



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL

Gabriel Anzolin

**NÃO ESTACIONARIEDADE DE CHEIAS NO BRASIL:
ANÁLISE DE FREQUÊNCIA COM COVARIÁVEIS CLIMÁTICAS**

Florianópolis

2022

Gabriel Anzolin

**NÃO ESTACIONARIEDADE DE CHEIAS NO BRASIL:
ANÁLISE DE FREQUÊNCIA COM COVARIÁVEIS CLIMÁTICAS**

Dissertação submetida ao Programa de Pós-graduação em Engenharia Ambiental da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia Ambiental.

Orientador: Prof. Pedro Luiz Borges Chaffe, Dr.
Coorientadora: Profa. Regina Rodrigues Rodrigues.

Florianópolis

2022

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

Anzolin, Gabriel

NÃO ESTACIONARIEDADE DE CHEIAS NO BRASIL: ANÁLISE DE
FREQUÊNCIA COM COVARIÁVEIS CLIMÁTICAS / Gabriel Anzolin ;
orientadora, Pedro Luiz Borges Chaffe, coorientador,
Regina Rodrigues Rodrigues , 2022.

87 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Ambiental, Florianópolis, 2022.

Inclui referências.

1. Engenharia Ambiental. 2. Cheias. 3. Análise de
frequência. 4. Não estacionariedade. 5. Incerteza. I.
Chaffe, Pedro Luiz Borges. II. Rodrigues , Regina
Rodrigues . III. Universidade Federal de Santa Catarina.
Programa de Pós-Graduação em Engenharia Ambiental. IV. Título.

Gabriel Anzolin

**NÃO ESTACIONARIEDADE DE CHEIAS NO BRASIL:
ANÁLISE DE FREQUÊNCIA COM COVARIÁVEIS CLIMÁTICAS**

O presente trabalho em nível de mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Leonardo Hoinaski, Dr.
Universidade Federal de Santa Catarina

Prof. Dirceu Silveira Reis Junior, Dr.
Universidade de Brasília

Prof. Antonio Fernando Harter Fetter Filho, Dr.
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de mestre em Engenharia Ambiental.

Prof. Leonardo Hoinaski, Dr.
Coordenação do Programa de Pós-Graduação

Prof. Pedro Luiz Borges Chaffe, Dr.
Orientador

Florianópolis

2022

AGRADECIMENTOS

Agradeço à Universidade Federal de Santa Catarina, por me proporcionar ensino público e de qualidade durante todos os anos de graduação e de mestrado. À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de estudos que tornou este trabalho possível.

Ao meu orientador, Prof. Pedro Chaffe, que durante a graduação me encorajou e inspirou a entrar no mundo da Hidrologia, ciência linda pela qual tenho grande prazer em estudar. 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. Agradeço também à Prof. Regina Rodrigues, pela coordenação.

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. Pelo 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 da UFSC, por toda ajuda, inspiração e por tornarem os dias de trabalho muito mais leves e divertidos (mesmo que de maneira remota). Agradeço também aos meus amigos que me acompanharam durante todos esses anos de graduação e de mestrado.

Aos Professores Leonardo Hoinaski, Dirceu Reis e Antonio Fetter, por terem aceitado fazer parte da banca avaliadora e pelas importantes contribuições para tornar este trabalho muito melhor.

Muito Obrigado!

RESUMO

Impactos como o aumento observado na temperatura da superfície terrestre, mudanças nos padrões de circulação da atmosfera, urbanização, práticas agrícolas e regularização de vazões levaram ao desenvolvimento e uso de modelos não estacionários para análise de frequência de cheias. Entretanto, devido à incerteza associada à detecção e estimativa de tendências em séries históricas e à incerteza intrínseca ao se extrapolar mudanças para o futuro, não está claro como e em que circunstâncias esses modelos devem ser utilizados para estimativa de eventos de cheia. Neste estudo, testou-se a hipótese de que o uso covariáveis climáticas pode melhorar a habilidade de modelos não estacionários em descrever estatisticamente o regime de cheias em relação à suposição de estacionariedade. Foram utilizados dados de vazão e informação climática de 379 bacias hidrográficas de todo o Brasil, obtidas das bases de dados CAMELS-BR e NOAA CPC entre 1980 e 2018. Foi comparado o uso de modelos estacionários e não estacionários utilizando a distribuição generalizada de valores extremos (GEV). Para o modelo não estacionário, o parâmetro de posição da distribuição GEV pode variar com o tempo (tendência linear) ou uma das cinco covariáveis climáticas (i.e., temperatura média anual, índice NINO 3.4, precipitação média anual, precipitação máxima anual e umidade máxima anual do solo). Os parâmetros da distribuição GEV foram inferidos com simulações de Monte Carlo via Cadeia Markov com o algoritmo DREAM_(ZS). A avaliação de desempenho foi feita com o uso dos critérios de informação de Akaike para pequenas amostras e de Bayes estimados para o período de calibração (primeiros 30 anos), e os últimos 9 anos foram reservados para avaliar a habilidade preditiva dos modelos com o uso do fator de Bayes. Os resultados revelam que: (i) a precipitação média anual e a precipitação máxima anual foram as covariáveis mais influentes no regime de cheias; (ii) a seleção do modelo baseada em métricas de qualidade do ajuste (e.g., critérios de informação) favorece a seleção do modelo não estacionário, especialmente quando as covariáveis foram significativas no regime de cheias; e (iii) a seleção do modelo com base na habilidade preditiva (i.e., validação) mostrou que o uso de informações físicas melhora a capacidade preditiva do modelo não estacionário, mesmo levando em consideração a incerteza relativa à inferência dos parâmetros da distribuição de extremos. Esses resultados sugerem que o uso de informação climática é uma abordagem promissora para mitigar uma das principais limitações de modelos não estacionários, i.e., a incerteza devido ao aumento da complexidade do modelo.

Palavras-chaves: Cheias. Análise de frequência. Não estacionariedade. Incerteza.

ABSTRACT

Recent increases in earth surface temperature, changes in atmospheric circulation patterns, increase in urbanization, agricultural practices, and streamflow regularization prompted the development and use of nonstationary models for flood frequency analysis. However, due to the uncertainty associated with trend detection and estimation in historical time series and the intrinsic uncertainty to extrapolate changes into the future, it is not clear how and under what circumstances those models should be used for prediction. In this study, we tested the hypothesis that physical covariates can improve the statistical representation of observed flood peak distributions relative to stationary assumption. We used streamflow data and physical information of 379 hydrographic basins across Brazil, obtained from CAMELS-BR and NOAA CPC datasets for the 1980-2018 period. We compared the use of stationary and nonstationary models for flood frequency analysis using the generalized extreme value distribution (GEV) and the uncertainty in the model's performance. In the nonstationary case, the location parameter of the GEV distribution could either vary with time (following a linear trend) or one of five physical covariates (i.e., annual average temperature, NINO 3.4 index, annual average precipitation, annual maximum precipitation, and annual maximum soil moisture). The parameters of the GEV distribution were inferred using Markov Chain Monte Carlo sampling with the DREAM(ZS) algorithm. The performance evaluation was made using the small sample Akaike information criterion and Bayesian information criterion estimated for the fitting period (first 30 years), and the last 9 years were used to evaluate the predictive ability of the models using the Bayes factor. Our results reveal that: (i) annual average precipitation and annual maximum precipitation were the covariates most influent in the flood regime; (ii) model selection based on metrics of goodness-of-fit (e.g., information criteria) supports the selection of the non-stationary model, especially when the covariates showed a significant effect in the flood regime; and (iii) model selection based on predictive ability (i.e., evaluation with out-of-sample data) showed that the use of physical information improves the predictive ability of the nonstationary model, even taking into account the uncertainty relative the parameter inference of the extreme value distribution. These results suggest that the use of physical information is a promising approach to improve on the main limitations of nonstationary models, i.e., the uncertainty due to increased model complexity.

Keywords: Floods. Frequency analysis. Nonstationarity. Uncertainty.

