33
3.4.3	Avaliação de desempenho	35
3.4.3.1	<i>Critérios de informação.....</i>	36
3.4.3.2	<i>Validação dos modelos.....</i>	37
4	RESULTADOS E DISCUSSÃO.....	39
4.1	AVALIAÇÃO DE DESEMPENHO: CRITÉRIOS DE INFORMAÇÃO	39
4.2	AVALIAÇÃO DE DESEMPENHO E ANÁLISE DE INCERTEZA: VALIDAÇÃO	44
5	CONCLUSÕES E RECOMENDAÇÕES	51
	REFERÊNCIAS.....	53
	APÊNDICE A	59
	APÊNDICE B.....	61
	APÊNDICE C	67

1 INTRODUÇÃO

Diversos projetos hidráulicos de infraestrutura (galerias de drenagem pluvial, reservatórios e análise de suscetibilidade de movimento de massa) são idealizados com base na Chuva de Projeto, que é obtida por meio das Curvas de Intensidade-Duração-Frequência (IDF). Tradicionalmente, as Curvas IDF são calculadas considerando a premissa de estacionariedade das séries temporais, i.e., quando não há tendência significativa ou mudança no regime de precipitação. Neste caso, assume-se que a probabilidade de ocorrência de eventos extremos não varia significativamente ao longo do tempo (CHENG; AGHAKOUCHAK, 2014).

Entretanto, segundo dados do Quinto Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2014), desde 1960, as atividades antropogênicas vêm contribuindo para alterar o ciclo hidrológico global. A principal causa desta alteração está associada a elevação da temperatura global, que aumenta a capacidade de retenção de água da atmosfera, intensificando o ciclo hidrológico e afetando os eventos de precipitação (RAGNO *et al.*, 2018). Portanto, espera-se que as mudanças climáticas alterem a intensidade, duração e frequência de eventos extremos. Esta alteração recebe o nome de não estacionariedade (CHENG; AGHAKOUCHAK, 2014).

Devido aos impactos das mudanças climáticas no ciclo hidrológico, a premissa de estacionariedade vem sendo questionada pela comunidade científica. Assim, a identificação de tendências em eventos extremos pluviométricos levou ao desenvolvimento e uso de modelos não estacionários para a análise de frequência de eventos extremos de precipitação. Estes modelos consideram que os parâmetros da distribuição de extremos utilizada na análise de frequência de extremos, que usualmente são constantes, sejam variáveis em relação ao tempo. Contudo, devido à incerteza associada à detecção e estimativa de tendência nas séries históricas disponíveis, assim como à incerteza intrínseca ao se realizar qualquer previsão de cenários futuros, ainda não existe um consenso quanto à utilização de modelos estacionários ou modelos não estacionários (SERAGO; VOGEL, 2018).

Neste trabalho, realizou-se uma comparação de desempenho entre o uso de modelos estacionário e não estacionário para a determinação das Curvas IDF, considerando a incerteza associada à inferência dos parâmetros da distribuição Generalizada de Valor Extremo (GEV), aplicadas a séries históricas de precipitação da região sul do Brasil. O desenvolvimento deste trabalho concentrou-se em responder a seguinte pergunta: a presença de tendência significativa em uma série temporal justifica a utilização de modelos não estacionários para a análise de frequência de extremos?.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo geral deste trabalho é determinar as Curvas de Intensidade-Duração-Frequência de precipitação para região sul do Brasil.

1.1.2 Objetivos Específicos

1. Caracterizar as séries históricas de precipitação da região sul do Brasil quanto a sua estacionariedade;
2. Avaliar o desempenho de modelos estacionário e não estacionário na determinação das curvas de Intensidade-Duração-Frequência para região sul do Brasil.
3. Avaliar o efeito da adição de complexidade dos modelos na inferência dos parâmetros e estimativa de incerteza.

2 REVISÃO BIBLIOGRÁFICA

2.1 CURVAS IDF

No contexto da Engenharia Hidráulica e de Recursos Hídricos, a concepção de projetos hidráulicos de infraestrutura e de análise de risco hidrológico são frequentemente associados à eventos extremos de precipitação (VENEZIANO; LANGOUSIS; FURCOLO, 2006). Eventos extremos de precipitação estão diretamente relacionados a uma série de impactos que afetam a sociedade de diferentes maneiras (Papalexiou e Montanari, 2019). Segundo Doocy et al. (2013), entre 1980 e 2009, mais de meio milhão de mortes foram causadas por inundações induzidas por eventos extremos de chuva. No mesmo período, aproximadamente 3 bilhões de pessoas foram afetadas por inundações (JONKMAN, 2005). Eventos extremos de chuva podem afetar severamente estações de tratamento de água, redes coletoras de esgoto sanitário, além de colaborar na propagação de surtos de doenças transmissíveis pela água (CURRIERO *et al.*, 2001). Estes eventos também podem aumentar a presença de contaminantes microbianos na água de escoamento superficial, provocando impactos na saúde pública (PARKER *et al.*, 2010). Chuvas intensas podem devastar áreas destinadas a produção agrícola (ROSENZWEIG et al., 2002), desencadear deslizamentos de terra (MARTELLONI *et al.*, 2012), aumentam o risco de danos e falhas em estruturas hidráulicas (Nissen e Ulbrich, 2017) e são responsáveis por causar inundações, principalmente em áreas urbanas (superfícies impermeáveis) e zonas costeiras (elevação do nível do mar) (WDOWINSKI *et al.*, 2016).

Devido a esta longa lista de impactos decorrentes de eventos extremos de chuva, na última década, um dos focos da Hidrologia teórica e aplicada têm sido a estimativa de eventos extremos de precipitação. Comumente, estas estimativas são realizadas a partir de Curvas de Intensidade-Duração-Frequência (IDF). Curvas IDF representam a intensidade provável de um determinado evento de precipitação, de uma duração particular (em certos casos, tempo de concentração de uma bacia hidrográfica, e.g., utilização do método racional para estimativa da vazão de projeto), e um período médio de recorrência (período de retorno).

A estimativa de eventos extremos de precipitação associada a diferentes períodos de retorno não pode ser baseada em técnicas determinísticas, sendo necessária a utilização de uma abordagem estocástica (probabilística), em que a precipitação é considerada como uma variável aleatória que segue uma distribuição de probabilidade (NERANTZAKI; PAPALEXIOU, 2019). Portanto, a determinação de Curvas IDF consiste em ajustar uma distribuição de

probabilidade que seja representativa dos dados observados, para intensidades de precipitação de diferentes durações.

2.2 ANÁLISE DE FREQUÊNCIA

Como citado, diversos projetos hidráulicos de infraestrutura (e.g., drenagem de águas pluviais urbanas, dimensionamento de barragens e reservatórios ou análise de suscetibilidade de movimento de massa) são idealizados com base na Chuva de Projeto, que é obtida através das Curvas IDF. Tradicionalmente, as técnicas desenvolvidas para este propósito são fundamentadas no conceito de estacionariedade das séries temporais, em que se assume que o comportamento da série temporal é invariável em relação ao tempo. Neste caso, a probabilidade de ocorrência de eventos extremos não varia significativamente ao longo do tempo (CHENG; AGHAKOUCHAK, 2014). Isto implica que uma variável qualquer (e.g., vazão máxima anual ou precipitação máxima anual) pode ser modelada a partir de modelos probabilísticos (e.g., distribuição Generalizada de Valor Extremo, *Lognormal*, *Weibull*, *Logpearson*) cujo parâmetros da Função Densidade de Probabilidade (PDF) são constantes ao longo do tempo (MILLY *et al.*, 2008).

Entretanto, devido às mudanças hidroclimáticas, a hipótese de estacionariedade das séries temporais vem sendo questionada pela comunidade científica. Segundo Milly *et al.* (2015), a mudança climática antropogênica é uma realidade e está ficando mais influente. Dados do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2014) sugerem que o aumento da temperatura deve ter implicações hidrológicas. Estas implicações estão relacionadas com a influência da temperatura sobre características do ciclo hidrológico, e.g., tipo de precipitação, quantidade de água armazenada em geleiras, intensidade de precipitação e taxas de evapotranspiração (MILLY *et al.*, 2015). Ainda de acordo com Milly *et al.* (2015), mudanças no ciclo hidrológico são impulsionadas por mudanças sistemáticas na circulação atmosférica, afetando a distribuição espacial da precipitação e a radiação, principais componentes do equilíbrio do ciclo hidrológico terrestre.

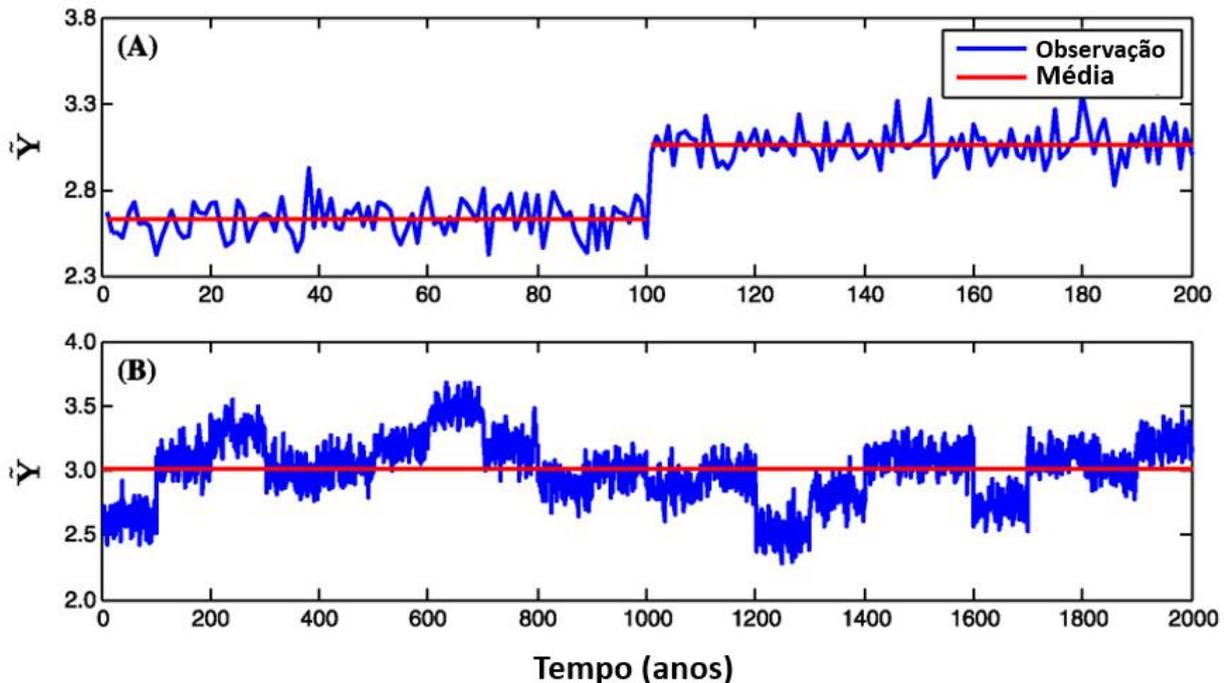
Diante destas mudanças, em seu artigo, Milly *et al.* (2008) declararam que a “estacionariedade está morta” e que há uma necessidade em detectar e considerar a não-estacionariedade das séries temporais nos modelos de predição de eventos hidrológicos extremos e na gestão de Recursos Hídricos. Este cenário levou ao desenvolvimento de modelos probabilístico não estacionários, em que é possível considerar que os parâmetros de uma

distribuição de probabilidade variam ao longo do tempo, *e.g.*, Vogel *et al.* (2011), Prosdocimi *et al.* (2014).

Por outro lado, outros autores da comunidade científica alegam que considerar a não-estacionariedade não é uma solução universal na modelagem das mudanças ambientais e que a utilização de modelos não estacionários e de expressões como “a estacionariedade está morta” deve ser feita com cuidado (MONTANARI; KOUTSOYIANNIS, 2014). Sadegh *et al.* (2014) sugerem cautela em classificar uma série temporal como estacionária ou não estacionária. Segundo os autores, sem observações longas o suficiente, é particularmente difícil tomar esta decisão. Quando apenas um curto período de observações é avaliado, pode ser que seja detectada a presença de não estacionariedade na série de dados (Figura 1.A). Entretanto, quando a série é avaliada por um longo período de tempo (Figura 1.B), tem-se que as observações na verdade são estacionárias. Sendo assim, avaliar curtos períodos pode enviesar a tomada de decisão quanto à estacionariedade da série. Além disso, Serago e Vogel (2018) destacam a incerteza associada à detecção e estimativa de tendência nas séries históricas disponíveis e também da incerteza intrínseca ao se realizar qualquer previsão de cenários futuros.

Portanto, é preciso compreender se a utilização de modelos não estacionários é realmente necessária. Assim, Engenheiros e Técnicos devem utilizar as informações disponíveis para selecionar a melhor técnica possível para projetar e adaptar estruturas hidráulicas para a condição de um clima em mudança (MONTANARI; KOUTSOYIANNIS, 2014).

Figura 1 – Explicação do conceito de estacionariedade e de não-estacionariedade de séries temporais a partir de um processo estocástico univariado considerando diferentes tamanhos da série. (A) Ilustra os primeiros 200 anos de observações, conclusão preliminar: série não estacionária; (B) Ilustra a série em sua totalidade (2000 anos), em que se conclui que a série é estacionária. As linhas em azul são os valores da série sintética gerada a partir de um processo estocástico univariado, e a linha vermelha representa uma média do sistema de 100 anos.



Fonte: Traduzido de Sadegh *et al.* (2014).

2.3 CHUVAS INTENSAS NO BRASIL

A Tabela 1 traz o resumo das principais pesquisas relacionadas à determinação de Curvas IDF no Brasil. As pesquisas foram avaliadas de acordo com o número de estações pluviométricas utilizadas, fonte dos dados, área de estudo, da distribuição de extremos utilizada, se levou em consideração ou não a incerteza acerca da inferência dos parâmetros da distribuição de extremos considerada, e se considerou ou não a não estacionariedade das séries temporais de precipitação.

Os resultados deste levantamento mostram que no Brasil a maioria dos trabalhos relacionados a chuvas intensas se resume a ajustar a equação IDF para intensidades de precipitação de diferentes durações. Em relação aos modelos probabilísticos, Gumbel é a distribuição de extremos mais utilizada. Com exceção do trabalho desenvolvido por Gomes e Vargas Junior (2018), a incerteza acerca da determinação dos parâmetros da distribuição de extremos não é considerada. Alguns trabalhos, como Schardong e Srivastav (2014) e Sabóia *et*

al. (2016) utilizam dados de GCMs para estimar as intensidades de precipitação para cenários futuros. Embora estes estudos considerem os efeitos das mudanças climáticas nos eventos extremos de precipitação, os modelos utilizados na determinação das Curvas IDF não possuem características não estacionárias. Destaca-se a seguir alguns trabalhos e suas principais conclusões.

O trabalho pioneiro de Curvas IDF no Brasil foi desenvolvido por Pfafstetter (1957). Foram utilizados dados de 98 séries históricas de precipitação disponibilizadas pelo serviço de Meteorologia da Agricultura. Neste trabalho, Pfafstetter desenvolveu uma equação empírica para estimar as precipitações máximas em função de sua duração e tempo de recorrência.

Neriolo, Medeiros e Cordero (2002) calcularam equações IDF para o estado de Santa Catarina a partir de 150 séries históricas de precipitação, disponibilizadas pelo Centro Integrado de Meteorologia e Recursos Hídricos (CLIMERH). A distribuição de extremos utilizada foi a de Gumbel. Como resultados, foram estabelecidas isoietas de intensidade de chuva para todo o estado de Santa Catarina.

Back, Henn e Oliveira (2011) determinaram equações IDF para 13 estações pluviométricas (ANA) no estado de Santa Catarina utilizando a distribuição de Gumbel. Os resultados mostram grande variação na intensidade máxima da chuva entre as estações estudadas. Foram observados maiores valores de coeficientes de variação nas séries de máximas anuais de chuva com duração superior a 600 min das estações situadas na faixa litorânea do estado de Santa Catarina.

Back e Boneti (2014) determinaram equações IDF para o cálculo da chuva de projeto em instalações prediais no estado de Santa Catarina. Foram utilizadas 147 estações pluviométricas (ANA) também para estado de Santa Catarina, utilizando a distribuição de Gumbel. Os resultados mostram que a chuva máxima com duração de 5 minutos e período de retorno de 5 anos em Santa Catarina varia entre 127,7 a 266,5 mm/h. Os maiores valores de intensidade ocorrem na faixa do Litoral Norte do Estado e no Extremo Oeste, com menores valores na região do Planalto Catarinense e Alto Vale do Itajaí.

Schardong e Srivastav (2014) utilizaram dados de Modelos de Circulação Global (GCM) do CMIP5 para atualizar a equação de chuvas intensas do município de São Paulo. A distribuição de extremos utilizada foi a de Gumbel. Os resultados apresentam uma tendência de aumento das precipitações extremas quando comparadas ao cenário atual. O incremento obtido de aproximadamente 4,5% para cenário menos crítico e de cerca de 31% para cenário mais crítico.

Sabóia *et al.* (2017) avaliou o impacto das mudanças climáticas na rede de drenagem de águas pluviais urbanas, em Fortaleza, Ceará. Foram utilizados dados de precipitações oriundos de 6 GCMs. Neste estudo, foram geradas equações IDF para cenários futuros. Os novos valores de precipitação gerados por essas novas curvas IDFs foram utilizados como um dos dados de entrada do programa HEC-HMS. Os resultados sugerem aumento nas vazões e volumes escoados no sistema de drenagem analisado.

Weschenfelder *et al.* (2017) determinaram equações IDF para o município de Porto Alegre com a distribuição de Gumbel. Foram utilizadas séries sintéticas de precipitação para os cenários atual e projetados (futuros), obtidos a partir de um gerador estocástico de precipitação LARS-WG. Os resultados mostraram que o gerador LARS-WG representou bem a precipitação do cenário climático atual, mas mostrou baixa aplicabilidade para cenários futuros.