LISTA DE FIGURAS

- Figura 1.** Representação esquemática das principais características de um evento de cheia, como magnitude (vazão máxima), tempo de pico, duração e volume (área em azul). ..28
- Figura 2.** Exemplos de série (a) estacionária e não estacionária com (b) tendência monotônica, (c) mudança abrupta e (d) mudança na variância.29
- Figura 3.** Exemplo da influência do tamanho da amostra na interpretação quanto a estacionariedade ou não estacionariedade de uma série temporal. (a) primeiros 200 anos de observações, conclusão preliminar: série não estacionária. (b) série em sua totalidade (2000 anos de observações), conclusão: a série é estacionária e apresenta comportamento não estacionário em um determinado período de tempo, mas o processo é estacionário. As linhas pretas representam uma série sintética gerada a partir de um processo estocástico univariado e a linha em vermelho representa o valor da média.32
- Figura 4.** Controle de qualidade dos dados com o uso da curva da permanência. Exemplos de bacias hidrográficas em que a série de dados foi (a) aprovada pelo controle de qualidade dos dados (estação fluviométrica Fazenda Franciso, na bacia hidrográfica do Atlântico, trecho leste; ANA N° 56240000) e (b) descartada da análise (estação fluviométrica Derocal, na bacia hidrográfica do São Francisco; ANA N° 46455000).38
- Figura 5.** Localização das 379 bacias hidrográficas selecionadas para este estudo, classificadas de acordo com suas respectivas regiões hidrográficas (cores). A linha preta indica o limite territorial do Brasil e as linhas cinzas os cursos da água.39
- Figura 6.** PDF da distribuição GEV para condições de (a) estacionariedade com diferentes valores do parâmetro de forma. As linhas azul, preta e vermelha correspondem a valores de $K < 0$ (Tipo II, Fréchet), $K = 0$ (Tipo I, Gumbel) e $K > 0$ (Tipo III, Weibull), respectivamente, e (b) não estacionariedade com diferentes valores do coeficiente angular do modelo linear de tendência. As linhas vermelha, preta e azul correspondem a $\alpha_1 < 0$, $\alpha_1 = 0$ e $\alpha_1 > 0$, respectivamente.43
- Figura 7.** Representação do teste de Kolmogorov-Smirnov. As linhas azul e vermelha representam as CDFs F_1 e F_2 , respectivamente. A linha preta representa a máxima diferença entre F_1 e F_244
- Figura 8.** Exemplo de análise da influência da covariável no regime de cheias para: (a) influência de sinal negativo, (b) influência não significativa e (c) influência de sinal positivo. As linhas tracejadas representam um intervalo de credibilidade de 95% do parâmetro α_1 e o marcador em formato de x representa o valor zero.48

Figura 9. (a) Estimativas MAP do parâmetro de posição da distribuição GEV (linhas sólidas) para os modelos ST (azul), uST (amarelo) e NS (vermelho) inferidos a partir da série máxima anual da estação fluviométrica Óbidos (linha preta), localizada na bacia do rio Amazonas (ANA N° 17050001) para o período de calibração (1980 – 2009). As faixas sombreadas em azul, amarelo e vermelho representam um intervalo de credibilidade de 90% da estimativa do parâmetro de posição para os modelos ST, uST e NS, respectivamente. (b-d) Os histogramas em cinza representam a PDF empírica dos dados referentes ao período de validação (2010-2018) e as linhas em azul, amarelo e vermelho representam as estimativas MAP da PDF da distribuição GEV para os modelos ST, uST e NS (extrapolação de 45 anos em relação ao final do período de calibração), respectivamente. O modelo não estacionário mostrado é o que utiliza o tempo como covariável..... 51

Figura 10. Exemplo de GMM ajustado a distribuição a *posteriori* (linha preta) para os modelos (a) ST (histogramas em azul), (b) uST (histogramas em amarelo) e (c) NS (histogramas em vermelho), inferidos a partir da série máxima anual da estação fluviométrica Esperantina, localizada na bacia hidrográfica do Atlântico, trecho Norte/Nordeste (ANA N° 33170000). O modelo não estacionário mostrado é o que utiliza o tempo como covariável. 53

Figura 11. Resultados para a verificação da aderência dos dados à distribuição GEV para (a) teste de Kolmogorov-Smirnov, (b) *probability plot correlation coefficient* (PPCC) e (c) *root mean square error* (RMSE)..... 55

Figura 12. Influência das covariáveis no regime de cheias para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores dos círculos representam o valor do coeficiente de correlação de Spearman entre a covariável e a série de cheias (período de calibração). Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo o teste de correlação de Spearman com nível de confiança de 95% 58

Figura 13. Histogramas do coeficiente de correlação entre as séries de vazão máxima anual e as séries anuais das covariáveis para (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. 58

Figura 14. Influência das covariáveis no regime de cheias para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores com transparência indicam uma influência de sinal positivo (azul) e de sinal negativo

(vermelho) não significativa. Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo com a análise da distribuição a *posteriori* do coeficiente angular do modelo NS, com nível de confiança de 95%. 59

Figura 15. Suporte relativo à utilização do modelo ST para o critério de informação de Akaike. $\Delta AICc = AICc_s - AICc_{MIN}$. AICcs representa o valor do critério de informação do modelo ST e $\Delta AICc$ representa o valor mínimo do critério de informação (melhor modelo) para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. Círculos com bordas representam bacias hidrográficas em que a covariável foi estatisticamente significativa no regime de cheias de acordo com a análise da distribuição a *posteriori* do parâmetro α_1 , com nível de confiança de 95%. Resultados interpretados de acordo com Burnham e Anderson (2003), em que valores de $\Delta AICc$ entre 0 e 2 indicam suporte considerável, entre 4 e 7 indicam suporte consideravelmente menor, e valores maiores que 10 indicam a inexistência de suporte ao modelo ST. 61

Figura 16. Distribuição dos valores de $\Delta AICc$ para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias para séries em que a não foi considerada estatisticamente significativa no regime de cheias (histogramas brancos) e foi considerada estatisticamente significativa (histogramas em cinza escuro) no regime de cheias de acordo com a análise da distribuição a *posteriori* do parâmetro α_1 61

Figura 17. Suporte relativo à utilização do modelo ST para o critério de informação de Bayes. $\Delta BIC = \Delta BIC - BIC_{MIN}$. BICs representa o valor do critério de informação do modelo ST e BICMIN representa o valor mínimo do critério de informação (melhor modelo). A descrição dos demais itens é a mesma da Figura 15. 62

Figura 18. Distribuição dos valores de ΔBIC . A descrição dos demais itens é a mesma da Figura 16. 62

Figura 19. Comparação entre o modelo ST e NS para cada uma das covariáveis testadas. A figura mostra o percentual de bacias hidrográficas em que cada modelo foi considerado como melhor modelo para (a) AICc e (b) BIC. Foi considerado como melhor modelo aquele em que a covariável foi estatisticamente significativa no regime de cheias e que recebeu suporte pelos critérios de informação. 63

Figura 20. Comparação entre a habilidade preditiva dos modelos ST, uST e NS através do uso do fator de Bayes para todas as bacias hidrográficas avaliadas neste estudo, para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva

máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores representam o valor de B_j, k . Segundo Kass e Raftery (1995), valores de B_j, k entre 0 e 2 indicam um suporte fraco, valores entre 2 e 6 um suporte positivo, valores entre 6 e 10 um suporte forte e valores maiores que 10 indicam um suporte muito forte ao modelo \mathcal{M}_j . Os números no interior de cada painel mostram o percentual de bacias hidrográficas em que cada modelo obteve melhor habilidade preditiva. 66

Figura 21. Comparação entre a habilidade preditiva dos modelos ST, uST e NS através do uso do fator de Bayes para bacias hidrográficas em que a influência das covariáveis no regime de cheias foi considerada como persistente durante o período de validação. A descrição dos demais itens é a mesma da Figura 19..... 68

Figura 22. Dispersão entre as estimativas MAP da magnitude de um evento de cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$, escala logarítmica) para os modelos ST e uST (parâmetros do modelo NS ao final do período de calibração) para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores dos círculos representam o valor do coeficiente de correlação de Spearman entre a covariável e a série de cheias (período de calibração). Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo com a análise da distribuição *a posteriori* do coeficiente angular do modelo NS, com nível de confiança de 95%. A linha preta é a reta 1:1. 70

Figura 23. Dispersão entre as estimativas MAP da magnitude de um evento de cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$, escala logarítmica) para os modelos ST e NS (aumento de 5 anos para a covariável tempo e valor máximo da covariável observado no período de calibração). A descrição dos demais itens é a mesma da Figura 22..... 71

Figura 24. Curvas de frequência, i.e., eventos de cheias associados a diferentes tempos de retorno (em anos), e densidade de probabilidade para uma cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$) para os modelos ST (azul), uST (amarelo, com parâmetros do modelo NS ao final do período de calibração) e NS (vermelho, aumento de 5 anos para a covariável tempo e valor máximo da covariável observado no período de calibração) para covariáveis: (a) tempo, (b) temperatura média anual, (c) ENSO e (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias para estação fluviométrica Itamaraju, localizada na bacia hidrográfica do Atlântico, trecho leste (ANA N° 55340000). Linhas cheias representam as

estimativas MAP (conjunto ótimo de parâmetros), as linhas tracejadas representam um intervalo de credibilidade de 95%, e as bolas pretas representam as observações para o tempo de retorno empírico (estacionário)..... 72

Figura 25. Distribuição a *posteriori* dos parâmetros para os modelos (a) ST (azul), (b) uST (amarelo) e (c) NS (vermelho). A linha preta no primeiro quadro de cada painel representa a distribuição a *priori* do parâmetro de forma e a cruz em cinza em cada quadro representa a estimativa dos parâmetros pelo método de máxima verossimilhança. O modelo NS mostrado é o que utiliza o tempo como covariável. 74

LISTA DE TABELAS

Tabela 1. Exemplos de trabalhos relacionados a análise de frequência de extremos hidroclimáticos em todo o mundo. Notas: LP3 significa distribuição Log-Pearson 3, GEV significa distribuição Generalizada de Valor Extremo, LN significa distribuição Lognormal e GP significa distribuição generalizada de Pareto. μ representa a média da distribuição considerada, α , β e K representam os parâmetros de posição, escala e de forma da distribuição considerada, $g(x)$ representa uma função não paramétrica e c representa a covariável.....30

Tabela 2. Trabalhos relacionados a análise de frequência de cheias no Brasil. Notas: LP3 significa distribuição Log-Pearson 3, GEV significa distribuição Generalizada de Valor Extremo, LN significa distribuição Lognormal, GP significa distribuição generalizada de Pareto, P3 significa distribuição Pearson 3 e EXP significa distribuição exponencial. μ representa a média da distribuição considerada, α e β representam os parâmetros de posição e escala da distribuição considerada e λ representa o parâmetro da distribuição de Poisson, e c representa a covariável34

Tabela 3. Exemplo de definição da distribuição *a priori* e especificações dos parâmetros dos modelos ST e NS. As especificações dos parâmetros do modelo NS são relativas ao modelo que utiliza o tempo como covariável. a e b são os valores dos limites inferior e superior da distribuição uniforme $\mathcal{U}_{a,b}$ de cada parâmetro e μ e σ são os valores da média e de desvio padrão da distribuição normal $\mathcal{N}_{\mu,\sigma}$ disponível em Papalexiou e Koutsoyiannis (2013). ...46

SUMÁRIO

| | | |
|------|---|----|
| 1. | INTRODUÇÃO | 23 |
| 1.1. | OBJETIVO GERAL | 26 |
| 1.2. | OBJETIVOS ESPECÍFICOS | 26 |
| 2. | REVISÃO BIBLIOGRÁFICA | 27 |
| 2.1. | EVENTOS EXTREMOS..... | 27 |
| 2.2. | ANÁLISE DE FREQUÊNCIA DE EXTREMOS E ESTACIONARIEDADE | 29 |
| 2.3. | ANÁLISE DE FREQUÊNCIA DE CHEIAS NO BRASIL..... | 33 |
| 3. | MATERIAIS E MÉTODOS | 37 |
| 3.1. | ÁREA DE ESTUDO E DADOS FLUVIOMÉTRICOS | 37 |
| 3.2. | COVARIÁVEIS | 40 |
| 3.3. | ANÁLISE DE FREQUÊNCIA DE EXTREMOS..... | 41 |
| | Distribuição Generalizada de Valor Extremo | 41 |
| | Aderência dos Dados à distribuição GEV | 44 |
| | Estimativa dos parâmetros | 45 |
| 3.4. | INFLUÊNCIA DAS COVARIÁVEIS NO REGIME DE CHEIAS | 47 |
| | Correlação de Spearman | 48 |
| | Análise da distribuição <i>a posteriori</i> do parâmetro α_1 | 48 |
| 3.5. | ANÁLISE DE PERFORMANCE | 49 |
| | Critérios de informação | 49 |
| | Validação | 50 |
| 4. | RESULTADOS E DISCUSSÃO..... | 55 |
| 4.1. | ADERÊNCIA DOS DADOS À DISTRIBUIÇÃO GEV | 55 |
| 4.2. | RELAÇÃO ENTRE CHEIAS E COVARIÁVEIS..... | 56 |
| 4.3. | ANÁLISE DE DESEMPENHO DOS MODELOS..... | 60 |
| 4.4. | ANÁLISE DOS QUANTIS DE CHEIA | 69 |

| | |
|---|----|
| 4.5. IMPACTO DA ADIÇÃO DE COMPLEXIDADE NA INFERÊNCIA DOS PARÂMETROS | 73 |
| 5. CONCLUSÕES | 77 |
| 6. REFERÊNCIAS BIBLIOGRÁFICAS | 79 |

1. INTRODUÇÃO

Avanços na compreensão, modelagem e estimativa de extremos climáticos são necessários para garantir a resiliência da sociedade (SILLMANN et al., 2017). A análise de frequência de cheias está inclusa neste contexto, uma vez que é fundamental nos projetos de infraestrutura hidráulica e avaliação de risco hidrológico (HAILEGEORGIS; ALFREDSEN, 2017; VENEZIANO et al., 2006). Fatores como mudanças climáticas e outras atividades antropogênicas estão afetando o ciclo hidrológico (PACHAURI et al., 2014). Algumas dessas mudanças são causadas devido à variabilidade do sistema climático e a influências antrópicas, e.g., aumento da temperatura da superfície terrestre observado nas últimas décadas (BARNETT et al., 1999; MAZDIYASNI; AGHAKOUCHAK, 2015), mudanças em padrões de circulação da atmosfera (MILLY et al., 2008, 2015), urbanização (VOGEL et al., 2011), práticas agrícolas (FOUFOULA-GEORGIOU et al., 2015) e regularização com reservatórios (RÄSÄNEN et al., 2017). Devido à estes impactos no ciclo hidrológico, tem sido sugerida a necessidade de métodos não estacionários na avaliação do risco hidrológico e no planejamento dos recursos hídricos (MILLY et al., 2008, 2015). Entretanto, dada à incerteza associada à detecção e estimativa de tendências em séries históricas e a incerteza intrínseca para extrapolar as mudanças para o futuro (SERAGO; VOGEL, 2018), ainda não está claro em quais situações os modelos não estacionários devem ser utilizados

A abordagem mais utilizada para estimar eventos de cheia é através da análise de frequência de extremos, que envolve a estimativa da taxa de recorrência destes eventos através de abordagens probabilísticas (NERANTZAKI; PAPALEXIOU, 2019). Tradicionalmente, as técnicas desenvolvidas para este propósito se apoiam na premissa de estacionariedade dos registros históricos de vazão máxima, em que os parâmetros da distribuição são estimados por métodos como Máxima Verossimilhança (e.g., COLES, 2001) ou método dos Momentos (e.g., ZAGHLOUL et al., 2020). Neste caso, se assume que a probabilidade de ocorrência destes eventos não varia significativamente ao longo do tempo. Assim, estas séries podem ser modeladas através de distribuições de extremos cujos parâmetros são constantes ao longo do tempo (PETROW; MERZ, 2009; READ; VOGEL, 2015, 2016; ŠRAJ et al., 2016; VOGEL et al., 2015; VOGEL; YAINDL; WALTER, 2011).

Para contabilizar os efeitos da variabilidade do sistema climático e dos impactos das mudanças climáticas e do uso e ocupação da superfície terrestre no regime de cheias, modelos não estacionários foram propostos para estimativa destes eventos. Estes modelos consideram

que os parâmetros da distribuição de extremos que usualmente são constantes, variam no tempo de acordo com alguma covariável (e.g., BARTIKO; CHAFFE; BONUMÁ, 2017; HESARKAZZAZI et al., 2021; LU et al., 2020; LUKE et al., 2017; PROSDOCIMI; KJELDSEN, 2021; PROSDOCIMI; KJELDSEN; SVENSSON, 2014; RAGNO et al., 2019; READ; VOGEL, 2015; RENARD; SUN; LANG, 2013; SERAGO; VOGEL, 2018; SERINALDI; KILSBY, 2015; SILVA et al., 2017; SILVA; NAGHETTINI; PORTELA, 2015; SILVA; PORTELA; NAGHETTINI, 2014; ŠRAJ et al., 2016; STEIROU et al., 2019; VILLARINI et al., 2009; VOGEL; YAINDL; WALTER, 2011). Uma das limitações observada em alguns destes trabalhos é que o tempo é utilizado como covariável para explicar a evolução do regime de cheias ao longo do tempo, i.e., esta covariável é utilizada como um *proxy* para todas as possíveis influências relacionadas a não estacionariedade do regime de cheias. Entretanto, o trabalho conduzido por Luke et al. (2017) sugere que esta covariável apresenta limitações no que concerne seu uso para usos futuros. i.e, estimativa de dados independentes dos utilizados para a estimativa dos parâmetros do modelo - o ganho de desempenho observado pelo uso dessa informação não se mostrou suficiente para justificar a utilização de um modelo mais robusto (com maior número de parâmetros), principalmente devido à incerteza adicional promovida pela adição de complexidade do modelo.