Gomes e Vargas Junior (2018) determinaram a equação IDF para a cidade de Marataízes, no Espírito Santo, para uma estação pluviométrica (ANA). A distribuição de extremos utilizada foi a de Gumbel. Neste trabalho, os parâmetros da distribuição de extremos foram obtidos a partir de algoritmos de evolução diferencial. Destaca-se aqui que este foi o único trabalho encontrado no Brasil que considerou a incerteza no processo de inferência dos parâmetros da distribuição de Gumbel. Os resultados obtidos indicaram bons ajustes para os modelos de Gumbel e da equação de chuvas intensas com o uso da otimização global via evolução diferencial.

Souza *et al.* (2019) elaboraram mapas de intensidade de precipitação para tempo de retorno de 5 anos e diferentes duração para todo o Brasil por meio da distribuição de Gumbel. Foram utilizados dados de 4411 estações pluviométrica (ANA). Os valores de intensidade foram interpolados para todo o Brasil e permitem a obtenção da intensidade de precipitação para regiões com escassez de dados.

Tabela 1 – Trabalhos relacionados a chuvas intensas no Brasil (continua).

Notas: ANA significa Agência Nacional de Águas, INMET significa Instituto Nacional de Meteorologia, GCM significa Modelos de Circulação Global, FUNCEME significa Fundação Cearense de Meteorologia e Recursos Hídricos, CLIMERH significa Centro Integrado de Meteorologia e Recursos Hídricos, DAEE significa Departamento de Água e Energia Elétrica. ** significa que não se utilizou distribuições de probabilidade.

Autor	Nº de Est. Plu.	Fonte de Dados	Área de Estudo	Distribuição de Extremos	Incerteza	NS
Pfafstetter (1957)	98	Serviço de Meteorologia da Agricultura	Brasil	**	Não	Não
Martinez Júnior e Magni (1999)	30	DAEE	São Paulo	Gumbel	Não	Não
Neriolo, Medeiros e Cordero (2002)	150	CLIMERH	Santa Catarina	Gumbel	Não	Não
Oliveira et al. (2005)	73	Não informada	Goiás e Distrito Federal	Gumbel	Não	Não
Santos et al. (2009)	109	ANA	Mato Grosso do Sul	Gumbel	Não	Não

Autor	Nº de Est. Plu.	Fonte de Dados	Área de Estudo	Distribuição de Extremos	Incerteza	NS
Oliveira et al. (2011)	136	ANA	Mato Grosso	Gumbel	Não	Não
Back, Henn e Oliveira (2011)	13	Não Informado	Santa Catarina	Gumbel	Não	Não
Garcia et al. (2011)	3	INMET	Mato Grosso	Gumbel	Não	Não
Souza et al. (2012)	74	ANA	Pará	Gumbel	Não	Não
Silva et al. (2012)	12	ANA	Pernambuco	Gumbel e Weibull	Não	Não
Aragão et al. (2013)	48	ANA	Sergipe	Weibull e Gumbel	Não	Não
Pinto (2013)	Não Informado	ANA	Brasil	Generalizada de Pareto, Generalizada de Valor Extremo, Generalizada Logística, Gama, Gumbel e Exponencial	Não	Não

Autor	N° de Est. Plu.	Fonte de Dados	Área de Estudo	Distribuição de Extremos	Incerteza	NS
Schardong, Srivastav e Simonovic (2014)	GCM	Modelos de Clima CMIP5	São Paulo	Gumbel	Não	Não
Back e Boneti (2014)	147	ANA	Santa Catarina	Gumbel	Não	Não
Campos et al. (2014)	133	ANA	Piauí	Gumbel	Não	Não
Fechine <i>et al.</i> (2014)	3	FUNCEME	Região Metropolitana do Cariri	Gumbel, Lognormal (para 2 e 3 parâmetros), Gama (para 2 e 3 parâmetros)	Não	Não
CampOS <i>et al.</i> (2017)	132	ANA	Paraíba	Gumbel, Lognormal (para 2 e 4 parâmetros), Pearson III e Logpearson III	Não	Não
Sabóia <i>et al.</i> (2017)	GCM	Modelos de Clima CMIP5	Fortaleza	Gumbel	Não	Não

Autor	Nº de Est. Plu.	Fonte de Dados	Área de Estudo	Distribuição de Extremos	Incerteza	NS
Braga <i>et al.</i> (2018)	32	Alerta Rio	Rio de Janeiro	Gumbel	Não	Não
Gomes e Vargas Junior (2018)	1	ANA	Marataízes	Gumbel	Sim	Não
Weschenfelder <i>et al.</i> (2019)	Série sintética de precipitação	LARS-WG	Porto Alegre	Gumbel	Não	Não
Silva <i>et al.</i> (2019)	105	ANA	Região do Matopiba	Gumbel, Lognormal (para 2 e 3 parâmetros), Pearson e Lorpearson III	Não	Não
Souza <i>et al.</i> (2019)	4411	ANA	Brasil	Gumbel	Não	Não
Dorneles <i>et al.</i> (2019)	1	INMET	Pelotas	Normal, Lognormal, Gumbel e Gama	Não	Não

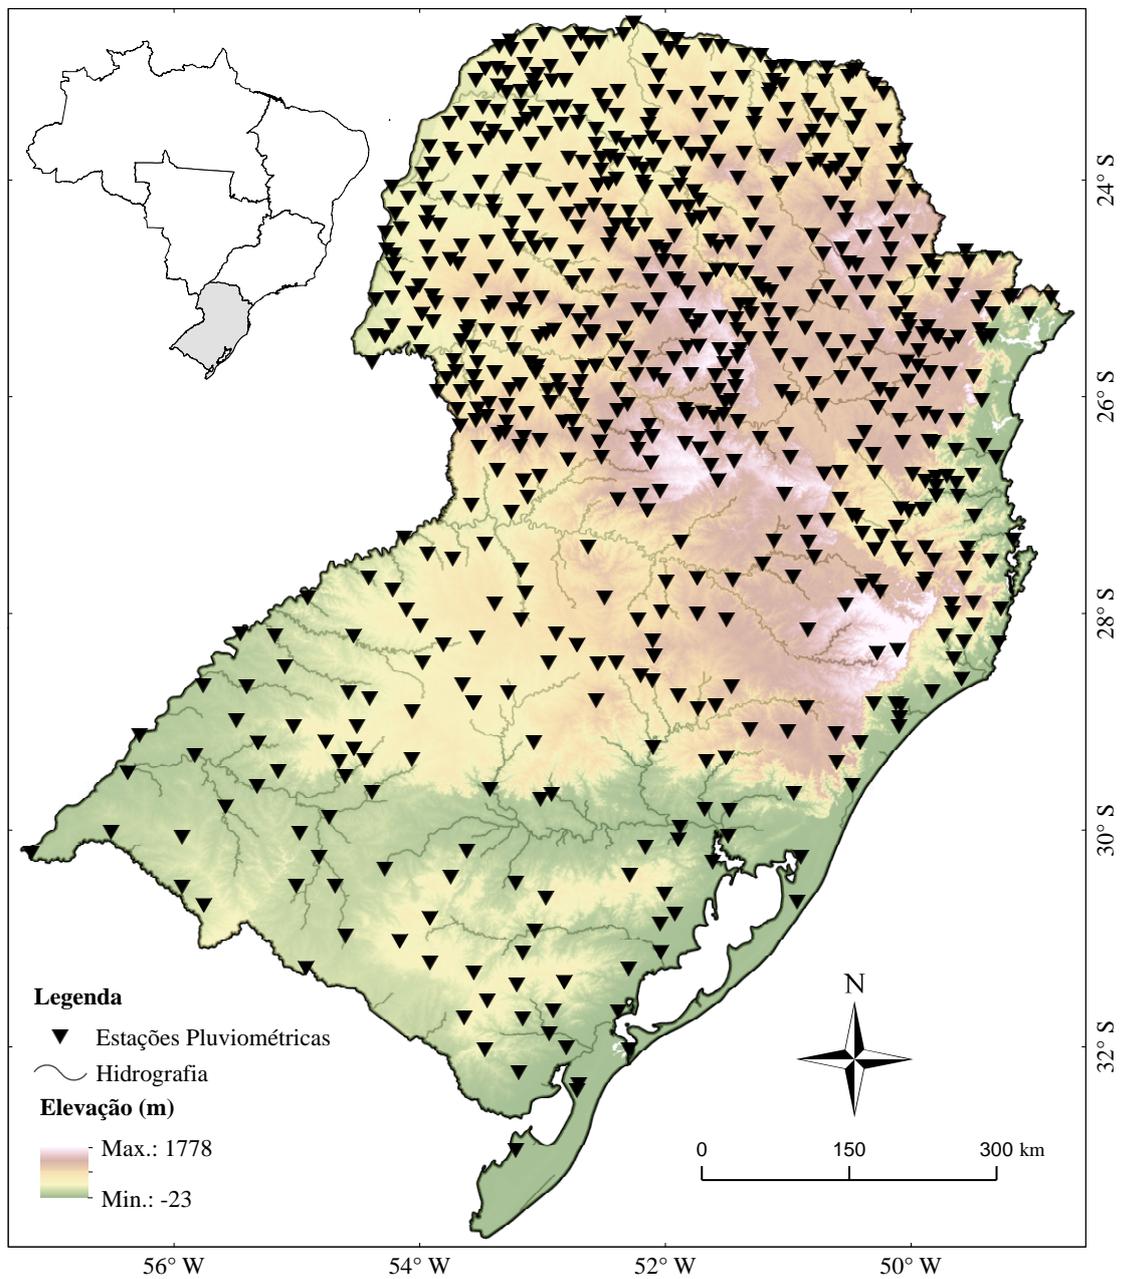
3 MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo é a região sul do Brasil (Figura 2). Politicamente, o Sul é dividido em três unidades federativas: Paraná (PR), Santa Catarina (SC) e Rio Grande do Sul (RS). Segundo o Instituto Brasileiro de Geografia e Estatística (IBGE, 2016), o sul do Brasil ocupa uma área na ordem de 570.000 km², e pode ser dividido em três regiões hidrográficas: bacia do Atlântico Sul, bacia do Paraná e bacia do Uruguai.

Segundo a classificação de Köppen-Geiger, o clima da região Sul é subtropical úmido com verões quentes em altitude mais baixas e verões temperados em altitudes mais elevadas. A precipitação anual varia entre aproximadamente 1.200 mm nas extremidades norte e sul e 2.500 mm na costa norte (CHAGAS; CHAFFE, 2018).

Figura 2 - Área de estudo, região sul do Brasil; disposição das estações pluviométricas selecionadas neste estudo.



Fontes: limites da região sul do Brasil (IBGE, 2010); estações pluviométricas (ANA, 2017), altimetria (USGS, 2006); e hidrografia gerada a partir de USGS (2006).

3.2 DADOS PLUVIOMÉTRICOS

As séries históricas das estações pluviométricas utilizadas neste trabalho foram obtidas a partir da Agência Nacional de Águas (ANA, 2017), no Portal HidroWeb (www.snirh.gov.br/hidroweb). Trata-se de medições diárias realizadas por meio de 1938 estações pluviométricas distribuídas ao longo de toda a região Sul. As estações de monitoramento possuem heterogeneidade em sua distribuição, havendo maior concentração no estado do Paraná e menor concentração em Santa Catarina.

Do total de estações pluviométricas disponíveis, foram consideradas neste estudo apenas aquelas com ao menos 30 anos completos de observações e no máximo 10% de falhas (ausência de medições). Além disso, foi feita uma análise exploratória dos dados, que consiste em analisar graficamente os valores diários e de máximas diárias anuais, onde foram eliminadas estações pluviométricas com valores considerados como discrepantes. Este processo de seleção resultou em um total de 696 estações pluviométricas (Figura 2). Em relação a consistência dos dados, nenhum método de consistência foi aplicado, sendo utilizados os dados com a consistência estabelecidas pela ANA (2017).

Para cada estação pluviométrica selecionada, foram geradas séries de intensidade máxima anual (*annual maxima series*, AMS) para as precipitações acumuladas de 1 a 7 dias, conforme Ragno *et al.* (2018). Portanto, para cada estação pluviométrica, tem-se um total de sete séries AMS. Essa estratégia foi adotada devido à inexistência de registros históricos de precipitação com resolução temporal superior à diária e com tamanho mínimo necessário para o cálculo das Curvas IDF.

3.3 ANÁLISE DE TENDÊNCIA

O teste de Mann-Kendall (MANN, 1945; KENDALL, 1975) foi utilizado para detectar a presença de tendência monotônica nas séries AMS. É um teste estatístico não paramétrico, ou seja, que não exige distribuição normal dos dados. Suas premissas são: independência da série e constância de sua distribuição (homoscedasticidade). O teste foi escolhido por ser popular em estudos hidrológicos e por ser pouco afetado por *outliers* presentes na série de dados.

A hipótese nula é de que não há presença de tendência significativa na série temporal, e a hipótese alternativa é que há tendências na série. Os passos para aplicação do teste são descritos a seguir:

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

em que n é o comprimento da série de dados (anos), x_j e x_i são os valores sequenciais da série, e:

$$\text{sgn}(x_j - x_i) = \begin{cases} +1, & x_j > x_i \\ 0, & x_j = x_i \\ -1, & x_j < x_i \end{cases} \quad (2)$$

Para $n \geq 10$, espera-se que S seja normalmente distribuído, com média igual a zero, e variância igual a:

$$V = \frac{n \cdot (n - 1) \cdot (2 \cdot n + 5) - \sum_{i=1}^m t_i(t_i - 1) \cdot (2 \cdot t_i + 5)}{18} \quad (3)$$

em que m é o número de grupos de valores repetidos na série, e t_i o número de valores repetidos no grupo i . O teste estatístico padronizado é calculado:

$$Z = \begin{cases} \frac{S - 1}{\sqrt{V}}, & S > 0 \\ 0, & S = 0 \\ \frac{S + 1}{\sqrt{V}}, & S < 0 \end{cases} \quad (4)$$

Finalmente, o p-valor é retirado da tabela de distribuição normal a partir do valor de Z . O teste, neste caso, as tendências graduais, são consideradas significativas se:

$$|Z| > Z_{1-\frac{\alpha}{2}} \quad (5)$$

o que indica que, para um nível de significância α , a hipótese nula é rejeitada. Um valor de Z positivo indica a presença de uma tendência positiva, e um valor negativo indica a presença de uma tendência negativa. O teste foi aplicado com nível de significância $\alpha = 0,05$.

3.4 ANÁLISE DE FREQUÊNCIA

3.4.1 Distribuição Generalizada de Valor Extremo (GEV)

A distribuição Generalizada de Valor Extremo (GEV) é uma combinação de três distribuições estatísticas assintóticas de valor extremo máximo, sendo elas: Gumbel, Fréchet e Weibull. A função densidade de probabilidade (PDF) da distribuição GEV é dada pela Equação (6):

$$g(x) = \frac{1}{\sigma} \left[1 - \xi \left(\frac{x - \mu}{\sigma} \right) \right]^{-\left(\frac{1}{\xi} + 1\right)} \exp \left\{ - \left[1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} \right\} \quad (6)$$

em que μ é o parâmetro de localização (média) e representa o centro da distribuição, σ é o parâmetro de escala (desvio padrão) e representa a distribuição dos dados em torno de μ , e ξ é o parâmetro de forma e descreve o comportamento da cauda da distribuição (assimetria).

Dois modelos foram considerados neste estudo: modelo estacionário (ST), em que os parâmetros da distribuição GEV são assumidos como sendo constantes ao longo do tempo; e modelo não estacionário (NS). No modelo NS, um ou mais parâmetros da PDF da distribuição de extremos variam com o tempo. Aqui, considerou-se que a média (μ) da distribuição GEV aumenta ou diminui linearmente ao longo do tempo, i.e., $\mu(t) = \mu_1 t + \mu_0$. O modelo estacionário possui três parâmetros a serem inferidos, $\theta = \{\mu, \sigma, \xi\}$, enquanto o modelo não estacionário possui quatro parâmetros, $\theta = \{\mu_0, \mu_1, \sigma, \xi\}$.

3.4.2 Inferência dos parâmetros

Neste trabalho, a inferência Bayesiana foi utilizada na estimativa dos parâmetros dos modelos ST e NS, permitindo a inferência conjunta do conjunto ótimo de parâmetros e da incerteza associada a esta estimativa. Na abordagem Bayesiana, as variáveis hidrológicas são consideradas como variáveis probabilísticas e então o Teorema de Bayes é utilizado para atualizar a probabilidade de uma determinada hipótese (modelo + conjunto de parâmetros) com base em uma evidência disponível (observações). Segundo este Teorema, a distribuição a *posteriori* dos parâmetros $P(\theta|\tilde{Y})$ é proporcional a distribuição a *priori* $P(\theta)$ e da função de verossimilhança $P(\tilde{Y}|\theta)$, i.e.,

$$P(\boldsymbol{\theta}|\tilde{\mathbf{Y}}) \propto P(\boldsymbol{\theta})P(\tilde{\mathbf{Y}}|\boldsymbol{\theta}) \quad (7)$$

A distribuição *a priori* resume a informação disponível a respeito dos valores dos parâmetros antes da análise dos dados disponíveis, a função de verossimilhança sumariza as informações fornecidas pelos dados utilizados na inferência e $\tilde{\mathbf{Y}} = \{\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_n\}$ é a série de intensidade máxima anual.