Uma maneira de lidar com a incerteza adicional promovida por este tipo de abordagem puramente estatística é através do uso de covariáveis físicas, i.e., utilização de relações determinísticas capazes de explicar a evolução do regime de cheias ao longo do tempo, fazendo com que os modelos não estacionários apresentem performance superior quando comparado a premissa de estacionariedade. Exemplos incluem a utilização de informação climática como chuva e temperatura média anual (e.g., HESARKAZZAZI et al., 2021; ŠRAJ et al., 2016), índices climáticos que representam fenômenos e teleconexões de larga escala (e.g., SILVA et al., 2017; SILVA; NAGHETTINI; PORTELA, 2015; SILVA; PORTELA; NAGHETTINI, 2014; STEIROU et al., 2019), mudanças no uso e ocupação do solo (e.g., RAGNO et al., 2019), índice demográfico (e.g., VILLARINI et al., 2009) e grau de regularização das bacias hidrográficas (e.g., LU et al., 2020).

O Brasil é um país com dimensões continentais, com diferentes padrões climáticos, hidrológicos, de uso e ocupação da terra e com uma densa rede de drenagem e relevo representativos de grande parte da América do Sul. Sendo assim, oferece uma grande oportunidade para estudos relacionados a análise de frequência de extremos de vazão, que até o momento foram timidamente explorados (e.g., BARTIKO; CHAFFE; BONUMÁ, 2017; SILVA et al., 2017;

SILVA; NAGHETTINI; PORTELA, 2015; SILVA; PORTELA; NAGHETTINI, 2014). Neste trabalho pretende-se abordar as seguintes questões:

- (1) A presença de não estacionariedade em registros históricos de vazão máxima justifica a utilização de modelos não estacionários para análise de frequência cheias?
- (2) Sob quais condições os modelos não estacionários devem ser utilizados para análise de frequência de cheias?
- (3) Quais são as covariáveis mais influentes no regime de cheias no Brasil?
- (4) Quais são as covariáveis que fornecem melhores resultados na análise de frequência de cheias no Brasil?

Neste trabalho, testou-se a hipótese de que a utilização de covariáveis físicas melhora a habilidade de modelos não estacionários em descrever estatisticamente o regime de cheias utilizando dados de vazão máxima anual de 379 bacias hidrográficas do Brasil. Para isso, comparou-se as habilidades descritiva e preditiva de modelos estacionário e não estacionário baseados na distribuição Generalizada de Valor Extremo (GEV), levando em consideração a incerteza acerca da estimativa de seus parâmetros.

1.1. OBJETIVO GERAL

Avaliar o desempenho de modelos estacionário e não estacionários para a estimativa de eventos de cheias anuais no Brasil.

1.2. OBJETIVOS ESPECÍFICOS

- (1) Identificar quais são as covariáveis mais influentes no regime de cheias no Brasil.
- (2) Identificar quais covariáveis fornecem melhor desempenho para análise de frequência cheias no Brasil.
- (3) Identificar sob quais condições os modelos não estacionários devem ser utilizados para análise de frequência de cheias no Brasil.
- (4) Avaliar o efeito da adição de complexidade dos modelos na inferência dos parâmetros da distribuição de extremos e no grau de incerteza nos quantis de cheias.

2. REVISÃO BIBLIOGRÁFICA

2.1. EVENTOS EXTREMOS

O termo “evento extremo” é utilizado por diversas áreas do conhecimento, e.g., climatologia, ciências da terra, ecologia, engenharia, hidrologia e ciências sociais. Entretanto, não há um consenso para a definição de “evento extremo” para todas as áreas que o utilizam (MCPHILLIPS et al., 2018), sendo necessário deixar claro no estudo em questão qual é a definição adotada. Normalmente, eventos extremos são definidos como: (1) eventos com baixa probabilidade de ocorrência (eventos raros), baseados na estimativa de tempo médio de recorrência feito a partir de uso de modelos estatísticos ajustados a séries de observações, ou (2) eventos capazes de causar danos socioeconômicos significativos (SENEVIRATNE et al., 2012). Na prática, nem sempre essa correspondência é observada – danos socioeconômicos podem ser provenientes de eventos com baixa probabilidade de ocorrência ou ainda, nem todos os danos são causados por eventos extremos.

No contexto da engenharia, eventos extremos estão normalmente associados a padrões e aspectos construtivos de projetos de infraestrutura, i.e., estimativa da magnitude de determinado evento associado a um tempo médio de ocorrência (tempo de retorno), calculada a partir de métodos estatísticos. Neste texto, o termo “eventos extremos” faz referência a elevados valores de vazão que são observados na seção de um rio, que diferem dos valores preponderantemente observados em uma determinada região, definidos a partir de vazão máxima anual. A Figura 1 ilustra as principais características de um evento de cheia em um rio.

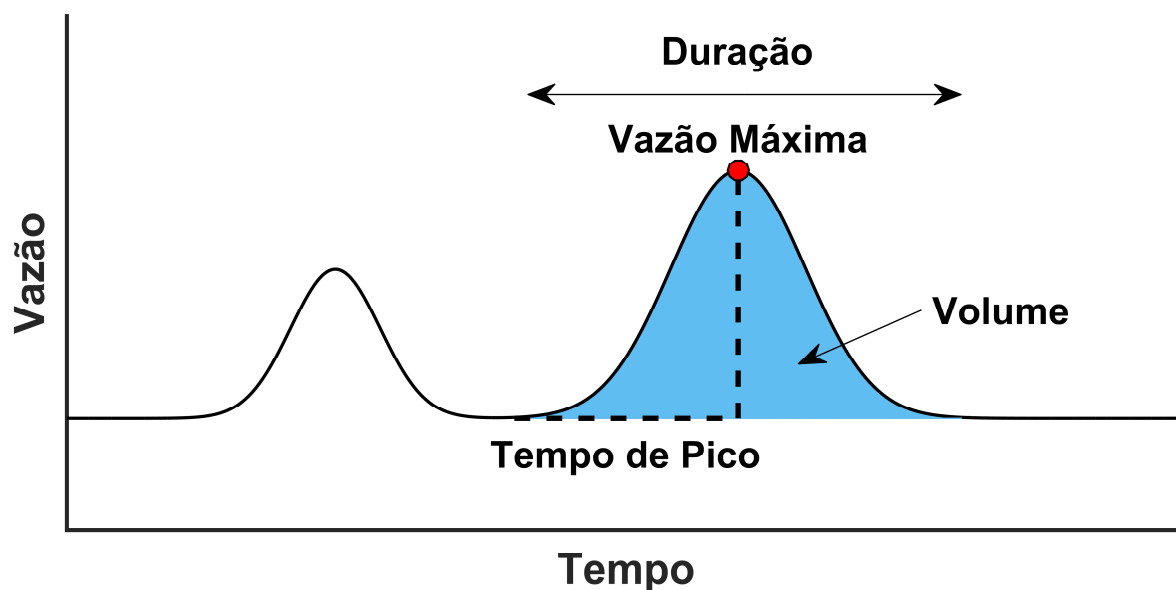


Figura 1. Representação esquemática das principais características de um evento de cheia, como magnitude (vazão máxima), tempo de pico, duração e volume (área em azul).

Eventos extremos de vazão estão diretamente associados a uma série de impactos que afetam a sociedade. Segundo Doocy et al. (2021), 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). Ainda, segundo dados do *United Nations Office for Disaster Risk Reduction* (UNDRR), estes eventos são os que mais afetam pessoas em todo o mundo, com perdas econômicas anuais estimadas em US\$ 104 bilhões. Ainda de acordo com o órgão, entre 1997 e 2017, aproximadamente 76 milhões de pessoas foram afetadas por estes eventos, inundações, sendo o Brasil o país com o segundo maior potencial de perdas associadas a inundações entre as nações emergentes, sendo que em 2013, este tipo de evento provocou 108 mortes e afetou mais de 4 milhões de pessoas em todo o país (BRASIL, 2014).

Além de sua relevância social, o estudo de eventos extremos são frequentemente pautados como um dos maiores desafios para as ciências hidrológicas, e.g., são mencionados em quatro dos vinte e três desafios contemporâneos da hidrologia (BLÖSCHL et al., 2019), e são reconhecidos pelo *The World Climate Research Program* como uma das áreas do conhecimento em que mais avanços são necessários (Sillmann et al., 2017).

2.2. ANÁLISE DE FREQUÊNCIA DE EXTREMOS E ESTACIONARIEDADE

A análise de frequência de extremos é uma técnica amplamente utilizada nas ciências hidrológicas e na concepção de projetos de engenharia, e.g., dimensionamento de estruturas hidráulicas destinadas a evitar que eventos extremos se tornem desastres naturais. É utilizada para estimar a magnitude de um evento associado a um certo tempo de retorno, ou então para estimar com que frequência um evento de certa magnitude é igualado ou superado. Dado o caráter aleatório da ocorrência de eventos extremos, estas estimativas são feitas a partir do ajuste de uma distribuição de probabilidade (e.g., Lognormal, Gumbel, GEV e etc) a séries máximas anuais da variável de interesse (COLES, 2001).

Tradicionalmente, as técnicas desenvolvidas para este propósito são fundamentadas na premissa de estacionariedade das séries máximas anuais, i.e., que as características destas séries, como média, variância e forma de sua distribuição (SLATER et al., 2021) são aproximadamente constante ao longo do tempo, o que implica que a probabilidade de ocorrência dos eventos extremos não varia significativamente ao longo do tempo. Portanto, essas séries podem ser modeladas a partir de distribuições de probabilidades cujos parâmetros são constantes ao longo do tempo (PETROW; MERZ, 2009; READ; VOGEL, 2016; ŠRAJ et al., 2016; VOGEL et al., 2015; VOGEL; YAINDL; WALTER, 2011)




Figura 2. Exemplos de série (a) estacionária e não estacionária com (b) tendência monotônica, (c) mudança abrupta e (d) mudança na variância.

Entretanto, esta premissa amplamente adotada na análise de frequência de extremos pode se tornar inválida devido a variabilidades naturais e de interferências antrópicas. Segundo a equação de Clausius-Clapeyron, um aumento de 1°C na temperatura resulta 7% de aumento na capacidade da atmosfera em reter umidade (TRENBERTH, 2011). Assim, com o aumento da temperatura da superfície terrestre observado nas últimas décadas (BARNETT et al., 1999; KARL; MELILLO; PETERSON, 2014; MAZDIYASNI; AGHAKOUCHAK, 2015), tem-se que o excesso de umidade na atmosfera tende a intensificar o ciclo hidrológico, levando a uma maior aridez em regiões tropicais e uma maior umidade em altas latitudes (SCHIERMEIER, 2010), podendo afetar a magnitude (eventos se tornando mais ou menos severos), frequência

(eventos ocorrendo com mais ou menos frequência) e sazonalidade (eventos ocorrendo em épocas do ano diferente das usuais) de extremos anuais ou sazonais (SLATER et al., 2021). Estas mudanças observadas no ciclo hidrológico levaram ao desenvolvimento e uso de modelos não estacionários para análise de frequência de extremos.

A Tabela 1 sumariza as informações de alguns trabalhos publicados na literatura relativos à análise de frequência de extremos hidroclimáticos em todo o mundo. O levantamento foi organizado de acordo com tipo de dado utilizado, da distribuição de extremos utilizada na análise de frequência, à estrutura do modelo não estacionário (i.e., quais parâmetros variam no tempo e qual o modelo de tendência adotado) e da covariável utilizada para explicar a não estacionariedade do processo de interesse. De acordo com este levantamento, nota-se que há uma grande variedade de combinações de distribuições, de estruturas de modelo e de covariáveis empregadas. Em relação a estrutura dos modelos, tem-se o uso de modelos de tendência aplicados a um ou mais parâmetros da distribuição, e.g., linear, exponencial e quadrático, havendo uma predominância de modelos lineares. Há também uma grande variedade de covariáveis empregadas, e.g., utilização do tempo, informação climática (chuva anual ou índices climáticos que representam fenômenos e teleconexões de larga escala), mudanças no uso e ocupação do solo, índice demográfico e grau de regularização das bacias hidrográficas.

Tabela 1. Exemplos de trabalhos relacionados a análise de frequência de extremos hidroclimáticos em todo o mundo. Notas: LP3 significa distribuição Log-Pearson 3, GEV significa distribuição Generalizada de Valor Extremo, LN significa distribuição Lognormal e GP significa distribuição generalizada de Pareto. μ representa a média da distribuição considerada, α , β e K representam os parâmetros de posição, escala e de forma da distribuição considerada, $g(x)$ representa uma função não paramétrica e c representa a covariável.

| Referência | Variável | Distribuição | Estrutura do Modelo | Covariável |
|----------------------------|----------|--------------|---|--------------------|
| Luke et al. (2017) | Vazão | LP3 | $\mu_c = \mu_0 + \mu_1 c$ | Tempo |
| Cheng e AghaKouchak (2014) | Chuva | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ | Tempo |
| Ragno et al. (2018) | Chuva | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo |
| Ragno et al., (2019) | Vazão | LP3 | $\mu_c = \mu_0 \exp(\mu_1 c)$ | Urbanização |
| Šraj et al. (2016) | Vazão | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo e chuva |
| Steirou et al. (2019) | Vazão | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ | Índices climáticos |

Tabela 1. Exemplos de trabalhos relacionados a análise de frequência de extremos hidroclimáticos em todo o mundo. Notas: LP3 significa distribuição Log-Pearson 3, GEV significa distribuição Generalizada de Valor Extremo, LN significa distribuição Lognormal e GP significa distribuição generalizada de Pareto. μ representa a média da distribuição considerada, α , β e K representam os parâmetros de posição, escala e de forma da distribuição considerada, $g(x)$ representa uma função não paramétrica e c representa a covariável.

| Referência | Variável | Distribuição | Estrutura do Modelo | Covariável |
|------------------------------|---------------------|------------------|--|---|
| Villarini et al. (2009) | Vazão | Gumbel | $\alpha_c = g(x)$ $\beta_c = g(x)$ | Tempo, população e chuva |
| Luo e Zhu, (2019) | Altura de ondas | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ | Tempo |
| Lu et al. (2020) | Vazão | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\alpha_c = \alpha_0 + \alpha_1 c + \alpha_2 c^2$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo, chuva e índice de reservatório |
| Prosdocimi e Kjeldsen (2021) | Vazão | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\alpha_c = \alpha_0 \exp(\alpha_1 c)$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo |
| Brown et al. (2014) | Chuva e Temperatura | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ $K_c = K_0 + K_1 c$ | Temperatura global |
| Vogel et al. (2011) | Vazão | LN | $\mu_c = \mu_0 + \mu_1 c$ | Tempo |
| Lee et al. (2020) | Chuva | GP | $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Temperatura do ar e do ponto de orvalho |
| Prosdocimi et al. (2014) | Vazão | LN | $\mu_c = \mu_0 + \mu_1 c$ | Tempo e chuva |
| Serinaldi e Kilsby (2015) | Vazão | Gumbel | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo |
| Tramblay et al. (2013) | Chuva | GP | $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Índices climáticos |
| Renard et al. (2006) | Vazão | Exponencial e GP | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo |

Embora modelos não estacionários tenham sido amplamente utilizados nas últimas décadas, ainda não há um consenso na comunidade científica quanto ao uso desta abordagem. Autores como Milly et al. (2008) sugerem que a “estacionariedade está morta” diante das mudanças hidroclimáticas observadas nas últimas décadas, e reforçam a necessidade de se utilizar modelos capazes de levar em consideração estas mudanças no planejamento de recursos hídricos e análise de riscos (MILLY et al., 2008, 2015). Já autores como Montanari e Koutsoyiannis (2014) afirmam que a “estacionariedade é imortal”, e sugerem cautela no uso de modelos não

estacionários, bem como o uso de expressões como “a estacionariedade está morta”. Os autores defendem que modelos estacionários devem ser a técnica padrão, e que modelos não estacionários só devem ser aplicados quando as mudanças observadas são bem compreendidas através do uso de relações determinísticas hábeis a explicar a evolução de um processo ao longo do tempo e afirmam que “mudança” não significa necessariamente “não estacionariedade”. Isso se deve à incerteza associada à detecção e estimativa de tendências em séries históricas disponíveis, bem como a incerteza intrínseca em relação ao comportamento e permanência destas tendências no futuro (LUKE et al., 2017; MARTINS; STEDINGER, 2000; MATALAS, 1997; SERAGO; VOGEL, 2018; SERINALDI; KILSBY, 2015). Sadegh et al. (2015) sugerem que é preciso cautela antes de assumir um processo como não estacionário, uma vez que com registros históricos curtos, um evento de longa memória, que apresenta comportamento não estacionário em um determinado período de tempo, pode ser interpretado como não estacionário, mas que na verdade é estacionário (Figura 3).




Figura 3. Exemplo da influência do tamanho da amostra na interpretação quanto a estacionariedade ou não estacionariedade de uma série temporal. (a) primeiros 200 anos de observações, conclusão preliminar: série não estacionária. (b) série em sua totalidade (2000 anos de observações), conclusão: a série é estacionária e apresenta comportamento não estacionário em um determinado período de tempo, mas o processo é estacionário. As linhas pretas representam uma série sintética gerada a partir de um processo estocástico univariado e a linha em vermelho representa o valor da média.