O algoritmo DREAM_(ZS) foi utilizado para aproximação da distribuição *a posteriori* dos parâmetros dos modelos ST e NS. Trata-se de um amostrador do tipo Markov Chain Monte Carlo (MCMC), que combina evolução diferencial (DE-MC) e inferência Bayesiana para obtenção conjunta da distribuição dos parâmetros e estimativa de incertezas. Mais detalhes sobre o funcionamento deste algoritmo são descritos em Vrugt *et al.* (2016). Como dados de entrada, foram fornecidas as séries de intensidade máxima diária anual de cada estação pluviométrica selecionada para este estudo.

A utilização do algoritmo DREAM_(ZS) exige que o usuário escolha o número de parâmetros do modelo (dimensão do problema, d); número de cadeias de Markov (N); e número de gerações (T). Foram utilizadas $N = 3$ cadeias de Markov com $T = 8.000$ gerações em cada cadeia, conforme sugerido por Luke *et al.* (2017). Para garantir que a distribuição *a posteriori* dos parâmetros dos modelos seja uma distribuição estacionária, 50% dos valores iniciais de cada cadeia foram descartados, resultando em uma distribuição *a posteriori* com 12.000 conjuntos de parâmetros. O primeiro elemento de cada cadeia de Markov foi amostrado por meio de uma distribuição uniforme com limites apresentados na Tabela 2.

Tabela 2 - Intervalos dos parâmetros dos modelos estacionário e não estacionário utilizados na inferência dos parâmetros.

Parâmetro	Intervalo		Unidade
	Mín.	Máx.	
μ_0	0	500	mm/d
μ_1	-5	5	mm/(d.ano)
σ	0	200	mm/d
ξ	-0,5	0,5	-

O usuário precisa definir também a função de verossimilhança a ser utilizada. Para um determinado conjunto de parâmetros $\boldsymbol{\theta}$ e uma série com n observações $\tilde{\mathbf{Y}} = \{\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_n\}$ i.e.,

$$L(\boldsymbol{\theta}|\tilde{\mathbf{Y}}) = \prod_{i=1}^n P(\tilde{y}_i|\boldsymbol{\theta}) \quad (8)$$

Para estudos relacionados a análise de frequência de extremos, como é o caso das Curvas IDF, a função de verossimilhança é a PDF da distribuição de extremos considerada. Portanto, para este estudo, a função de verossimilhança é a PDF da distribuição GEV, que para $\xi \neq 0$ é representada pela Equação 9.

$$L(\boldsymbol{\theta}|\tilde{\mathbf{Y}}) = \frac{1}{\sigma} \left[1 - \xi \left(\frac{\tilde{y}_i - \mu}{\sigma} \right) \right]^{-\left(\frac{1}{\xi} + 1\right)} \exp \left\{ - \left[1 + \xi \left(\frac{\tilde{y}_i - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} \right\} \quad (9)$$

Para o modelo ST, os valores da função de verossimilhança são calculados diretamente a partir de $\boldsymbol{\theta} = \{\mu, \sigma, \xi\}$. Já para o modelo NS, tem-se $\boldsymbol{\theta}_i = \{\mu_0 + \mu_1 t_i, \sigma, \xi\}$, em que t_i é o tempo (em anos) entre a primeira e a i -ésima observação de $\tilde{\mathbf{Y}}$.

Como citado, a utilização do DREAM_(ZS) permite também quantificar incertezas. Embora existam diversas fontes de incerteza a serem consideradas nas simulações de modelos (i.e, monitoramento, métodos e formulação dos modelos), neste trabalho levou-se em consideração apenas a incerteza associada à estimativa dos parâmetros. Para isto, foram utilizados os últimos 12.000 valores da distribuição *a posteriori* dos modelos ST e NS obtidos com o algoritmo DREAM_(ZS). Os resultados foram sumarizados por meio de intervalos de credibilidade de 95% (valores contidos entre os percentis 2,5 e 97,5).

3.4.3 Avaliação de desempenho

A comparação entre os resultados dos modelos ST e NS foi realizada de duas maneiras:

1. Inferência dos parâmetros a partir da série AMS completa e comparação realizada por meio dos critérios de informação (método 1);
2. Separação de um período da série AMS para inferência dos parâmetros e outro período para avaliação do desempenho do modelo (método 2);

3.4.3.1 Critérios de informação

O método 1 de avaliação de desempenho dos modelos consiste na utilização dos critérios de informação. Os critérios de informação são utilizados para estimar a atenuação de desempenho de um modelo ao ser utilizado em um período diferente do utilizado para inferência dos parâmetros, sem que seja necessário reservar uma parte da série de dados disponível exclusivamente para esta finalidade (OLIVEIRA *et al.*, 2018). São compostos por dois termos: um relacionado ao desempenho, que denota a habilidade de um modelo em reproduzir a série de dados utilizada no processo de inferência, e outro que penaliza a complexidade (número de parâmetros do modelo considerado e número de dados utilizados na inferência). Para este trabalho, os critérios de informação de Akaike (AIC_c) para séries de tamanho reduzido (AKAIKE, 1974) e Bayes (BIC) (SCHWARZ, 1978) foram utilizados e estão aqui representados pelas Equações (10) e (11), respectivamente:

$$AIC_c = -2 \ln(L^*) + \frac{2d(d+1)}{n-d-1} \quad (10)$$

e

$$BIC = -2 \ln(L^*) + d \ln(n) \quad (11)$$

em que L^* é o valor máximo da função de verossimilhança (conjunto ótimo de parâmetros); d é o número de parâmetros do modelo considerado; e n é o número de dados utilizados na inferência. O melhor modelo é aquele que minimiza o valor do critério de informação (entre todos os modelos em questão).

Como os critérios de informação são medidas relativas utilizadas para comparação entre diferentes modelos, o valor absoluto do critério de informação não possui nenhum significado (OLIVEIRA, 2018). Portanto, optou-se por calcular o suporte relativo do modelo ST, que é dado por meio da diferença entre o valor do critério de informação do modelo ST e o valor do critério de informação para o melhor modelo. O cálculo do suporte à utilização do modelo ST para os critérios de informação de Akaike e Bayes estão aqui representados pelas Equações (12) e (13), respectivamente:

$$\Delta AIC = AIC_{c,s} - AIC_{c,\min} \quad (12)$$

e

$$\Delta BIC = BIC_s - BIC_{\min} \quad (13)$$

em que ΔAIC (ou ΔBIC) é o suporte relativo à utilização do modelo ST; $\Delta AIC_{c,s}$ (ou ΔBIC_s) é o valor do critério de informação do modelo ST; e $AIC_{c,\min}$ (ou BIC_{\min}) é o valor do critério de informação do melhor modelo.

Segundo Luke *et al.* (2017), valores ΔAIC (ou ΔBIC) entre 0 e 2 indicam suporte considerável para utilização do modelo ST, valores de 7 a 10 indicam a inexistência de suporte a utilização do modelo ST.

3.4.3.2 Validação dos modelos

Para o método 2 de seleção dos modelos, cada série de dados foi separada em duas partes, sendo um período utilizado para inferência dos parâmetros e outro período para avaliar o desempenho dos modelos. A fim de se garantir ao menos 30 anos de observações para a inferência dos parâmetros da distribuição de extremo e 30 anos para validação dos modelos, apenas estações pluviométricas com ao menos 60 anos de observações foram consideradas. A utilização deste método permite a obtenção de resultados mais robustos quando comparado ao método 1, porém, reduziu significativamente o número de estações pluviométricas disponíveis (de 696 para 82 estações pluviométricas).

Destaca-se aqui a validação do modelo NS, que foi conduzida de duas maneiras:

1. Utilização de um modelo não estacionário (NS), com a extrapolação da tendência inferida, ou seja, considerou-se que a média da distribuição de extremos continua aumentando ou diminuindo ao longo do período de validação;

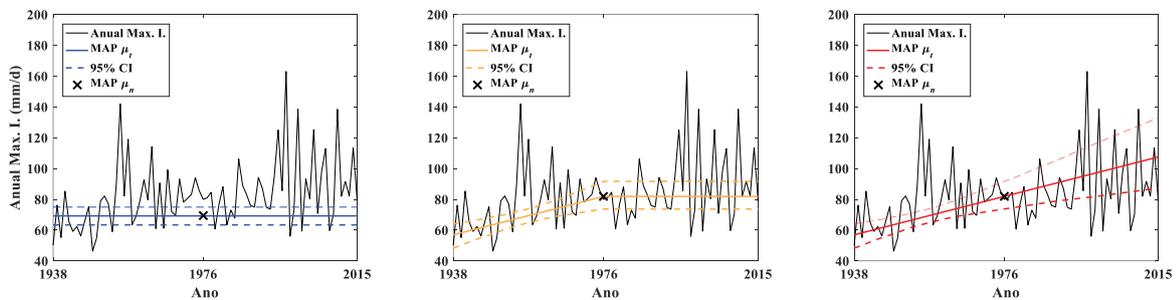
2. Aplicação de um modelo estacionário atualizado (uST), que utiliza os parâmetros do modelo NS ao final do período de inferência dos parâmetros, ou seja, a média da distribuição de extremos é calculada para um determinado tempo t utilizando-se o modelo NS (um modelo estacionário é atualizado através dos parâmetros de um modelo não estacionário), assim, considera-se o aumento ou redução observado na média durante o período de inferência, porém, sem extrapolá-lo.

A avaliação do desempenho dos modelos durante o período de validação foi realizada por meio do cálculo do valor da função de verossimilhança associado ao conjunto ótimo de parâmetros (L_{MAP}) – conjunto de parâmetros que maximiza a distribuição a *posteriori* (*maximum a posteriori*, MAP) e do valor médio da função de verossimilhança para todos os 12.000 conjuntos de parâmetros (L_{MED}). Na primeira abordagem, leva-se em consideração

apenas o desempenho ótimo do modelo, ou seja, sua habilidade em reproduzir a série de dados, enquanto na segunda, considera-se a incerteza acerca da inferência dos parâmetros.

A Figura 3 ilustra a média da distribuição GEV para os modelos estacionário (ST), estacionário atualizado (uST) e não estacionário (NS) para os períodos de inferência dos parâmetros e de validação.

Figura 3 - Exemplo de comparação entre os valores de média durante o período de inferência dos parâmetros e validação para os modelos estacionário (ST), estacionário atualizado (uST) e não estacionário (NS), respectivamente, para a estação pluviométrica 02349033, que apresentou tendência significativa de sinal positivo (quando avaliada para a série completa). O x em preto representa o final do período utilizado para inferência dos parâmetros. A linha contínua representa a média da distribuição GEV, e as linhas tracejadas representam o intervalo de credibilidade de 95% da estimativa da média.



4 RESULTADOS E DISCUSSÃO

4.1 AVALIAÇÃO DE DESEMPENHO: CRITÉRIOS DE INFORMAÇÃO

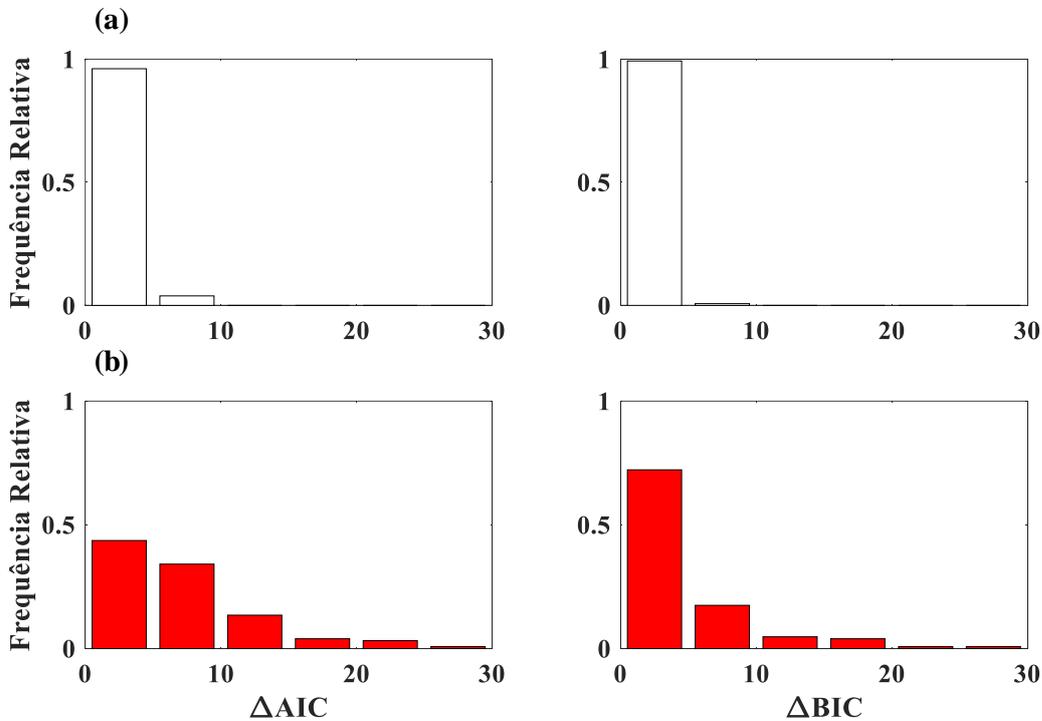
Os resultados dos critérios de informação de Akaike e de Bayes, utilizados para a avaliação de desempenho dos modelos ST e NS com parâmetros inferidos a partir da série AMS completa (método 1), para intensidade de precipitação de um dia de duração são apresentados na

Figura 4. Os resultados foram separados de acordo com a presença ou ausência de tendência significativa, detectada a partir do teste de Mann-Kendall, ao nível de significância $\alpha = 0,05$.

De maneira geral, os resultados mostram que quando não há presença de tendência significativa no período utilizado para inferência dos parâmetros dos modelos há maior suporte para a utilização do modelo ST (mais simples). Isto pode ser constatado devido à alta frequência de pequenos valores de ΔAIC e ΔBIC (Figura 4a). Estações pluviométricas com tendência significativa resultaram em maiores valores de ΔAIC e ΔBIC (Figura 4b). Este resultado sugere que a presença de tendência significativa durante o período de inferência dos parâmetros favorece a escolha de um modelo NS.

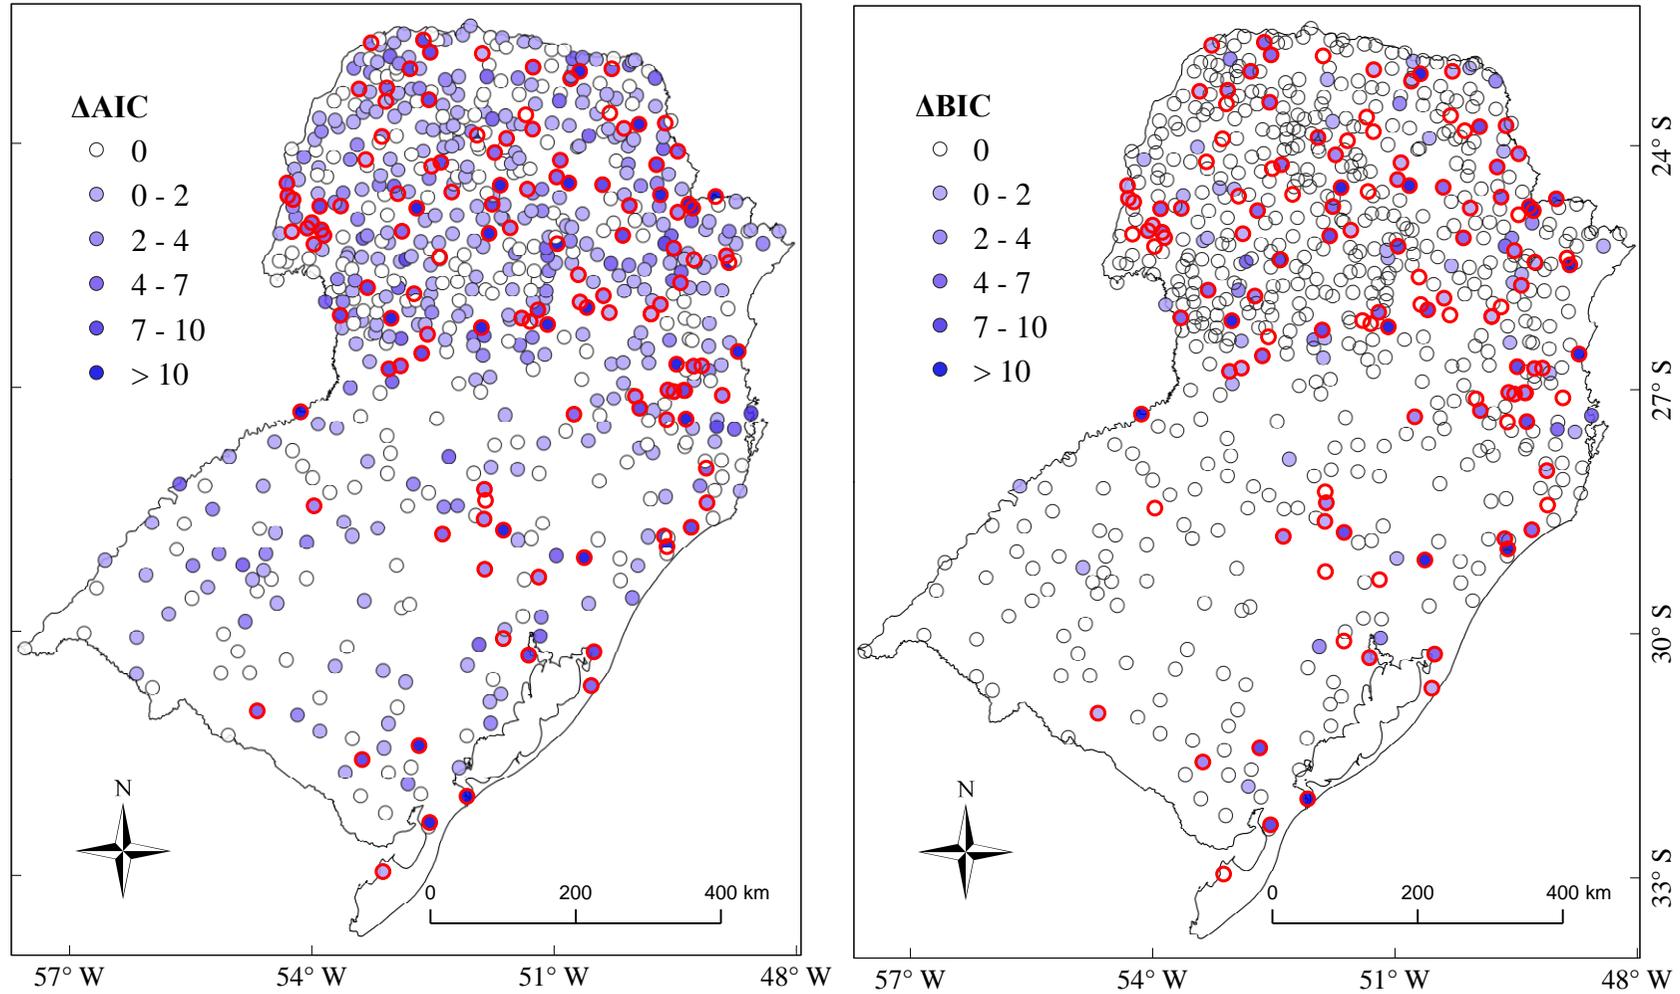
Em uma análise mais detalhada, o critério de informação de Bayes foi mais conservador no quesito adição de complexidade quando comparado ao critério de informação de Akaike, resultando em um maior favorecimento para a escolha do modelo ST. Considerando o critério de informação de Akaike, tem-se um maior suporte para a seleção do modelo NS, mesmo para séries temporais sem tendência significativa. Isto pode ser explicado devido ao seu maior potencial em maximizar o valor da função de verossimilhança, já que este modelo possui um maior número de parâmetros. Este resultado sugere que este critério de informação possui uma inabilidade em penalizar a complexidade dos modelos de maneira adequada, em que a seleção entre os modelos ST e NS é dominada pelo valor da função de verossimilhança, i.e., em sua capacidade de reproduzir a série de dados utilizada na inferência.