A falta de consenso quanto ao uso de modelos não estacionários deve persistir ao longo dos próximos anos, em parte devido à incerteza na detecção, estimativa e extrapolação de tendências (já discutido aqui), e das diferentes perspectivas reportadas na literatura. Por exemplo,

alguns autores afirmam que o uso de modelos não estacionários pode melhorar a representação estatística de eventos extremos (LÓPEZ; FRANCÉS, 2013; STRUPCZEWSKI; SINGH; FELUCH, 2001; VILLARINI et al., 2009). Entretanto, outros autores afirmam que o uso de modelos não estacionários para estimativa e previsão de extremos ainda não é bem compreendido (i.e., poucos estudos validam os modelos utilizando um período independente do utilizado na estimativa dos parâmetros), além de que a incerteza promovida por este tipo de abordagem é uma das principais limitações do uso destes modelos, mesmo quando o processo envolvido é sabidamente não estacionário (LUKE et al., 2017).

2.3. ANÁLISE DE FREQUÊNCIA DE CHEIAS NO BRASIL

A análise de frequência de cheias sob condições não estacionárias é um tema amplamente abordado nos Estados Unidos (LUKE et al., 2017; SERAGO; VOGEL, 2018; SERINALDI; KILSBY, 2015; VOGEL; YAINDL; WALTER, 2011), Europa (HESARKAZAZI et al., 2021; PROSDOCIMI; KJELDSSEN; SVENSSON, 2014; ŠRAJ et al., 2016; STEIROU et al., 2019) e Ásia (DU et al., 2015; ZENG et al., 2017; ZHANG et al., 2015), e muitos outros (e.g., Tabela 1). Inclusive, algumas iniciativas de agências governamentais têm sugerido atualizações nas diretrizes e técnicas utilizadas para análise de frequência de cheias (e.g., Comissão Europeia, 2007). Exemplos de trabalhos relacionados a análise de frequência de cheias no Brasil são mostrados na Tabela 2. Este levantamento foi organizado de acordo com a distribuição de extremos utilizada, se considerou ou não a não estacionariedade das séries temporais, da estrutura do modelo e da covariável empregada (caso fosse não estacionário).

Tabela 2. Trabalhos relacionados a análise de frequência de cheias no Brasil. Notas: Notas: LP3 significa distribuição Log-Pearson 3, GEV significa distribuição Generalizada de Valor Extremo, LN significa distribuição Lognormal, GP significa distribuição generalizada de Pareto, P3 significa distribuição Pearson 3 e EXP significa distribuição exponencial. μ representa a média da distribuição considerada, α e β representam os parâmetros de posição e escala da distribuição considerada e λ representa o parâmetro da distribuição de Poisson, e c representa a covariável.

| Referência | Distribuição | Estrutura do Modelo | Covariável |
|--------------------------|----------------------------------|---|---------------------------------|
| Gomes e Vargas (2018) | Gumbel | Estacionário | |
| Speckhann et al. (2018) | LP3, GEV, LN e Gumbel | Estacionário | - |
| Natalina et al. (2007) | P3, LP3, EXP, LN, Gama e Weibull | Estacionário | - |
| Bartiko et al. (2019) | LN | $\mu_c = \mu_0 + \mu_1 c$ | Tempo |
| Silva et al. (2014) | Poisson | $\lambda_c = \exp(\lambda_0 + \lambda_1 c)$ | Oscilação do Atlântico Norte |
| Silva et al., 2015; 2017 | Poisson e GP | $\lambda_c = \exp(\lambda_0 + \lambda_1 c)$ $\lambda_c = \exp(\lambda_0 + \lambda_1 c + \lambda_2 c^2)$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ $\beta_c = \exp(\beta_0 + \beta_1 c + \beta_2 c^2)$ $\beta_c = \exp(\beta_0 + \beta_1 c + \beta_2 c^2 + \beta_3 c^3)$ | <i>El Niño</i> Oscilação Sul |
| Sales e Reis (2021) | GEV | $\alpha_c = \alpha_0 + \alpha_1 c$ $\beta_c = \exp(\beta_0 + \beta_1 c)$ | Tempo |

Segundo o levantamento realizado, tem-se que no Brasil, estudos relacionados a análise de frequência de cheias são timidamente explorados, até mesmo sob a hipótese de estacionariedade. Dentre estes trabalhos, destaca-se o de Bartiko et al. (2017), que utilizaram um modelo não estacionário baseado em uma regressão linear entre as séries de cheias e o tempo utilizando a distribuição Lognormal (análogo ao desenvolvido por VOGEL et al., 2011) aplicado a 157 bacias hidrográficas correspondentes a região Sul do Brasil. Os resultados indicam que 75 bacias hidrográficas foram ser consideradas como não estacionárias, sendo que a maior parte está concentrada nas bacias dos rios Iguazu, Paranapanema e Uruguai.

Silva et al., 2014, 2015 e 2107 também avaliaram bacias hidrográficas correspondentes a região Sul do Brasil, na bacia do Rio Itajaí. Neste trabalho, os autores avaliaram o uso de diferentes estruturas de modelos não estacionários utilizando a abordagem *peak-over-threshold* para as distribuições de Poisson e Generalizada de Pareto, em que um índice relacionado ao *El Niño* Oscilação Sul (índice NINO 3.4) foi utilizado como covariável. Segundo os autores, a

covariável utilizada demonstrou uma influência consistente nos regimes de vazões da bacia hidrográfica do Itajaí.

Sales e Reis (2021) avaliaram o desempenho de modelos estacionário e de diferentes estruturas de modelos não estacionário dependentes do tempo para bacias hidrográficas na região hidrográfica do Rio Uruguai. Os autores reportaram que há presença de séries não estacionárias na área de estudo, com um padrão espacial similar ao reportado por Bartiko et al. (2017), sendo a estrutura de modelo estacionário com mudança no parâmetro de posição e com coeficiente de variação fixo o mais adequado para a estimativa de cheias.

A existência de poucos estudos relacionados a análise de frequência de eventos de cheias no Brasil, bem como a não existência de iniciativas governamentais com diretrizes básicas para a realização deste tipo de estudo é preocupante, uma vez que a estimativa de vazões máximas é o passo básico para a avaliação de riscos e fundamental para concepção de projetos, operação e gerenciamento de estruturas hidráulicas. Portanto, existe uma grande e urgente necessidade de avanços na compreensão e estimativa de eventos fluviométricos extremos no Brasil.

3. MATERIAIS E MÉTODOS

3.1. ÁREA DE ESTUDO E DADOS FLUVIOMÉTRICOS

Foram utilizados dados diários de vazão disponibilizados na versão brasileira da base de dados *Catchment Attributes and Meteorology for Large-Sample Studies* (CAMELS-BR; CHAGAS et al., 2020), que compreende dados fluviométricos de 3679 bacias hidrográficas do Brasil disponíveis no Portal HidroWeb da Agência Nacional de Águas (ANA; <http://www.snirh.gov.br/hidroweb/>). Neste estudo, as bacias hidrográficas foram selecionadas com base no período histórico disponível e na qualidade de seus dados. Foram utilizados apenas séries de bacias hidrográficas com dados disponíveis no período de 1980-2018 (39 anos). Adicionalmente, similar a Papalexiou e Koutsoyiannis (2013), foram descartadas bacias hidrográficas com percentual de falhas superior a 30% nos anos com os 40% menores valores de vazão máxima diária anual. Além disso, foi conduzida uma análise exploratória dos dados, através da inspeção visual da curva de permanência das vazões diárias de cada ano. Neste procedimento, séries cujas medições apresentaram ordem incorreta de magnitude ou zeros no lugar de dados ausentes não foram incluídas na análise. A Figura 4 ilustra o procedimento de análise exploratória dos dados e mostra um exemplo de série que foi aprovada pelo controle de qualidade dos dados (Figura 4a) e que foi descartada da análise (Figura 4b). Este processo de controle de qualidade dos dados resultou na seleção de 379 bacias hidrográficas (Figura 5).




Figura 4. Controle de qualidade dos dados com o uso da curva da permanência. Exemplos de bacias hidrográficas em que a série de dados foi (a) aprovada pelo controle de qualidade dos dados (estação fluviométrica Fazenda Franciso, na bacia hidrográfica do Atlântico, trecho leste; ANA N° 56240000) e (b) descartada da análise (estação fluviométrica Derocal, na bacia hidrográfica do São Francisco; ANA N° 46455000).

Para cada bacia hidrográfica, foram geradas séries de vazão máxima anual (*annual maximum series* – AMS, em ordem cronológica). O registro completo de cada AMS (1980-2018) é definido como um vetor de N observações Q , e foi dividido em dois períodos: (1) período de calibração, $\mathbf{X} = \{Q_1, \dots, Q_n\}$, em que $n = 30$; e (2) período de validação $\mathbf{X}^* = \{Q_{n+1}, \dots, Q_N\}$.

Ressalta-se que os resultados encontrados neste trabalho estão atrelados ao período de análise escolhido. Portanto, os resultados podem ser significativamente alterados caso um período diferente seja utilizado.

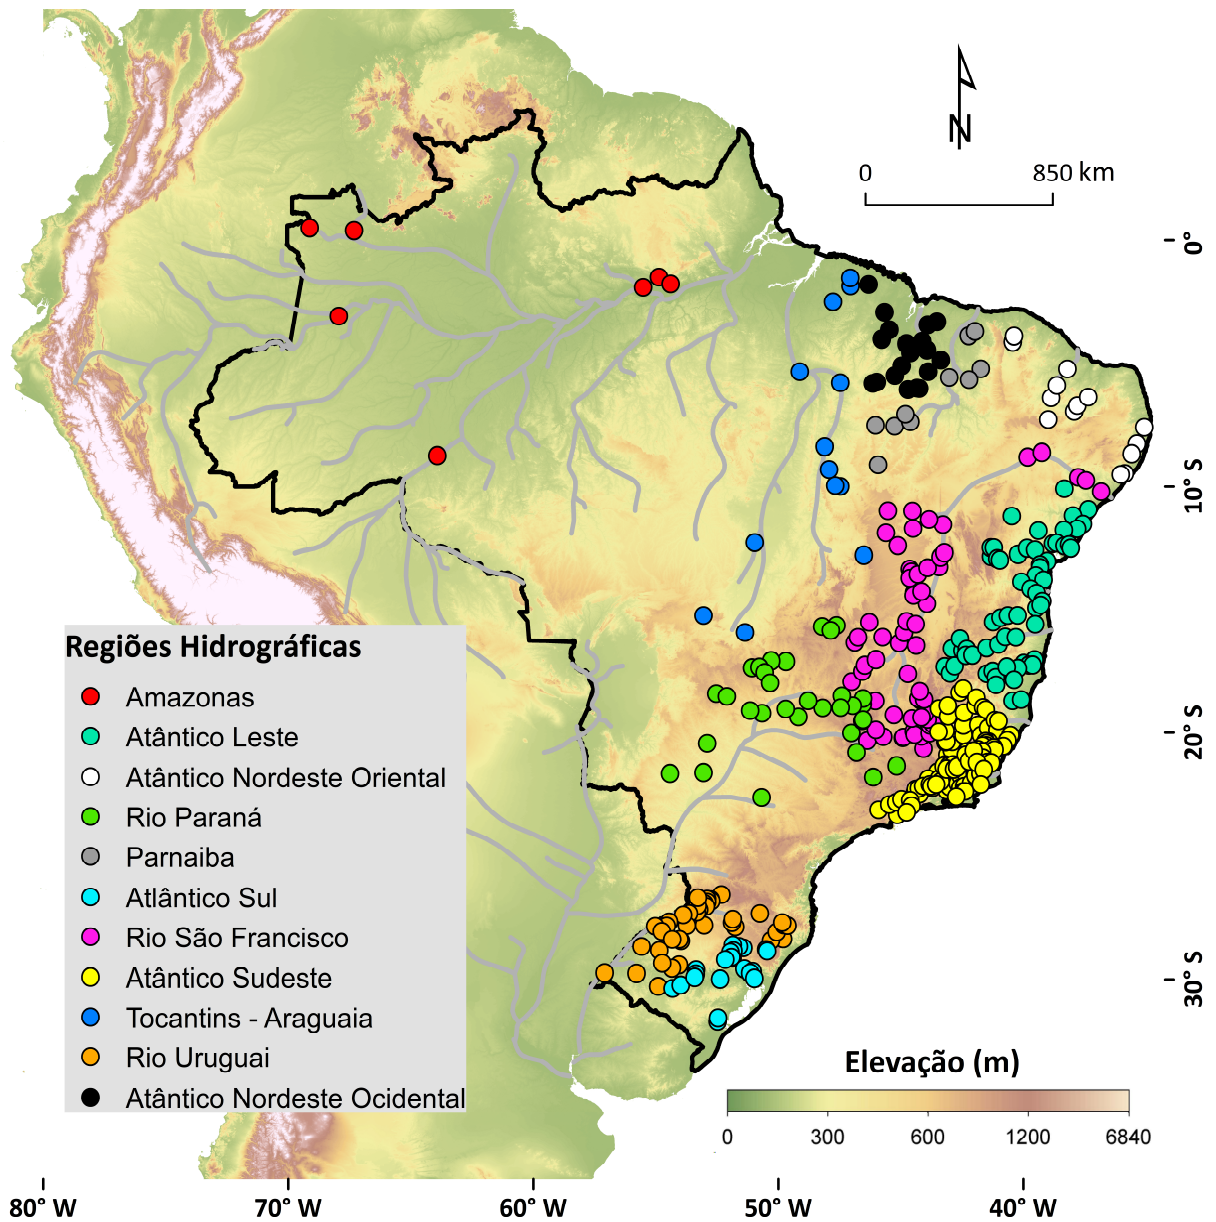


Figura 5. Localização das 379 bacias hidrográficas selecionadas para este estudo, classificadas de acordo com suas respectivas regiões hidrográficas (cores). A linha preta indica o limite territorial do Brasil e as linhas cinzas os cursos da água.

3.2. COVARIÁVEIS

Além das séries de vazão máxima anual de cada bacia hidrográfica necessárias para a análise de frequência de cheias, foram estabelecidas séries anuais (1980-2018) das covariáveis a serem utilizadas para explicar a evolução dos eventos de cheia ao longo do tempo. Similar a Chagas (2019), escolha das covariáveis deu-se de acordo com os seguintes critérios: (1) citações na literatura como variáveis de impacto nas mudanças do regime de cheias, (2) variáveis previamente utilizadas (e com bom desempenho) na literatura para a análise de frequência de cheias; (3) disponibilidade dos dados para a área de estudo e para o período analisado, (4) menor incerteza e maior resolução espacial dos dados. As covariáveis selecionadas para este estudo foram: tempo, chuva média anual, chuva máxima anual e umidade máxima anual do solo, temperatura média anual e um índice que representa o fenômeno *El Niño* Oscilação Sul (índice NINO 3.4).

A chuva média anual, chuva máxima anual de uma média móvel de 7 dias e temperatura média anual foram calculadas a partir de dados diários de chuva e temperatura provenientes do *National Oceanic and Atmospheric Administration Climate Prediction Center* (NOAA/CPC; <https://www.esrl.noaa.gov/psd/>), com resolução espacial de 0,5°. A umidade máxima do solo de uma média móvel de 7 dias foi calculada a partir de dados diários de umidade do solo adquirida do *Global Land Evaporation Amsterdam Model v3.3a* (GLEAM v3.3a; MARTENS et al., 2017; MIRALLES et al., 2011), com resolução espacial de 0,05°. O índice NINO 3.4 anual foi calculado como uma média dos meses de dezembro, janeiro e fevereiro, calculado a partir de dados mensais de temperatura da superfície do oceano pacífico equatorial, correspondente a região (5N-5S, 170W-120W), proveniente do NOAA CPC (https://psl.noaa.gov/gcos_wgsp/Timeseries/Data/nino34.long.data), com resolução espacial de 2°.

Com exceção dos dados utilizados para estabelecer o índice relacionado ao ENSO, todos os dados utilizados neste trabalho foram adquiridos e processados por Chagas et al. (2020). As séries diárias de chuva, temperatura e umidade do solo foram recortadas para cada bacia hidrográfica através da média dos valores diários dos pixels cujo os centroides interceptavam a área da bacia hidrográfica.

3.3. ANÁLISE DE FREQUÊNCIA DE EXTREMOS

Distribuição Generalizada de Valor Extremo

A distribuição Generalizada de Valor Extremo (GEV) foi utilizada na análise de frequência cheias. Esta distribuição é uma combinação de três distribuições assintóticas de valor extremo, sendo elas: Gumbel (Tipo I), Fréchet (Tipo II) e Weibull (Tipo III) (COLES, 2001). A parametrização aqui parametrização foi proposta por Mises (1936), embora seja comumente atribuída a Jenkinson (1955). A função de densidade de probabilidade (PDF), $f(x)$, da distribuição GEV é dada por:

$$f(x) = \frac{1}{\beta} \left(1 - K \left(\frac{x - \alpha}{\beta} \right) \right)^{-\left(\frac{1}{K} + 1\right)} \exp \left(- \left(1 + K \left(\frac{x - \alpha}{\beta} \right) \right)^{-\frac{1}{K}} \right) \quad \forall K \neq 0 \quad (1)$$

em que $\alpha \in \mathbb{R}$ é o parâmetro de posição e representa o centro da distribuição, $\beta > 0$ é o parâmetro de escala e representa a dispersão dos dados em torno de α , e $K \in \mathbb{R}$ é o parâmetro de forma e descreve o comportamento da cauda da distribuição. Para $K < 0$ tem-se a distribuição de Fréchet, enquanto que para $K > 0$, tem-se a distribuição de Weibull. Se $K \rightarrow 0$, a distribuição GEV se resume a distribuição de Gumbel (Figura 6a), i.e,

$$f(x) = \exp \left(- \exp \left(- \left(\frac{x - \alpha}{\beta} \right) \right) \right) \quad (2)$$