Figura 4 – Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₁. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).



A Figura 5 ilustra os valores de ΔAIC e de ΔBIC para todas as estações pluviométricas consideradas neste estudo, também para intensidades de precipitação de um dia. Percebe-se que há um padrão espacial, em que os maiores valores de ΔAIC e de ΔBIC ocupam principalmente o estado do Paraná.

Figura 5 - Valores de ΔAIC (à esquerda) e ΔBIC (à direita) para séries AMS_1 . As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte para o modelo ST.



Os resultados aqui apresentados e discutidos para a intensidade de precipitação de um dia de duração podem ser observados também para intensidades de durações superiores. Sendo assim, o padrão espacial observado se mantém, i.e., maiores valores de ΔAIC e de ΔBIC estão localizados no estado do Paraná. Além disso, as métricas de desempenho também apresentam o mesmo comportamento, em que maiores valores de ΔAIC e de ΔBIC se manifestam para séries AMS com tendência significativa. As Figuras Figura 6 e Figura 7 ilustram os resultados obtidos para os critérios de informação para a intensidade de precipitação de sete dias de duração.

Figura 6 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₇. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

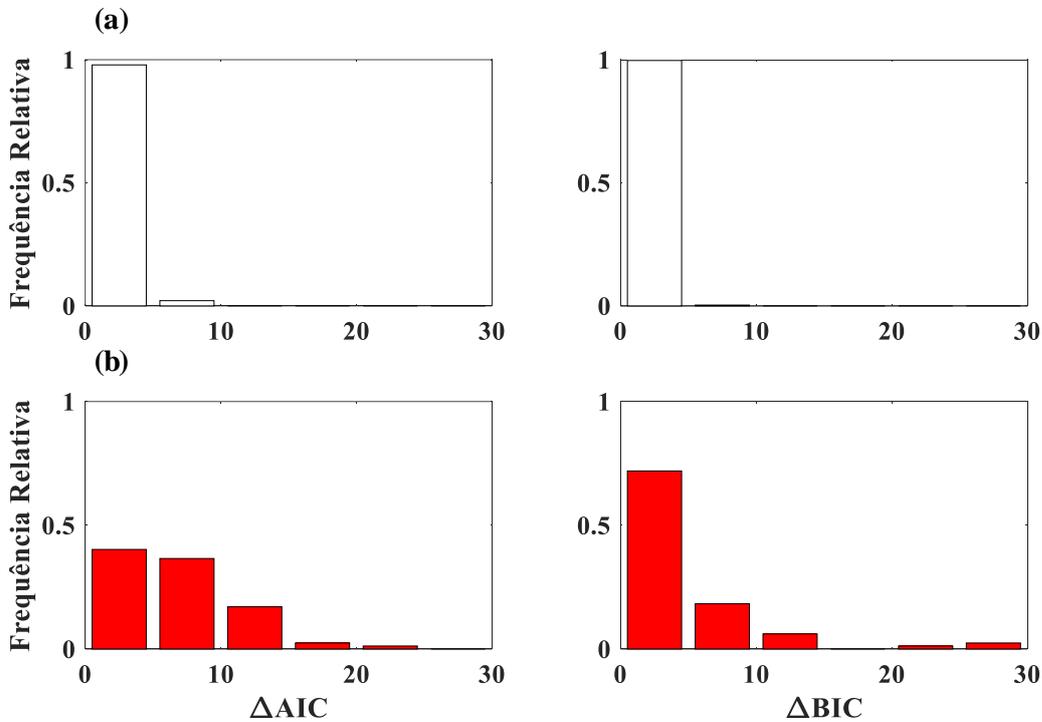
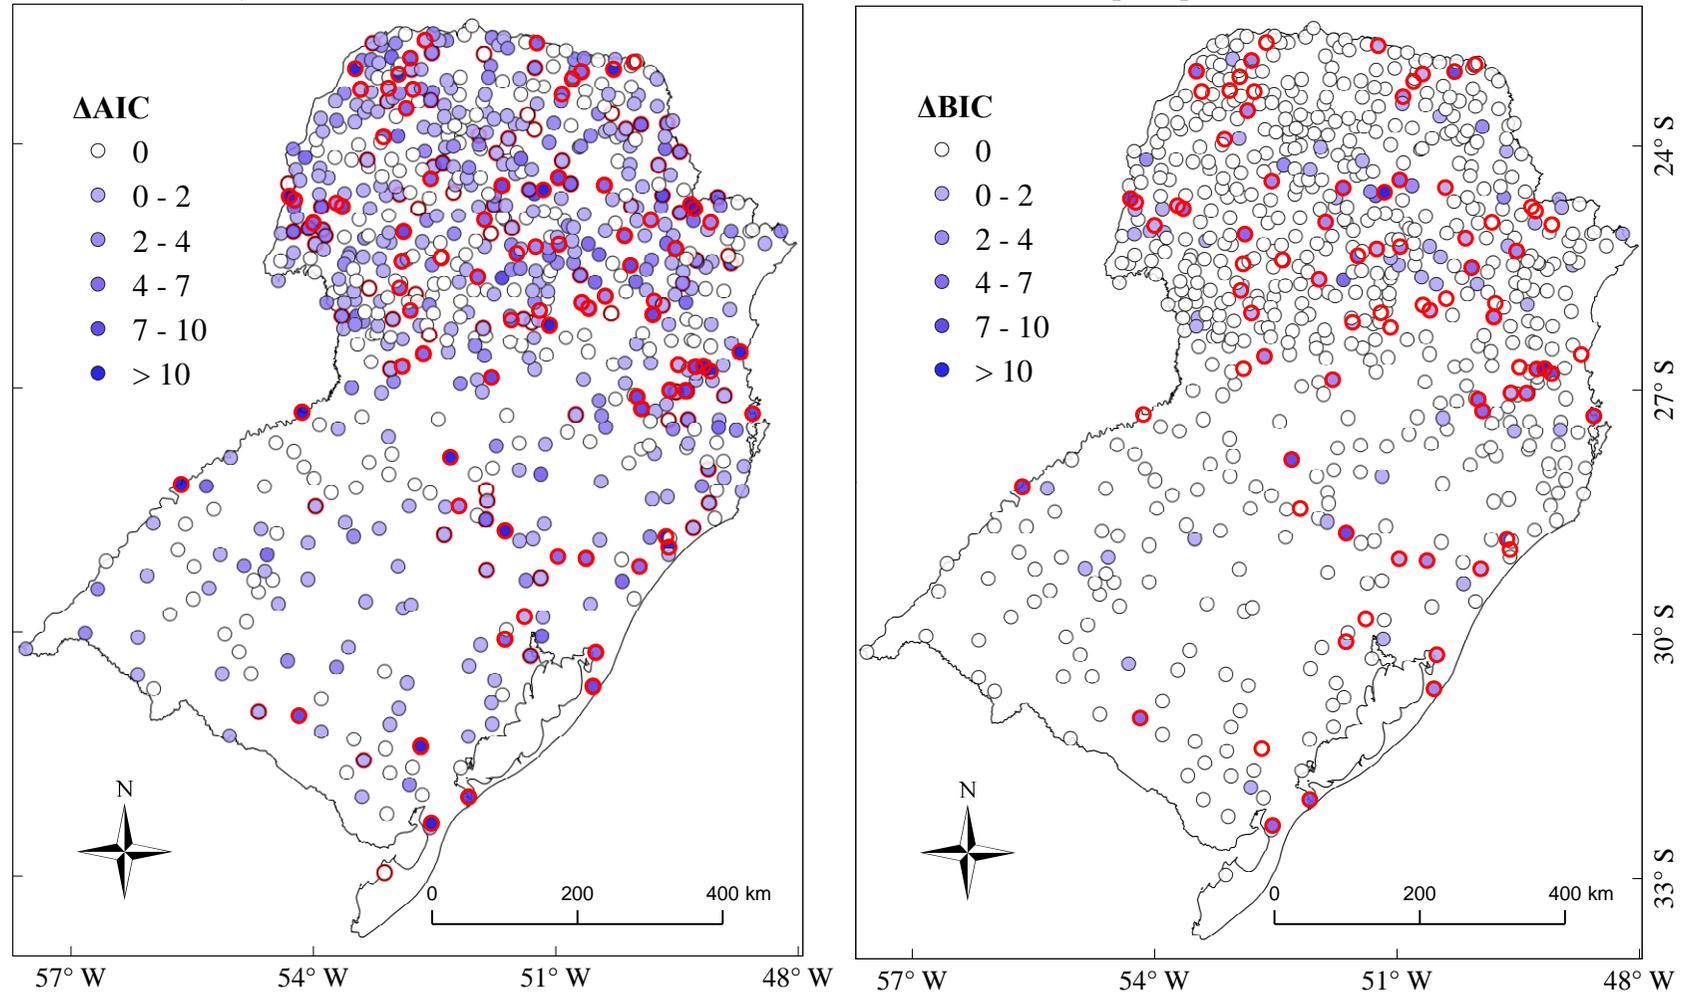


Figura 7 - Valores de (a) ΔAIC e (b) ΔBIC para séries AMS₇. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte para o modelo ST.



É possível perceber que, utilizando o critério de informação de Bayes, para uma mesma estação pluviométrica, mas considerando intensidades de diferentes durações, há concordância entre a seleção do modelo ST e NS. Por exemplo, para séries sem tendência significativa (614), o modelo ST foi escolhido 537 vezes, ou seja, em 537 estações pluviométricas o modelo ST teve o melhor desempenho para todas as sete durações consideradas. Já para séries com tendência (82), o modelo ST foi selecionado apenas 15 vezes. Para o critério de informação de Akaike, este padrão não é tão claro. Este resultado sugere que o critério de informação de Bayes consegue selecionar o melhor modelo de maneira mais coerente.

4.2 AVALIAÇÃO DE DESEMPENHO E ANÁLISE DE INCERTEZA: VALIDAÇÃO

Os resultados obtidos com a utilização do segundo método de avaliação de desempenho dos modelos ST e NS, i.e., com a separação da série de dados em um período de validação independente do período utilizado para a obtenção dos valores dos parâmetros da distribuição de extremos (método 2), são apresentados na Tabela 3.

Tabela 3 - Número de séries com melhor desempenho na validação para cada um dos modelos (estacionário – ST, estacionário atualizado – uST e não estacionário – NS) considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança (L_{MED}) de todas estações pluviométricas, para séries AMS de 1 a 7 dias.

Modelo	ST		uST		NS	
	L_{MAP}	L_{MED}	L_{MAP}	L_{MED}	L_{MAP}	L_{MED}
1	24	44	23	25	35	13
2	15	40	25	28	42	14
3	12	40	25	25	45	17
4	10	34	25	31	47	17
5	16	33	19	30	47	19
6	18	33	19	28	45	21
7	12	35	25	28	45	19

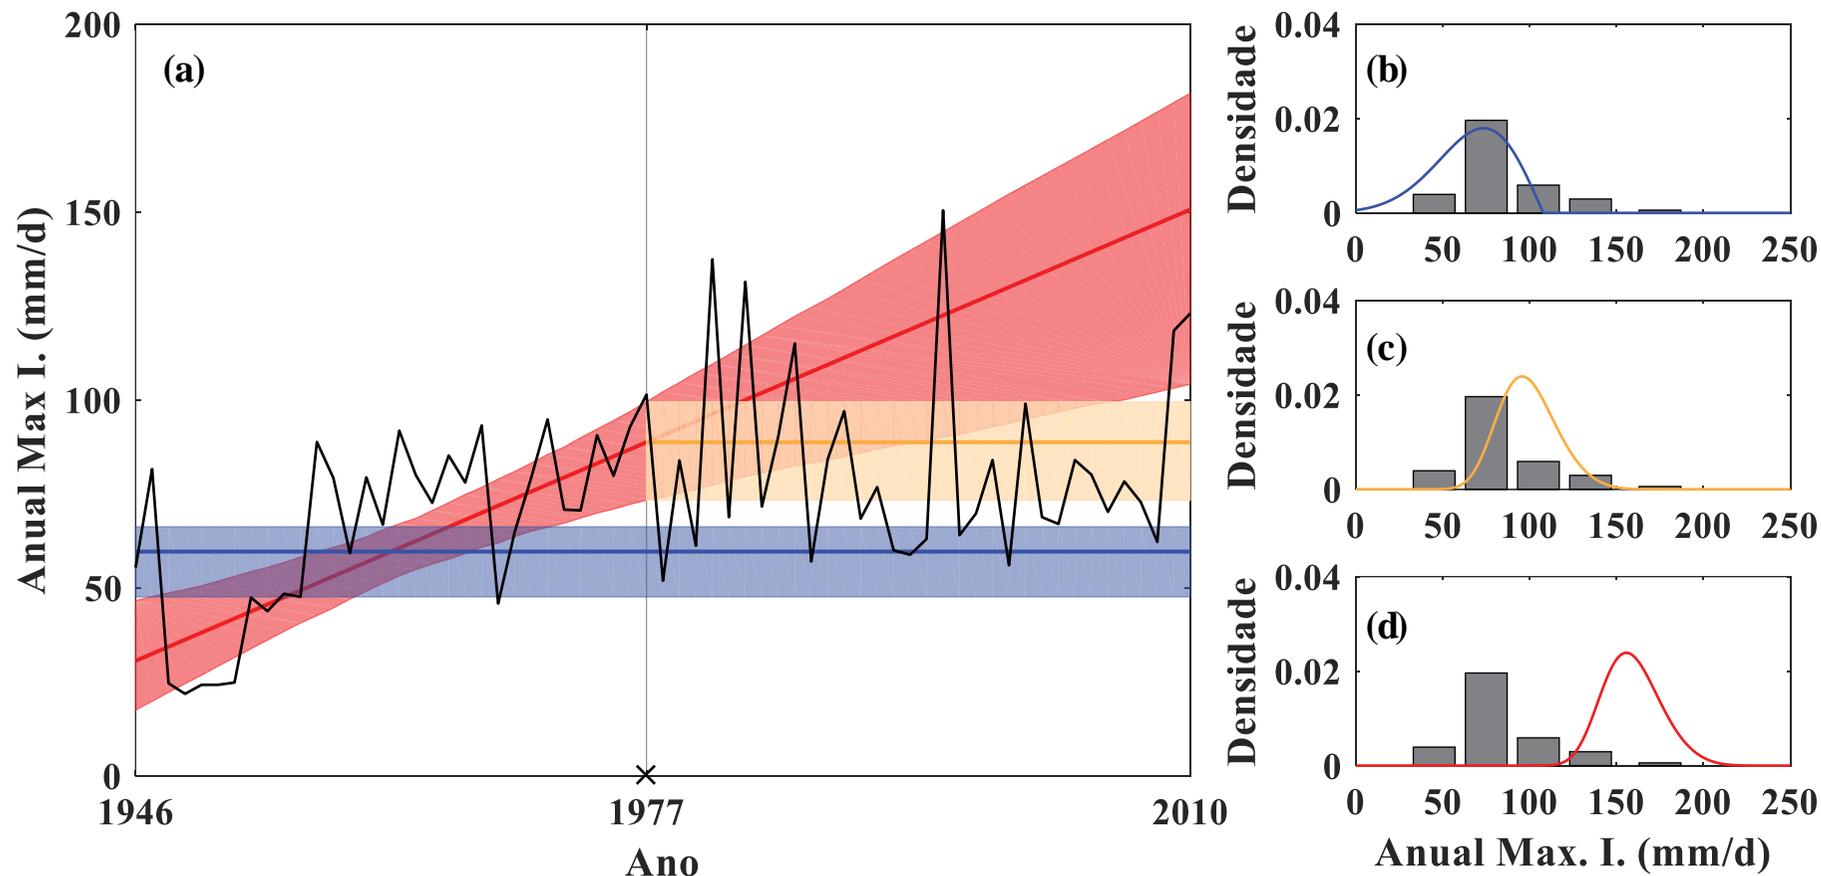
Considerando o desempenho dos modelos associado apenas ao conjunto ótimo de parâmetros (L_{MAP}), o modelo NS resultou em um maior número de estações com maiores valores para a função de verossimilhança para todas as intensidades de precipitação consideradas, o que denota uma maior habilidade deste modelo em reproduzir a série de dados utilizada no período de validação. O modelo uST, que possui características não estacionárias, também recebeu maior suporte quando comparado

ao modelo ST (com exceção para intensidade de 1 dia). Entretanto, quando a incerteza acerca da inferência dos parâmetros da distribuição de extremos é considerada, i.e., analisando o valor médio da função de verossimilhança para todos os 12.000 conjuntos de parâmetros (L_{MED}), o suporte ao modelo NS reduziu de maneira expressiva. Os resultados aqui encontrados vão ao encontro ao observado em outros estudos (e.g., Serinaldi e Kilsby, 2015) em que é constatado que o acréscimo de incerteza promovida pela adição de complexidade é uma das principais limitações do uso de modelos NS. Este resultado mostra a importância de se considerar a incerteza acerca da inferência dos parâmetros na comparação entre modelos ST e NS, conforme sugerido por Luke *et al.* (2017).

A Figura 8 ilustra a utilização de modelos ST, uST e NS, para estação pluviométrica Taquaruçu (02849004), localizada no município de Araranguá/SC, que apresentou tendência de sinal positivo quando avaliada para o período de inferência dos parâmetros (1946 - 1977). Os quadros b-d ilustram a comparação entre a densidade empírica calculada para os dados utilizados no período de validação dos modelos e a densidade obtida com as simulações dos modelos utilizando-se o conjunto ótimo de parâmetros. Os resultados mostram que a utilização de modelos uST e NS faz com que a densidade simulada se afaste das observações (em direção a maiores valores). É possível constatar também que os modelos com características não estacionárias (i.e., uST e NS) apresentam um intervalo de credibilidade com maior amplitude (Figura 8a), i.e., maior incerteza acerca da estimativa dos valores da média.

O percentil 100 da distribuição GEV (q_{100}) pode ser utilizado para estimar a intensidade de precipitação associada a um período de retorno de 100 anos. Considerando a abordagem tradicional utilizada em projetos hidráulicos de infraestrutura e de gestão de Recursos Hídricos (modelo ST), q_{100} é igual a 103 mm/d. Para o modelo uST, tem-se uma estimativa de 137 mm/d (+ 33%). Supondo que a frequência de eventos extremos é de fato não estacionária, e que a média da distribuição da série AMS_1 continua crescendo de acordo com a tendência inferida a partir do conjunto ótimo de parâmetros do modelo NS, i.e., extrapolação da tendência observada no período de inferência dos parâmetros para o ano final da série (2010), o percentil 100 para este modelo é igual a 199 mm/d (+ 93%). Considerar a extrapolação da tendência inferida é um procedimento arriscado e deve ser feito com cautela, uma vez que a origem e a persistência desta tendência ao longo do tempo são desconhecidas. Além disso, condicionar a não-estacionariedade das séries temporais a uma covariável como o tempo é uma abordagem puramente estatística. Sendo assim, não é capaz de considerar características físicas associadas a não estacionariedade. Luke *et al.* (2017) sugere condicionar a não-estacionariedade a outras covariáveis, como mudanças hidroclimáticas e na cobertura da superfície terrestre.

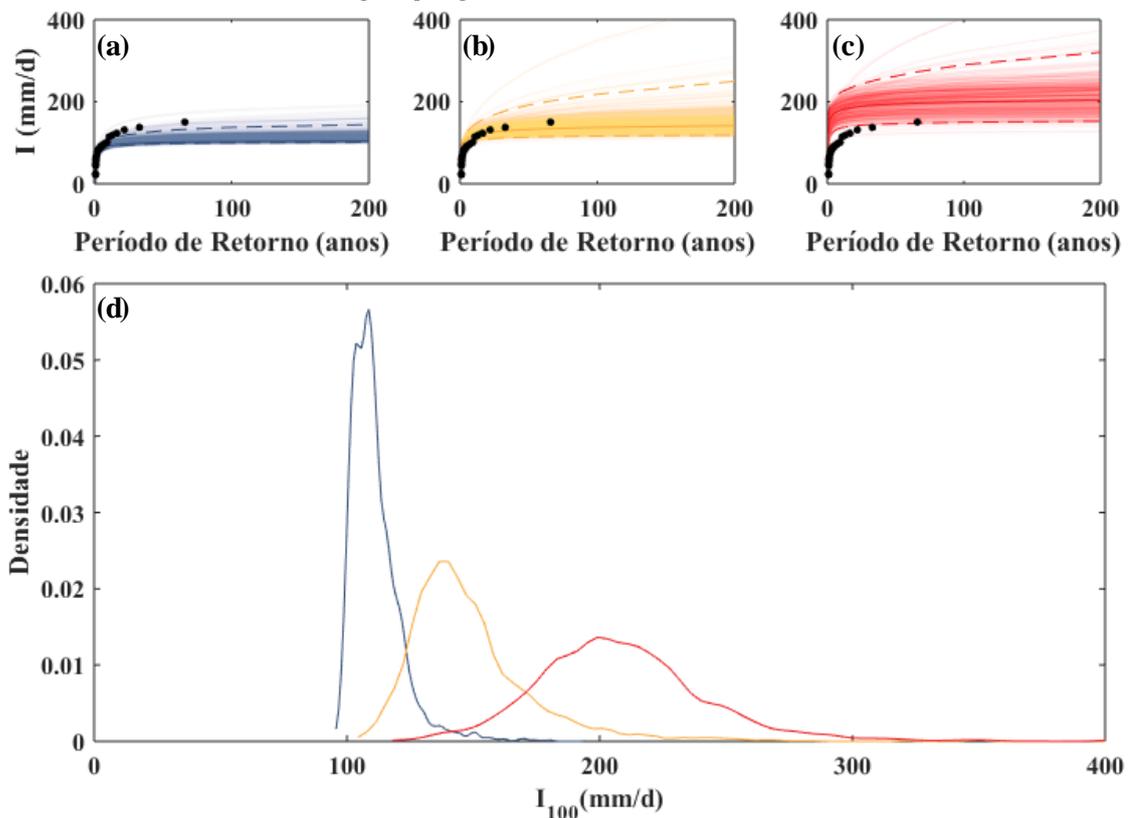
Figura 8 – (a) Média da distribuição GEV obtida através do conjunto ótimo de parâmetros para os modelos ST (azul), uST (dourado) e NS (vermelho), inferidos a partir da primeira metade da série AMS_1 (linha preta) – estação pluviométrica 02849004, que apresentou tendência significativa de sinal positivo (quando avaliada para o período de inferência dos parâmetros). As faixas sombreadas em azul, dourado e vermelho representam um intervalo de credibilidade de 95% da estimativa da média para os modelos ST, uST e NS, respectivamente. (b-d) Histogramas em preto representam a densidade empírica para os dados utilizados durante o período de validação, e as linhas contínuas ilustram a densidade dos modelos ST (azul), uST (dourado) e NS (vermelho, ano de 2010) para o conjunto ótimo de parâmetros.



Estas constatações são especialmente importantes do ponto de vista da Engenharia. A seleção de modelos com características não estacionárias para estimativa de intensidade de precipitação para uma série temporal estacionária pode levar à superestimativa da chuva de projeto – estruturas superdimensionadas remetem a maiores custos de implantação. A recíproca também é verdadeira, em que a falsa seleção de um modelo ST pode resultar em estruturas hidráulicas subdimensionadas (maior suscetibilidade a falhas).

A Figura 9 ilustra a influência em utilizar modelos ST, uST e NS (extrapolação para um tempo t em específico) na estimativa de intensidade de precipitação para diferentes períodos de retorno.

Figura 9 – Exemplo de comparação entre modelos (a) ST, (b) uST e (c) NS na estimativa de intensidade de precipitação para diferentes períodos de retorno para estação pluviométrica 02849004. Linhas contínuas representam as intensidades de precipitação associada a diferentes conjuntos de parâmetros. Linhas tracejadas representam intervalos de credibilidade de 95%, e as bolas pretas são os valores empíricos (d) Densidade de probabilidade para intensidade de 100 anos de período de retorno para modelos ST (azul), uST (dourado) e NS (vermelho). OBS: modelo NS com extrapolação para o ano final da série AMS₁ (2010).



Através dos valores de densidade de probabilidade para intensidade de 100 anos de período de retorno (Figura 9d), é possível estabelecer em qual “região” os valores se encontram concentrados. Assim como observado anteriormente para a média, os intervalos de confiança

dos valores de intensidade para diferentes períodos de retorno associados a modelos com características não estacionárias são mais amplos (maiores incertezas).

Resultados semelhantes foram encontrados para estações pluviométricas com séries AMS com tendência significativa de sinal negativo. A Figura 10 ilustra a utilização de modelos ST, uST e NS, para estação pluviométrica Porto Lucena (02755001), localizada no município de Porto Lucena/RS, que apresentou tendência de sinal negativo quando avaliada para o período de inferência dos parâmetros (1950 - 1982). Os quadros b-d ilustram a comparação entre a densidade empírica dos dados utilizados no período de validação dos modelos e a densidade obtida com as simulações dos modelos utilizando-se o conjunto ótimo de parâmetros. De forma idêntica ao observado anteriormente, a utilização de modelos uST e NS faz com que a densidade simulada se afaste das observações (em direção a menores valores).

Para o caso de tendência significativa de sinal negativo, modelos com características não estacionárias necessitam de maior atenção. Além da maior incerteza acerca da determinação de seus parâmetros, estão associados a estimativas de menores valores de intensidade de precipitação quando comparados com o modelo ST, já que a média diminuindo ao longo do tempo. Para este caso, a utilização de uma abordagem não estacionária não é recomendada, pois assume maiores riscos.

Figura 10 – (a) Média da distribuição GEV obtida através do conjunto ótimo de parâmetros para os modelos ST (azul), uST (dourado) e NS (vermelho), inferidos a partir da primeira metade da série AMS_1 (linha preta) – estação pluviométrica 02755001, que apresentou tendência significativa de sinal negativo (quando avaliada para o período de inferência dos parâmetros). As faixas sombreadas em azul, dourado e vermelho representam um intervalo de credibilidade de 95% da estimativa da média para os modelos ST, uST e NS, respectivamente. (b-d) Histogramas em preto representam a densidade empírica para os dados utilizados durante o período de validação, e as linhas contínuas ilustram a densidade dos modelos ST (azul), uST (dourado) e NS (vermelho, ano de 2010) para o conjunto ótimo de parâmetros.

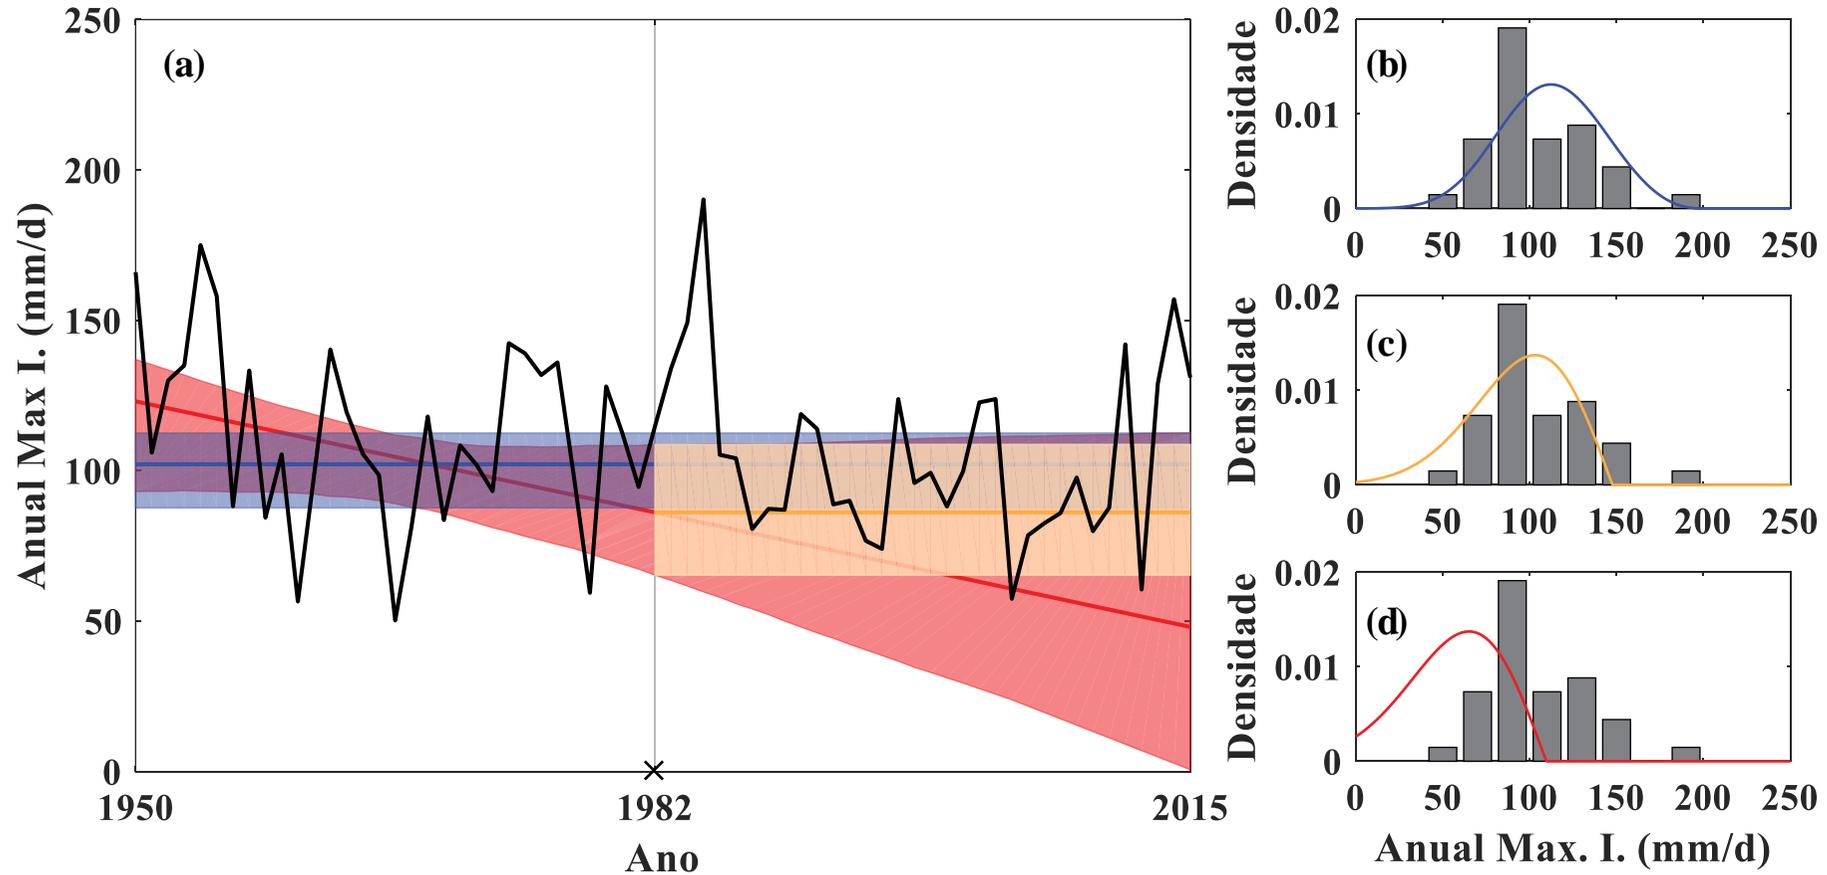
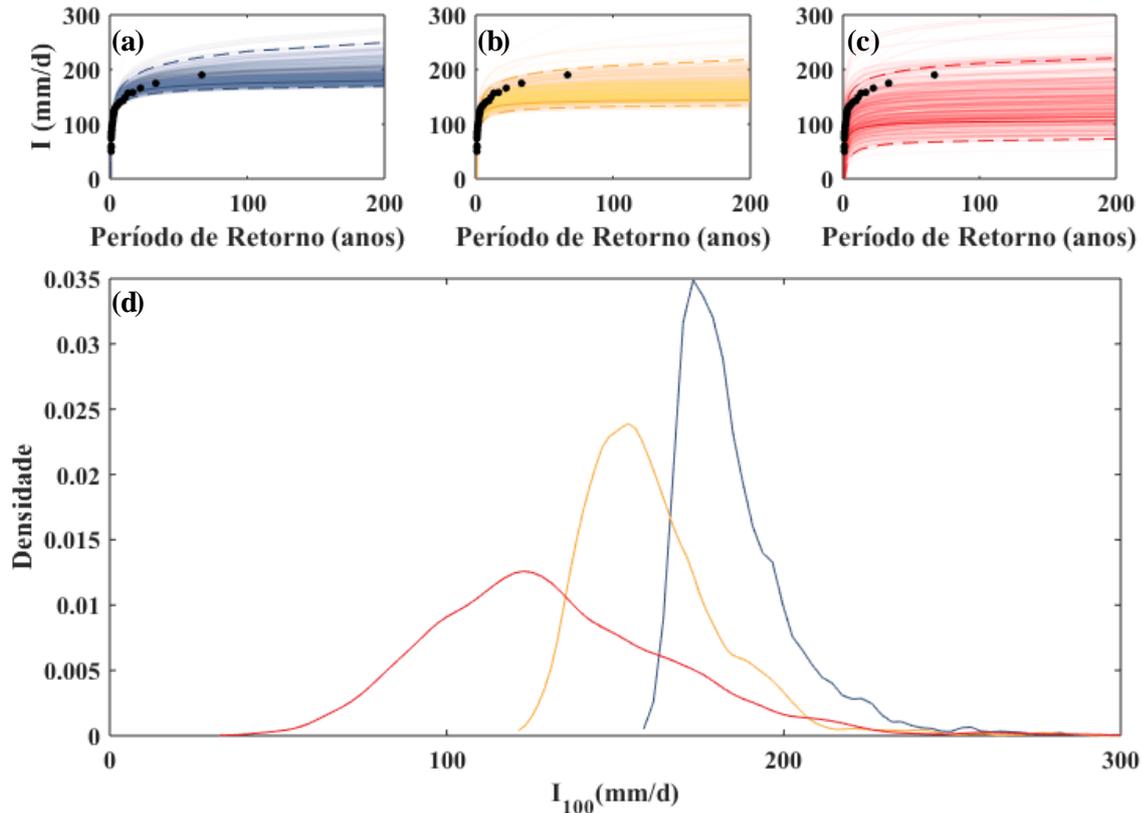


Figura 11 - Exemplo de comparação entre modelos (a) ST, (b) uST e (c) NS na estimativa de intensidade de precipitação para diferentes períodos de retorno para estação pluviométrica 02755001. Linhas contínuas representam as intensidades de precipitação associada a diferentes conjuntos de parâmetros. Linhas tracejadas representam intervalos de credibilidade de 95%, e as bolas pretas são os valores empíricos (d) Densidade de probabilidade para intensidade de 100 anos de período de retorno para modelos ST (azul), uST (dourado) e NS (vermelho). OBS: modelo NS com extrapolação para o ano final da série AMS₁ (2015).



Os resultados obtidos para validação dos modelos e análise de incerteza da estimativa dos parâmetros dos modelos sugerem que a presença de tendência significativa (de sinal positivo ou negativo) não é uma condição suficiente para justificar a utilização de modelos não estacionários na análise de frequência de extremos. Conforme sugerido por Luke *et al.* (2017), a utilização de modelos NS é justificada somente para casos em que a origem, comportamento e a permanência da não-estacionariedade ao longo do tempo sejam conhecidas, que dificilmente pode ser constatada por meio de estudos de tendência. Portanto, há uma necessidade de incluir processos físicos relevantes aos modelos estocásticos (MONTANARI; KOUTSOVIANNIS, 2014).

5 CONCLUSÕES E RECOMENDAÇÕES

Neste trabalho, realizou-se uma comparação entre a utilização de modelos estacionário e não estacionário para a determinação de Curvas IDF para séries históricas de precipitação relativas à região sul do Brasil. Os modelos utilizados foram baseados na distribuição GEV. A estimativa dos valores dos parâmetros e suas respectivas incertezas foram quantificadas a partir da Inferência Bayesiana, com a utilização do algoritmo DREAM_(ZS).

Os resultados para a análise de tendência significativa, detectadas a partir do teste de Mann-Kendall, ao nível de significância 0,05 mostram que há presença de tendência significativa para séries de intensidade máxima anual em todas as durações (i.e., 1 a 7 dias) investigadas neste trabalho. Além disso, constatou-se que há um padrão espacial, em que o Paraná é o estado com maior número de estações com tendência significativa.

A utilização de métodos de seleção de modelos, como os critérios de informação de Akaike e de Bayes, bem como considerar o desempenho dos modelos durante o período de validação relativo ao conjunto ótimo de parâmetros, sugerem a utilização de modelos NS para a previsão de eventos extremos, especialmente quando há presença de tendência significativa no período de calibração dos parâmetros da distribuição de extremos. Entretanto, quando a incerteza associada à estimativa dos parâmetros da distribuição de extremos é considerada, o suporte ao modelo NS diminui de maneira considerável.

Os resultados aqui encontrados demonstram a necessidade de se considerar a incerteza na estimativa dos parâmetros na comparação entre modelos ST e NS, e que a presença de tendência no período de calibração não é uma justificativa forte o bastante para justificar a seleção de um modelo NS na análise de frequência de extremos.

Para trabalhos futuros, recomenda-se que a não estacionariedade seja condicionada a covariáveis que sejam capazes de viabilizar o entendimento da origem, comportamento e persistência das tendências ao longo do tempo, conforme sugerido por outros estudos (e.g., Merz *et al.*, 2014).

REFERÊNCIAS

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automation Control**, v.19 n.6, p. 716–723, 1974.
- ANA - AGÊNCIA NACIONAL DE ÁGUAS. **HidroWeb: Sistema de Informações Hidrológicas**. 2015 Disponível em:<<http://www.snirh.gov.br/hidroweb/apresentacao>>. Acesso em 12 jan. 2017.
- ARAGÃO, R.; SANTANA, G. R.; COSTA, C. E. F. F.; CRUZ, MARCUS, A. S.; FIGUEIREDO, E. E.; SRINIVASAN, V. S. Chuvas intensas para o estado de Sergipe com base em dados desagregados de chuva diária, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 3, p. 243-252, 2013.
- BACK, A. J.; BONETTI, A. V. Chuva de projeto para instalações prediais de águas pluviais de Santa Catarina, **Revista Brasileira de Recursos Hídricos**, v. 19. n. 4, p. 260-267, 2014.
- BACK, A. J.; HENN, A.; OLIVEIRA, J. L. R. Heavy Rainfall equations for Santa Catarina, Brazil, **Revista Brasileira de Ciências do Solo**, v. 35, p. 2127-2134, 2011.
- BRAGA, R. N. S.; HORA, M. A. G. M.; LYRA, G. B.; NASCENTES, A. L. Determinação e interpolação dos coeficientes das equações de chuvas intensas para cidade do Rio de Janeiro. **Revista Ambiente & Água**, v. 13, n. 1, p. 1-14, 2018.
- CAMPOS, A. R.; SANTOS, G. G., SILVA, J. B. L.; FILHO, J. I.; LOURA, D. S. Equações de intensidade-duração-frequência de chuvas para o estado do Piauí, **Revista Ciência Agrônômica**, v. 45, n. 3, p. 488-498, 2014.
- CAMPOS, A. R.; SILVA, J. B. L.; SANTOS, G. G.; RATKE R. F. AQUINO, I. O. Estimate of intense rainfall equation parameters for rainfall stations of the Paraíba State, Brazil, **Pesquisa Agropecuária Tropical**, v. 47, n. 1, p. 15-21, 2017.
- CHAGAS, V. B. P.; CHAFFE, P. L. B. The Role of Land Cover in the Propagation of Rainfall into Streamflow Trends. **Water Resources Research**, v. 54, p. 5986–6004, 2018.
- CHENG, L.; AGHAKOUCHAK, A. Nonstationary precipitation intensity-duration-frequency curves for infrastructure design in a changing climate. **Scientific Reports**, v. 4, p. 7093, 2014.
- CUNHA, G. J. G.; VARGAS, E. A. J. A coupled system based on Differential Evolution for the determination of Rainfall intensity equations, **Revista Brasileira de Recursos Hídricos**, v. 23, n. 55, p. 1-12, 2018.
- CURRIERO, F. C.; PATZ, J. A.; ROSE, J. B.; LELE, S. The association between extreme precipitation and waterborne disease outbreaks in the United States, 1948–1994. **American Journal of Public Health**, v. 91, n. 8, p. 1194–1199, 2001.
- DOOCY S.; DANIELS A.; MURRAY S.; KIRCH TD. The Human Impact of Floods: a Historical Review of Events 1980-2009 and Systematic Literature Review. **PLOS Currents Disasters**. p. 1-29, 2013.

DORNELES, V.R.; DAMÉ, R. C.F.; TEIXEIRA-GANDRA, C. F. A.; MÉLLO, L.B.; RAMIREZ, M. A. A.; MANKE, E.B. Intensity-duration-frequency relationships of rainfall through the technique of disaggregation of daily rainfall, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 23, n. 7, p. 506-510, 2019.

FALAGUASTA, L. N.; GENOVEZ, A. M. Equações de Chuvas Intensas Generalizadas para os Estados de São Paulo e Paraná, **Revista Brasileira de Recursos Hídricos**, v. 8, n. 3, p 169-176, 2003.

FECHINI, V. S.; RODRIGUES, J. O.; MENDONÇA, L. A. R.; ANDRADE, E. M.; TAVARES, P. R. L. Desenvolvimento de equações Intensidade-Duração-Frequência sem dados pluviográficos em regiões semiáridas, *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 18, n. 7, p. 727-734, 2014.

GARCIA, G. G.; C. C.; AMORIM R. S. S.; GRIEBELER, N. P. Determinação da equação intensidade-duração-frequência para três estações meteorológicas do Estado de Mato Grosso, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 6, p. 575-581, 2011

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. IBGE - Mapas. 2010. Disponível em: < <http://mapas.ibge.gov.br/bases-e-referenciais/basescartograficas/malhas-digitais.html> >. Acesso em: 3 set. 2019.

IPCC (2014) Climate change 2014: impacts, adaptation, and vulnerability. Part A: global and sectoral aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. In: Field CB, Barros VR, Dokken DJ, Mach KJ, MastrandreaMD, Bilir TE, Chatterjee M, Ebi KL, Estrada YO, Genova RC, Girma B, Kissel ES, Levy AN, MacCracken S, Mastrandrea PR, White LL (eds). **Cambridge University Press, Cambridge**, pp 1132

KENDALL, M. G. Rank Correlation Methods. 4 ed. London: Charles Griffin, 1975;

LUKE, A.; VRUGT, J. A.; AGHAKOUCHAK, A; MATTHEW, R.; SANDERS, B. F. Predictiong nonstationarity flood frequencies: Evidence supports and updated stationarity thesis in the United States. **Water Resources Research**, p. 1–26, 2017.

MANN, H. B. Nonparametric tests against trend. **Econometrica: Journal of the Econometric Society**, p. 245-259, 1945;

MARTELLONI, G.; SEGONI, S.; FANTI, R.; Catani, F. Rainfall thresholds for the forecasting of landslide occurrence at regional scale. **Landslides**, v. 9, n. 4, p. 485–495, 2012.

MILLY, P. C. D.; BETANCOURT, J.; FALKENMARK, M.; et al. On Critiques of “stationarity is Dead: Whither Water Management?” **Water Resources Research**, v. 51, n. 9, p. 7785–7789, 2015.

MERZ, B.; et al. (2014). Floods and climate: Emerging perspectives for flood risk assessment and management. **Natural Hazards and Earth System Sciences**, v. 14, n. 7, p. 1921–1942.

MILLY, P. C. D.; BETANCOURT, J.; FALKENMARK, M.; et al. Stationarity is Dead: Whither water management? **Science**, v. 319, p. 573–574, 2008.

MONTANARI, A.; KOUTSOYIANNIS, D. Modeling and mitigating natural hazards: Stationary is immortal. **Water Resources Research**, p. 9748–9756, 2014.

NISSEN, K. M.; ULBRICH, U. Increasing frequencies and changing characteristics of heavy precipitation events threatening infrastructure in Europe under climate change. **Natural Hazards and Earth System Sciences**, v. 17, n. 7, p. 1177–1190, 2017.

NERILO, Nerilton; MEDEIROS, Pericles Alves; CORDERO, Ademar. **Chuvas intensas no Estado de Santa Catarina**. Florianópolis: Ed. da UFSC, Blumenau: Ed. da FURB, 2002. 156 p.

OLIVEIRA, D. Y. **Análise Bayesiana aplicada à modelagem dos processos de interceptação e chuva-vazão em duas bacias florestais**. 2018. 305p. Dissertação (Mestrado em Engenharia Ambiental) - Programa de Pós-Graduação em Engenharia Ambiental, Universidade Federal de Santa Catarina, 2018.

OLIVEIRA, D.Y.; BARTIKO, D.; CHAFFE, P.L.B. Incerteza na análise de frequência de vazões máximas anuais utilizando modelos estacionário e não estacionário aplicados à região sul do Brasil. **I Encontro Nacional de Desastres**, Porto Alegre, 2018.

OLIVEIRA, L. F. C.; CORTÊS, L. C.; WEHR, T. R.; BORGES, L. B.; SARMENTO, P. H. L.; GRIEBELER, N. P. Intensidade-duração-frequência de Chuvas Intensas para localidades no estado de Goiás e Distrito Federal. **Pesquisa Agrícola e Tropical**, v. 35, n. 1, p. 13-13, 2013.

OLIVEIRA, L. F. C.; VIOLA, M. R.; PEREIRA, S.; MORAIS, N. R. Modelos de predição de chuvas intensas para o estado do Mato Grosso, Brasil. **Revista Ambiente & Água**, v. 6, n. 3, p. 274-290, 2011.

PAPALEXIOU, S. M.; MONTANARI, A. Global and regional increase of precipitation extremes under global warming. **Water Resources Research**, v. 55, p. 4901–4914, 2019.

PAPALEXIOU, S. M.; NERANTZAKI, S.D. Tails of extremes: Advancing a graphical method and harnessing big data to assess precipitation extremes. **Advances in Water Resources**, v. 134, p. 103448, 2019.

PARKER, J. K.; MCINTYRE, D.; & NOBLE, R. T. Characterizing fecal contamination in stormwater runoff in coastal North Carolina, USA. **Water Research**. v. 44, n. 14, p. 4186–4194, 2010.

PFAFSTETTER, O. Chuvas intensas no Brasil. Rio de Janeiro: Ministério da Viação e Obras Públicas; DNOS – Departamento Nacional de Obras de Saneamento, 2. ed. 1957. 426p.

PROSDOCIMI, I.; KJELDSSEN, T. R.; SVENSSON, C. Non-stationarity in annual and seasonal series of peak flow and precipitation in the UK. **Natural Hazards and Earth System Sciences**, v. 14, n. 5, p. 1125–1144, 2014.

- RAGNO, E.; AGHAKOUCHAK, A.; LOVE, C. A.; CHENG, L.; VAHEDIFARD, F & LIMA, C. H. R. Quantifying changes in future Intensity-Duration-Frequency curves using multimodel ensemble simulations. **Water Resources Research**, 54, p. 1751–1764, 2018.
- ROSENZWEIG, C.; TUBIELLO, F. N.; GOLDBERG, R., MILLS; E.; BLOOMFIELD, J. Increased crop damage in the US from excess precipitation under climate change. **Global Environmental Change**, v. 12, n. 3, p. 197–202, 2002.
- SABÓIA, M. A. M.; SOUZA, F. A. F.; ARAÚJO, L. M. J.; SILVEIRA, C. S. Climate changes impact estimation on urban drainage system located in low latitudes districts: a study case in Fortaleza-CE, **Revista Brasileira de Recursos Hídricos**, v. 22, n. 21, p. 1-15, 2017.
- Sadegh, M.; VRUGT, J. A. J.; Xu, C.; VOLPI, E. The stationarity paradigm revisited: Hypothesis testing using diagnostics, summary metrics, and DREAM(ABC). **Water Resources Research**, v. 51, p. 9207-9231, 2015.
- SANTOS, G. G.; FIQUEIREDO, C. C.; OLIVEIRA, L. F. C.; GRIEBELER, N. P. Intensidade-duração-frequência de chuvas para o Estado de Mato Grosso do Sul, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, p. 899-905, 2009.
- SCHARDONG, A.; ROSHAN K. SRIVASTAV, R. K.; SIMONOVIC, S. P. Atualização da equação intensidade-duração-frequência para a cidade de São Paulo sob efeito de mudanças climáticas, **Revista Brasileira de Recursos Hídricos**, v. 19, n. 4, 2014.
- SCHWARZ, G. Estimating the dimension of a model. **Annals of Statistics**, v.6, n.2, p. 461–464, 1978.
- SERAGO, J. M.; VOGEL, R. M. Parsimonious nonstationary flood frequency analysis. **Advances in Water Resources**, v. 112, p. 1–16, 2018.
- SERINALDI, F.; KILSBY, C. G. Stationarity is undead: Uncertainty dominates the distribution of extremes. **Advances in Water Resources**, v. 77, p. 17–36, 2015.
- SILVA, B.M.; MONTENEGRO S. M. G.; SILVA, FERNANDHA, B. S. Chuvas Intensas em Localidades do Estado do Pernambuco. **Revista Brasileira de Recursos Hídricos**. v. 17, n.3, p. 135-147, 2012.
- SILVA, L. V.; CASAROLI, D.; EVANGELISTA, A. W. P.; ALVES, J.J.; BATTISTI, R. Rainfall Intensity-Duration-Frequency Relationships for Risk Analysis in the Region of Matopiba, Brazil. **Revista Brasileira de Meteorologia**, v. 34, n. 2, 247-254, 2019.
- SOUZA, G. R.; BELLO, I.P., OLIVEIRA, L. F. C.; CORRÊA, V. C. **Heavy rainfall maps in Brazil to 5 year return period**. **Revista Ambiente & Água**, v. 14. n. 5, p. 1-10, 2019.
- SOUZA, R. O. R. M; SCARAMUSSA, P. H. M.; AMARAL, M. A. C. M.; NETO, J. A. P.; PANTOJA, A. V.; SADECK, L. W. R. Equações de chuvas intensas para o Estado do Pará, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 9, p. 999-1005, 2012.

USGS - U.S. GEOLOGICAL SURVEY. Shuttle Radar Topography Mission 1 Arc Second scene. Maryland, EUA. 2006.

VENEZIANO, D.; A. LANGOUSIS; P. FURCOLO. 'Multifractality and rainfall extremes: A review'. **Water Resources Research**, v.42, p. 1-18, 2006.

VOGEL, R. M.; YAINDL, C.; WALTER, M. Nonstationarity: Flood magnification and recurrence reduction factors in the united states. **Journal of the American Water Resources Association**, v. 47, n. 3, p. 464–474, 2011.

VRUGT, J. A. Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation. **Environmental Modelling and Software**, v. 75, p. 273–316, 2016;

WDOWINSKI, S.; BRAY, R.; KIRTMAN, B. P.; WU, Z. Increasing flooding hazard in coastal communities due to rising sea level: Case study of Miami Beach, Florida. **Ocean and Coastal Management**, v. 126, p. 1–8, (2016).

WESCHENFELDER, A. B.; KLERING, E. V.; ALVES, R. C. M.; PINTO E. J. A. Geração de Curvas IDF's para Cenários Projetados na Cidade de Porto Alegre/RS. **Revista Brasileira de Meteorologia**, v. 34, n. 2, 201-216, 2019.

APÊNDICE A

A tabela a seguir mostrar os resultados obtidos na validação dos modelos para as estações pluviométricas que apresentaram tendência significativa no período de calibração.

Tabela 4 - Número de séries com melhor desempenho na validação para cada um dos modelos (estacionário – ST, estacionário atualizado – uST e não estacionário – NS) considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança (L_{MED}) de estações pluviométricas com tendência no período de calibração, para séries AMS de 1 a 7 dias.

Modelo	ST		uST		NS	
Série AMS	L_{MAP}	L_{MED}	L_{MAP}	L_{MED}	L_{MAP}	L_{MED}
1	6	9	4	3	7	5
2	2	4	2	2	6	4
3	2	4	3	3	6	4
4	2	4	3	3	6	4
5	1	2	2	1	4	4
6	3	5	3	3	6	4
7	2	4	6	4	6	4

APÊNDICE B

As figuras a seguir mostram os resultados para os critérios de informação de Akaike e de Bayes para as intensidades de precipitação de 2, 3, 4, 5 e 6 dias, para todas as estações pluviométricas analisadas neste estudo.

Figura 12 - Valores de $\Delta AICc$ (à esquerda) e ΔBIC (à direita) para séries AMS₂. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.

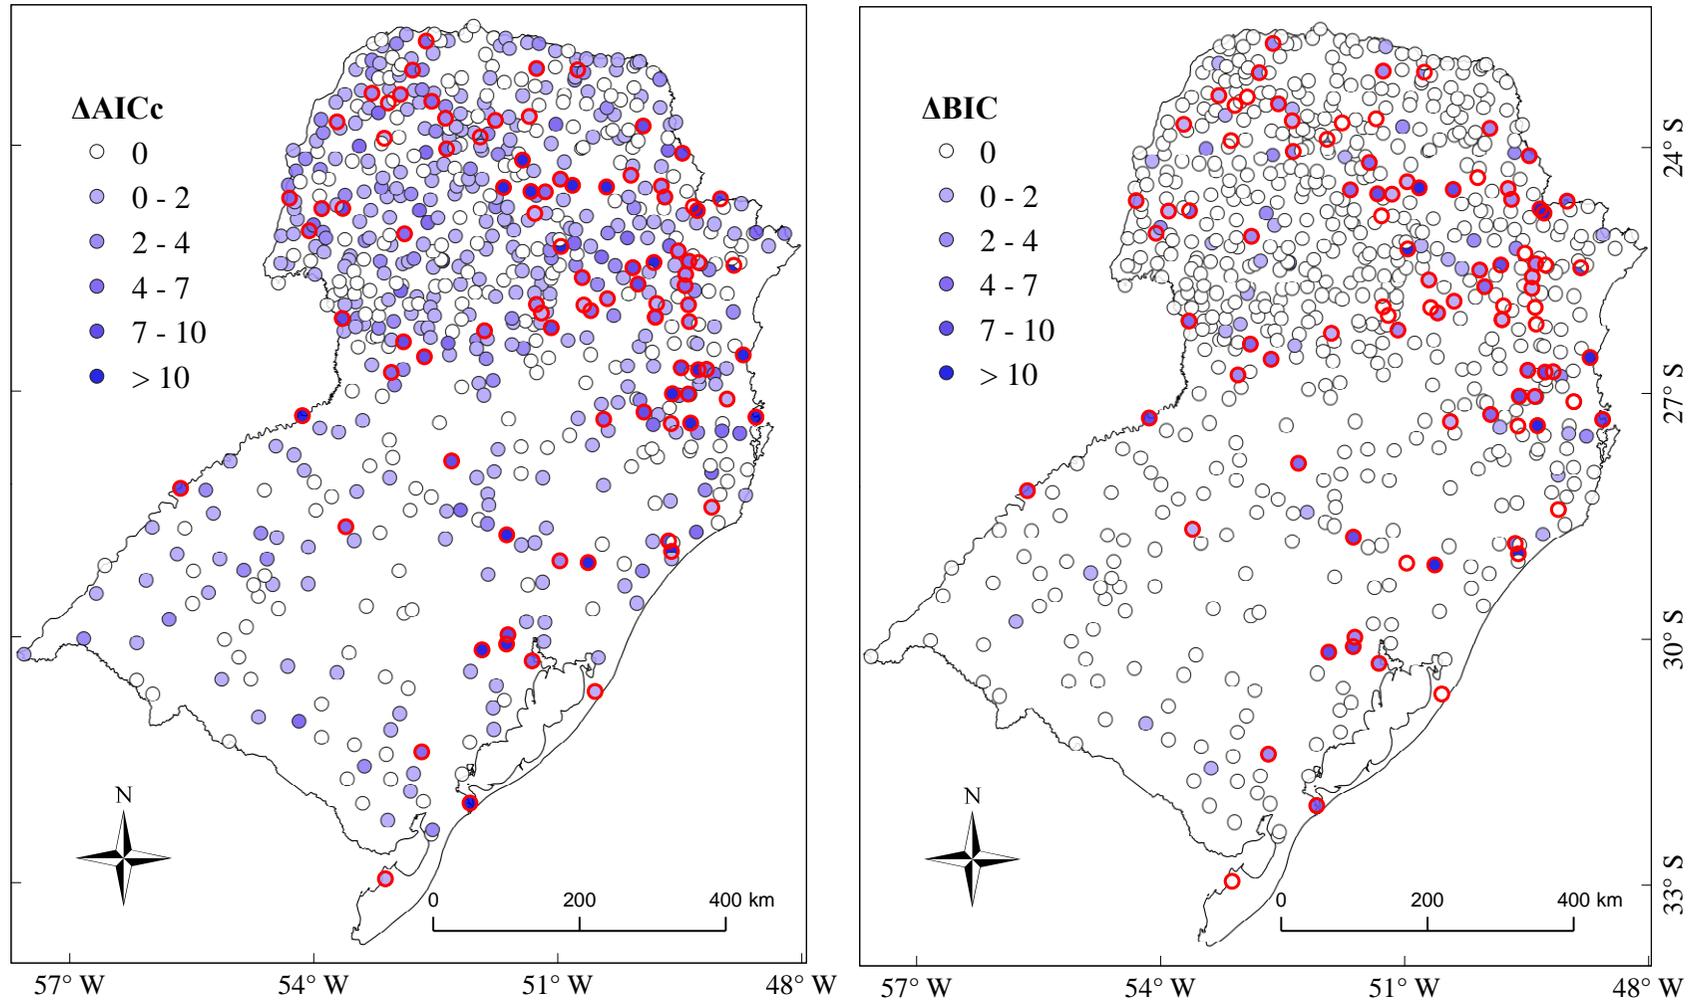


Figura 13 - Valores de $\Delta AICc$ (à esquerda) e ΔBIC (à direita) para séries AMS_3 . As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.

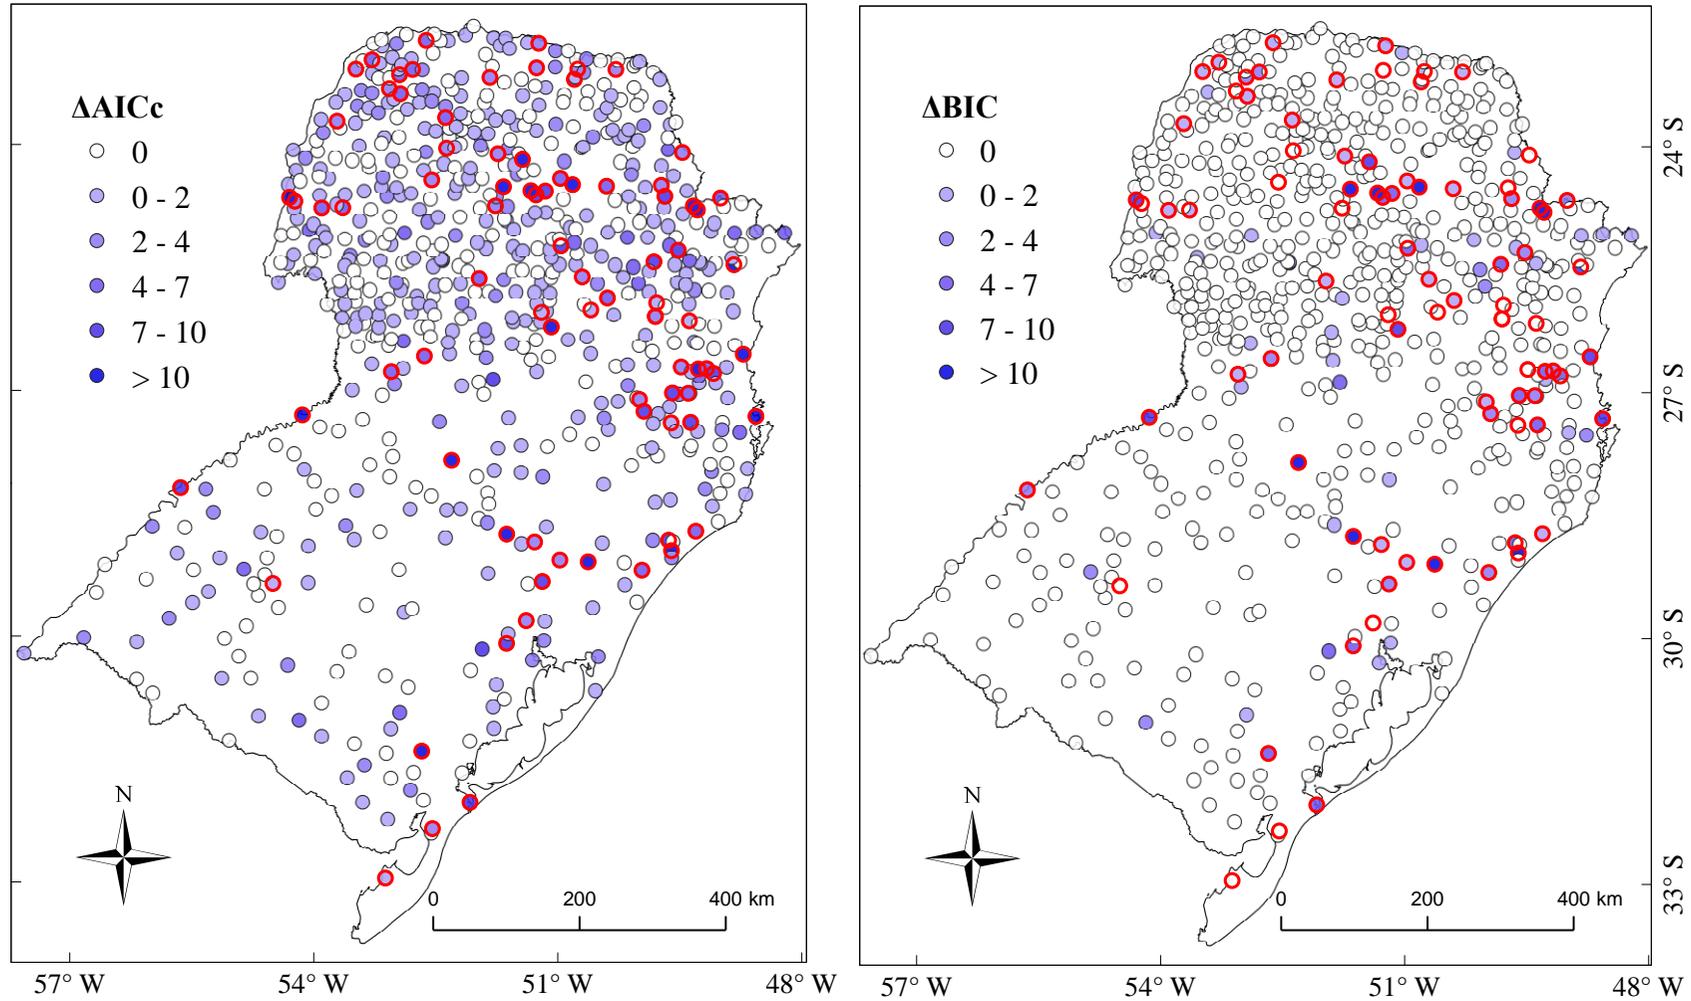


Figura 14 - Valores de $\Delta AICc$ (à esquerda) e ΔBIC (à direita) para séries AMS₄. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.

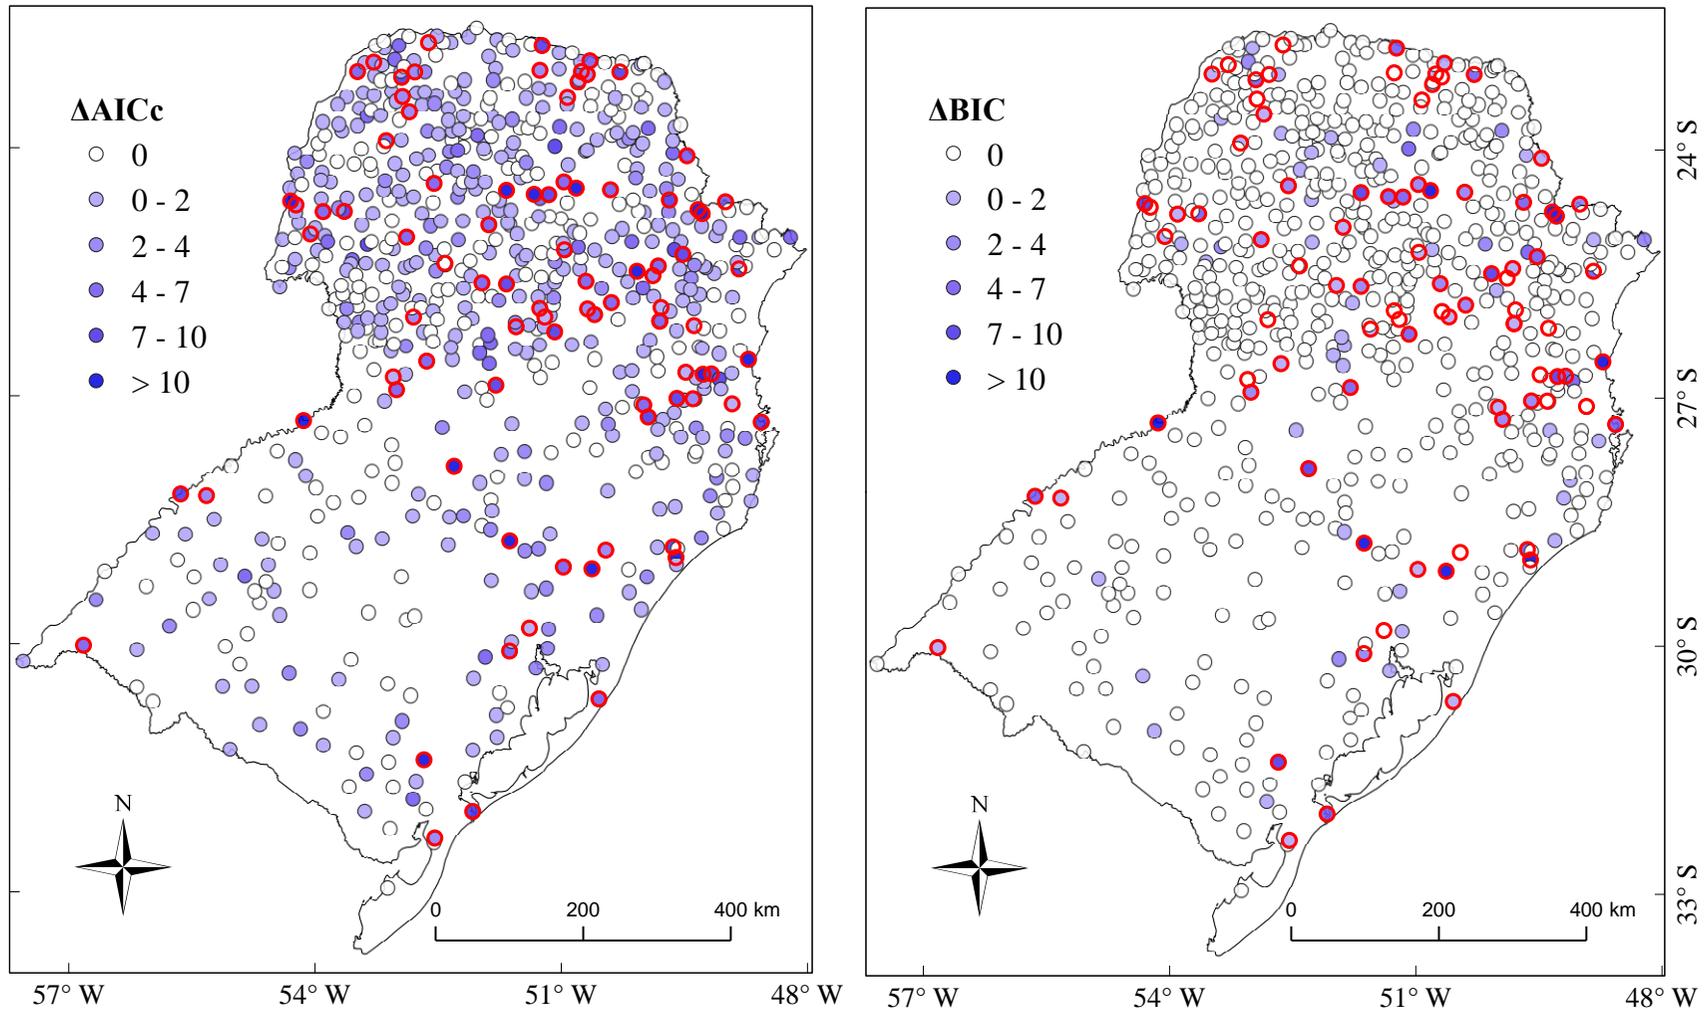


Figura 15 - Valores de $\Delta AICc$ (à esquerda) e ΔBIC (à direita) para séries AMS_5 . As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.

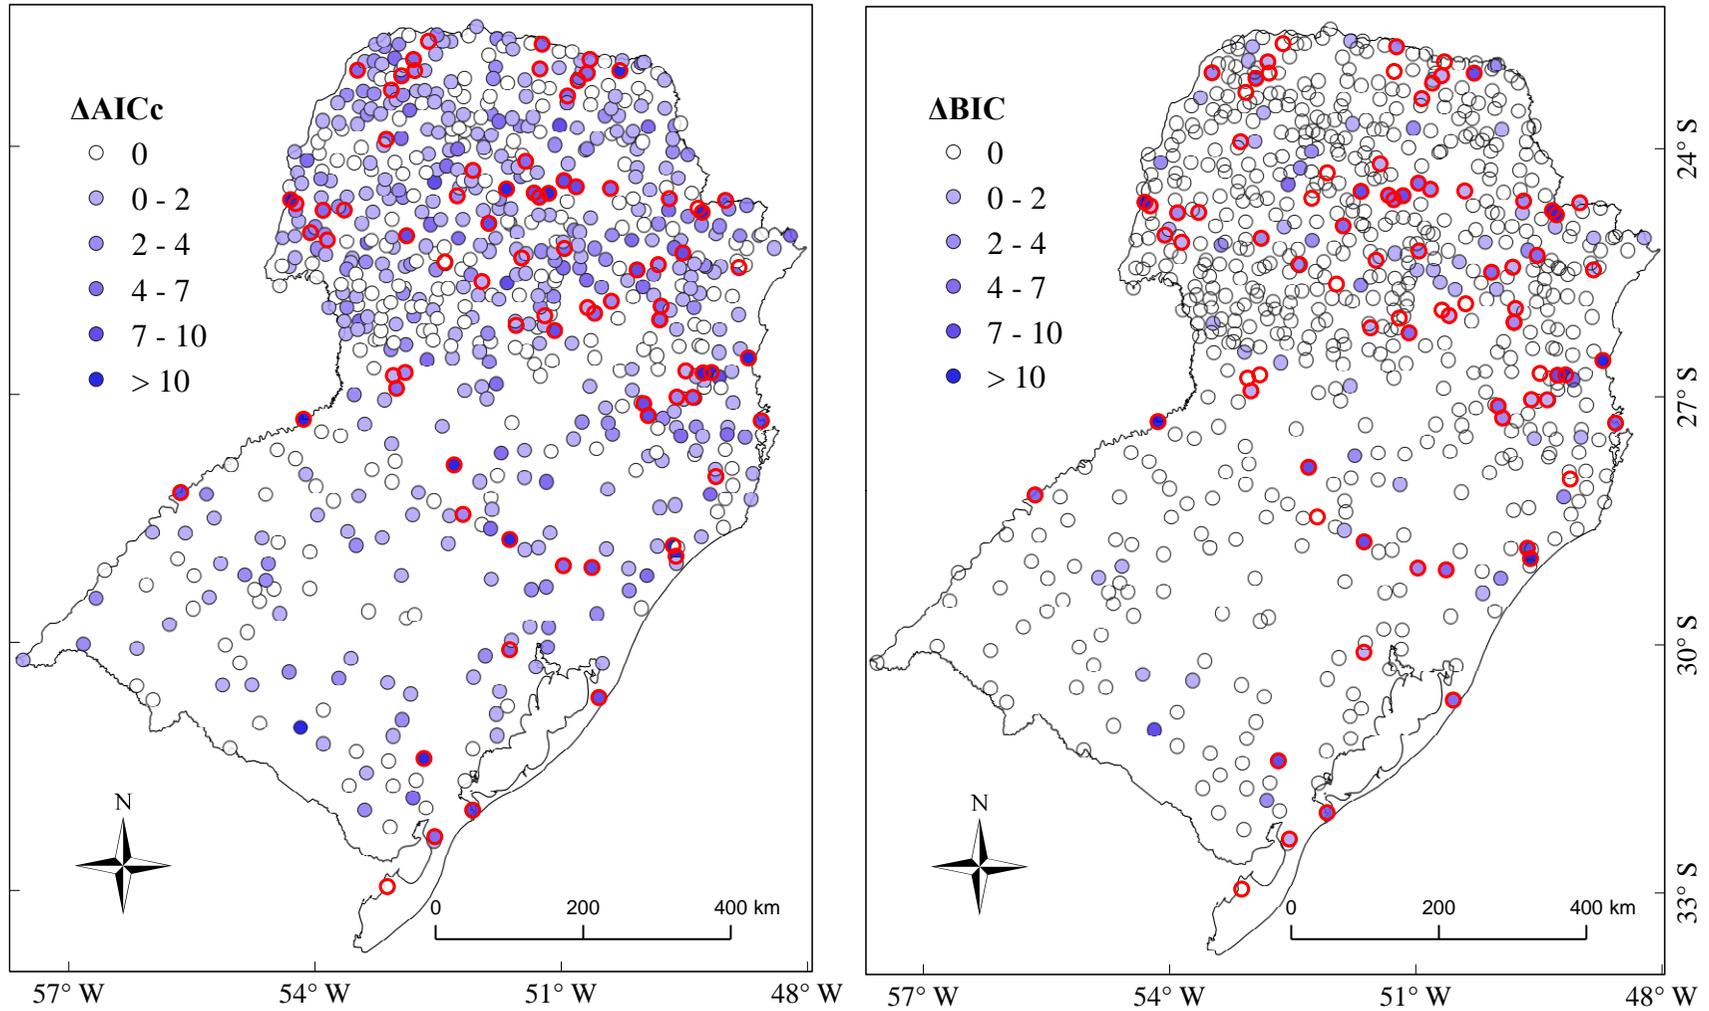
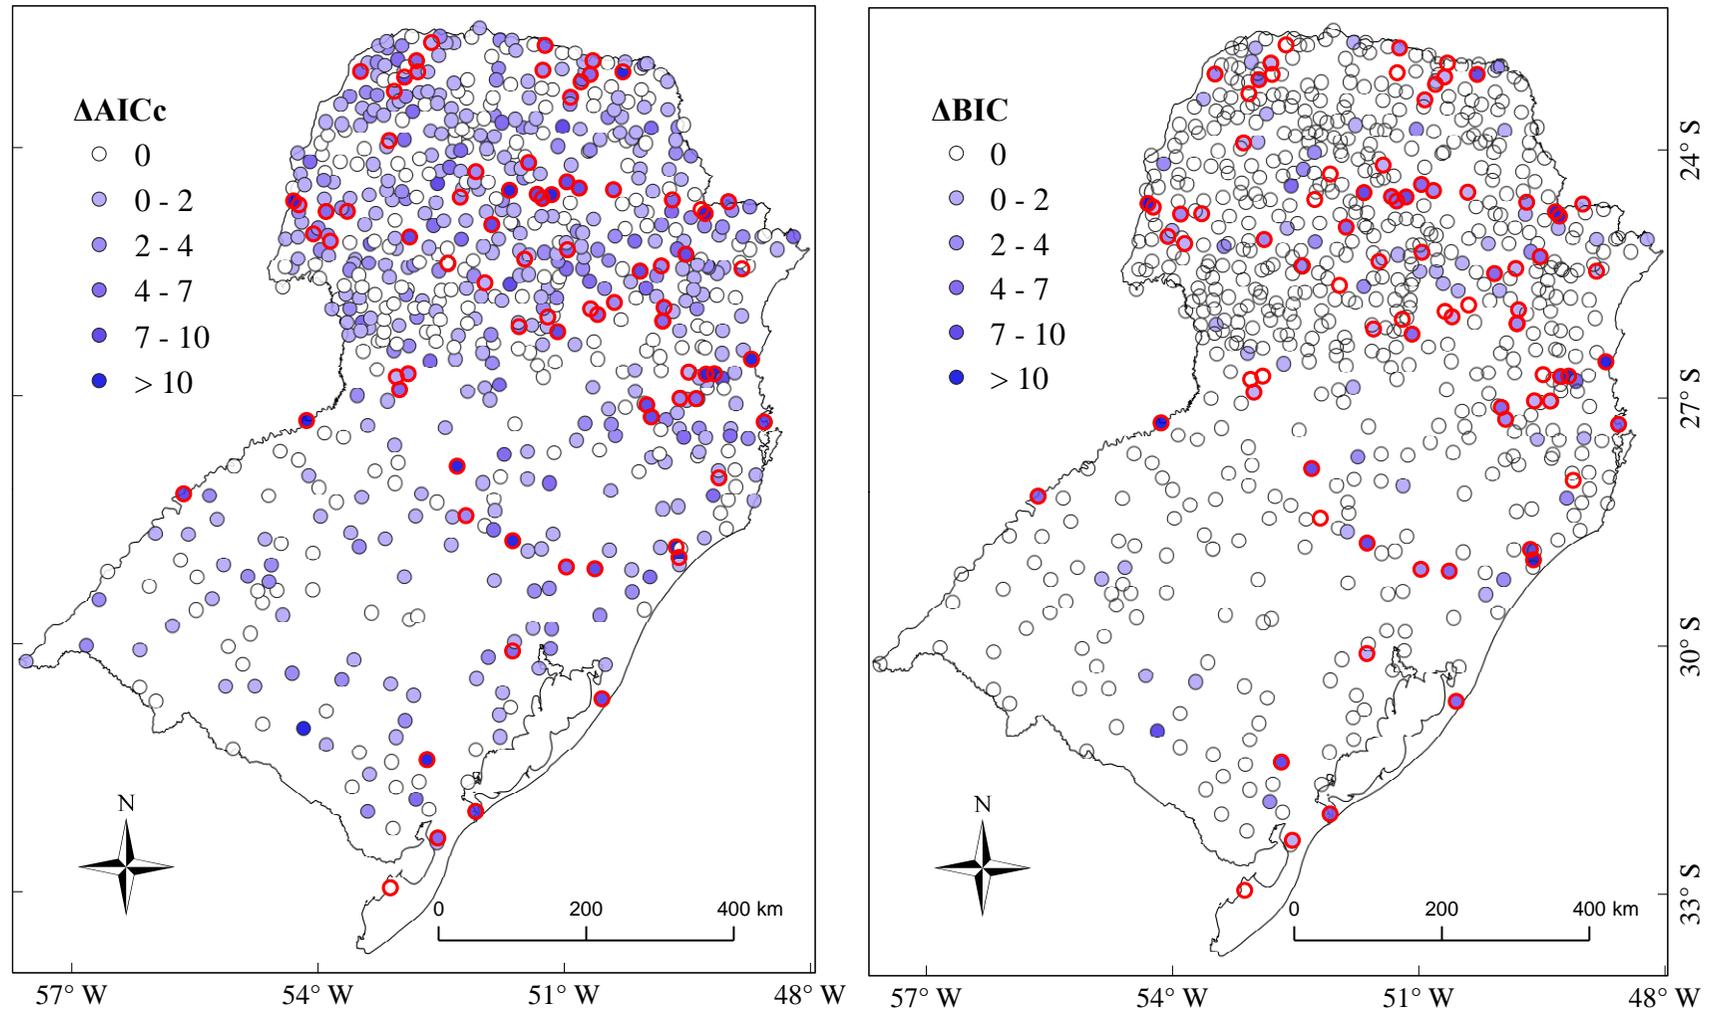


Figura 16 - Valores de $\Delta AICc$ (à esquerda) e ΔBIC (à direita) para séries AMS₆. As estações pluviométricas em vermelho são as que apresentaram tendência significativa (quando avaliadas para série completa). Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte ao modelo estacionário.



APÊNDICE C

As figuras a seguir mostram os histogramas para os critérios de informação de Akaike e de Bayes para as intensidades de precipitação de 2, 3, 4, 5 e 6 dias, para todas as estações pluviométricas analisadas neste estudo. Os resultados estão separados em estações com e sem tendência significativa.

Figura 17 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₂. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

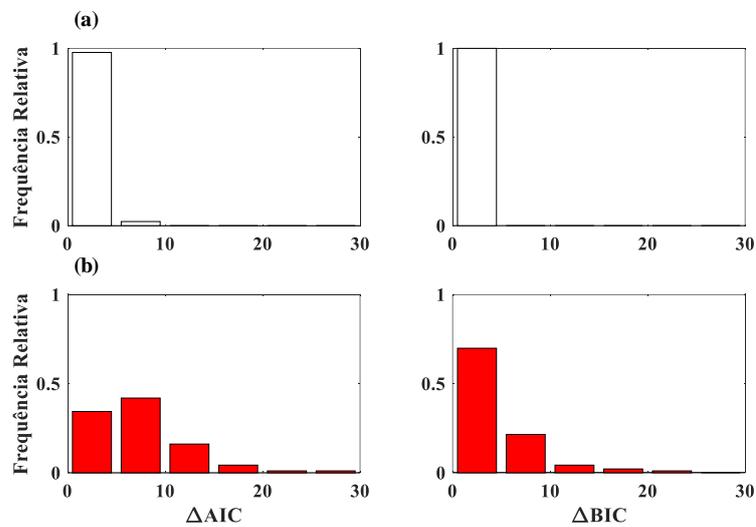


Figura 18 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₃. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

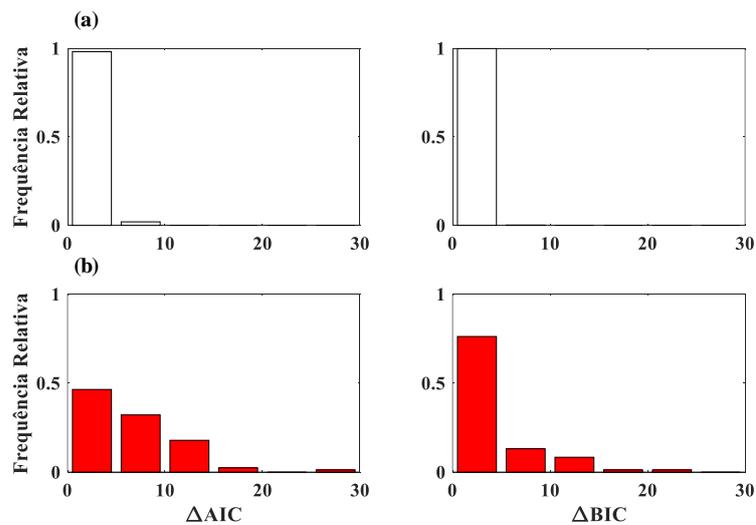


Figura 19 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₄. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

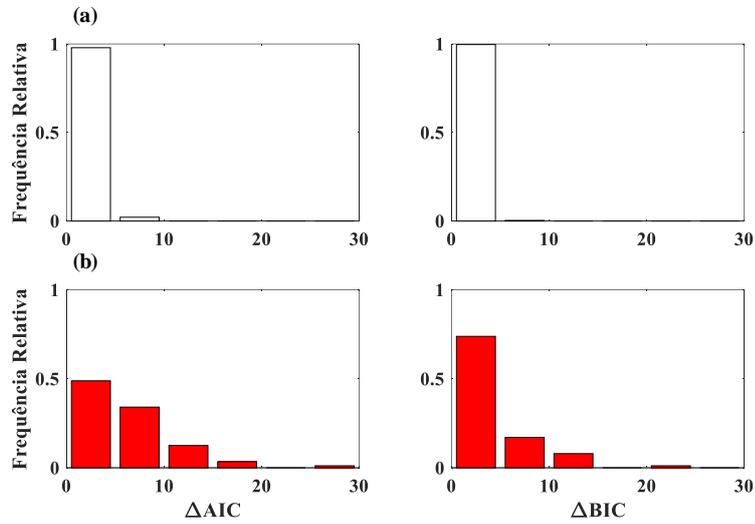


Figura 20 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₅. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

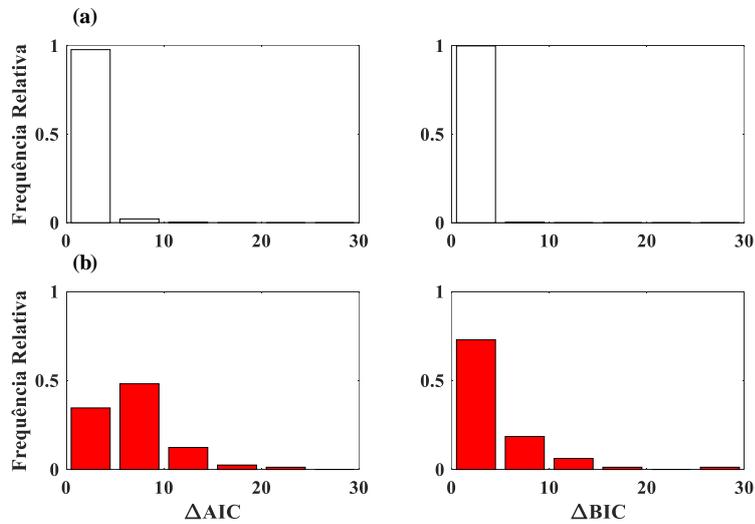


Figura 21 - Comparação entre os valores de ΔAIC ($= AIC_{c,s} - AIC_{c,min}$) e ΔBIC ($= BIC_s - BIC_{min}$) para estações pluviométricas (a) sem tendência significativa e (b) com tendência significativa para séries AMS₆. $AIC_{c,s}$ (BIC_s) é o valor de AIC_c (BIC) do modelo estacionário, e $AIC_{c,min}$ (BIC_{min}) é o menor valor de AIC_c (BIC).