Neste trabalho, duas estruturas de modelo baseados na distribuição GEV foram consideradas: (1) modelo estacionário (ST), em que os parâmetros da distribuição GEV são considerados como constantes; (2) modelo não estacionário (NS) no qual os parâmetros da distribuição de extremos podem variar no tempo de acordo com uma covariável (c). A estrutura de modelo NS utilizada neste estudo assume duas premissas: (1) dependência linear entre o parâmetro de posição e a covariável (c), i.e,

$$\alpha_c = \alpha_0 + \alpha_1 c \quad (3)$$

em que α_0 e α_1 são os coeficientes linear e angular do modelo linear de tendência, respectivamente, e (2) coeficiente de variação (C_v) constante. Esta premissa foi adotada uma vez que quando o parâmetro de escala é mantido constante, assume-se que a variância dos eventos de cheia não muda ao longo do tempo. Com isso, tem-se que o coeficiente de variação da série de cheias varia ao longo do tempo – um resultado muito improvável de acordo com análises conduzidas com milhares de rios (PROSDOCIMI et al., 2014; VOGEL et al., 2011). O C_v da distribuição GEV é dado por:

$$c_v = \frac{\frac{1}{|K|} (\Gamma(1 + 2K) - \Gamma^2(1 + K))}{\frac{\alpha}{\beta} + \frac{1}{K} (1 - \Gamma(1 + K))} \quad (4)$$

Nota-se que para que C_v da distribuição GEV seja estacionário, é preciso garantir que a razão $\xi = \frac{\alpha}{\beta}$ seja constante – o parâmetro de escala deve variar proporcionalmente ao parâmetro de posição, i.e.,

$$\beta_c = \frac{\alpha_0 + \alpha_1 c}{\xi} \quad (5)$$

em que ξ é o fator de proporção entre α_c e β_c . Portanto, o modelo ST possui três parâmetros a serem inferidos $\theta_s = \{K, \beta, \alpha\}$, e o modelo NS possui quatro parâmetros $\theta_n = \{K, \xi, \alpha_0, \alpha_1\}$. A Figura 6b ilustra a flexibilidade adicional da estrutura do modelo NS utilizado neste estudo.

Os quantis da distribuição GEV, i.e., magnitude dos eventos de cheia associados a diferentes tempos de retorno (T_R), foram calculados a partir da inversa da distribuição de probabilidades acumuladas (CDF) da distribuição GEV, i.e.,

$$X_p = \left(\left(-\frac{1}{\log(p)} \right)^{-K} - 1 \right) \left(\frac{\beta_c}{K} \right) + \alpha_c \quad \forall K \neq 0 \quad (6)$$

em que X_p é o quantil associado a probabilidade de não excedência $p = 1 - \frac{1}{T_r}$. Nota-se que uma vez que a premissa de não estacionariedade permite que os parâmetros de posição (e consequentemente de escala) variem ao longo do tempo, os quantis da distribuição GEV também podem variar no tempo de acordo com os valores das covariáveis.

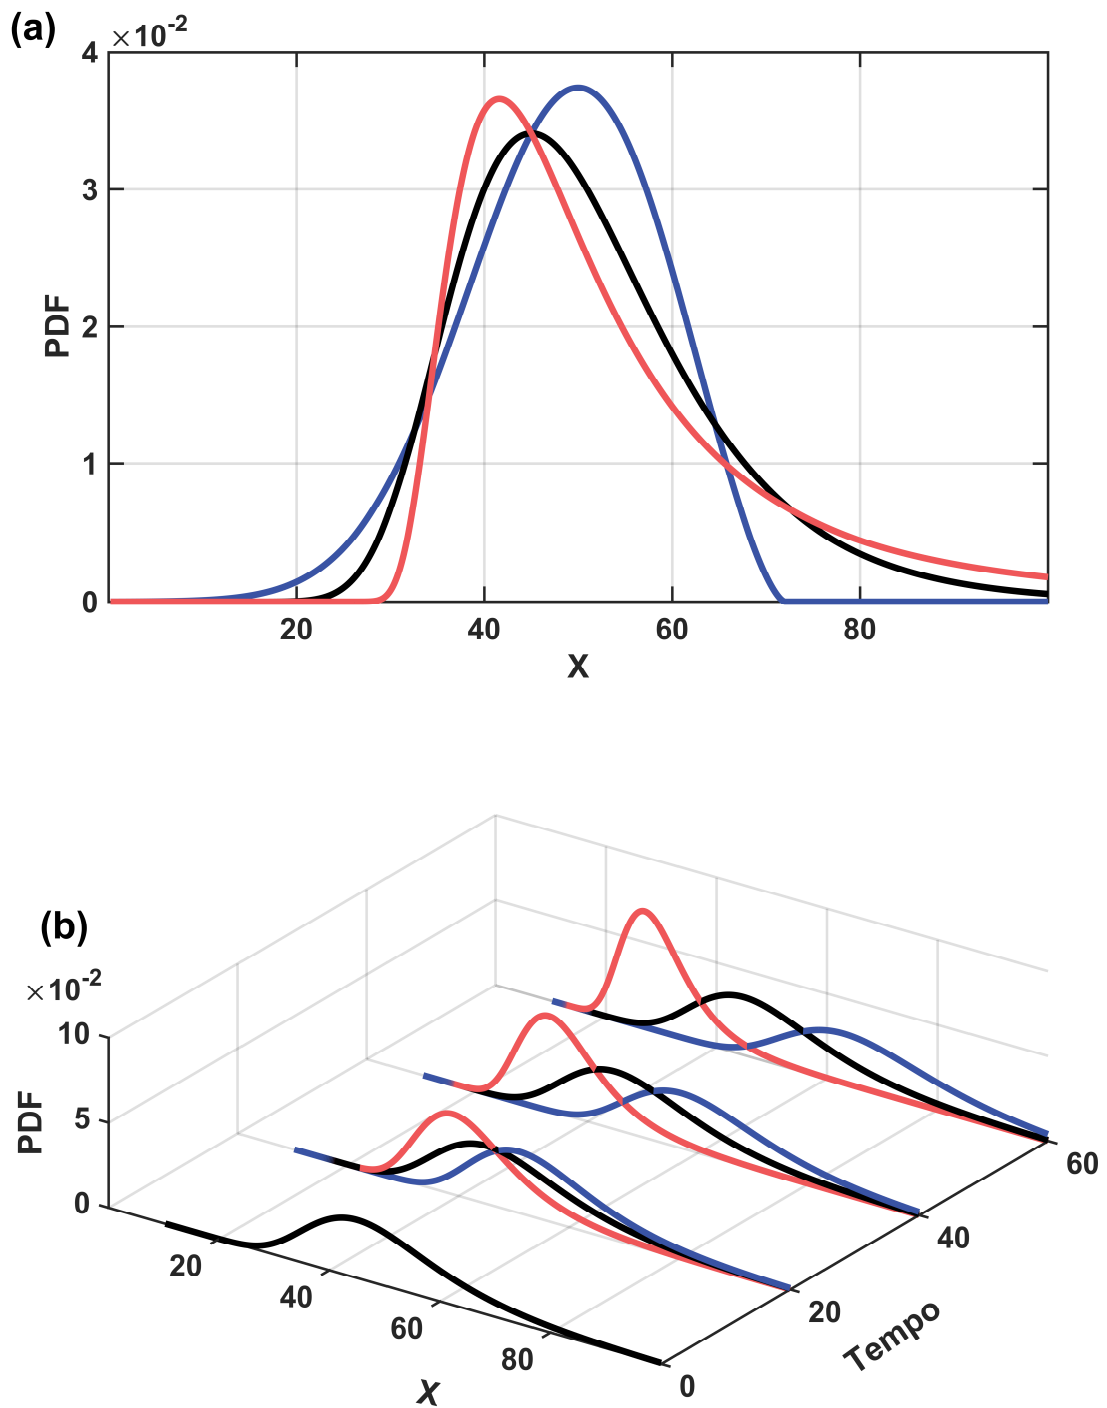


Figura 6. PDF da distribuição GEV para condições de (a) estacionariedade com diferentes valores do parâmetro de forma. As linhas azul, preta e vermelha correspondem a valores de $K < 0$ (Tipo II, Fréchet), $K = 0$ (Tipo I, Gumbel) e $K > 0$ (Tipo III, Weibull), respectivamente, e (b) não estacionariedade com diferentes valores do coeficiente angular do modelo linear de tendência. As linhas vermelha, preta e azul correspondem a $\alpha_1 < 0$, $\alpha_1 = 0$ e $\alpha_1 > 0$, respectivamente.

Aderência dos Dados à distribuição GEV

Neste trabalho, o teste de Kolmogorov-Smirnov (KS; MASSEY, 1951) foi utilizado para verificar a aderência das AMS à distribuição GEV, com nível de confiança de 99%. Trata-se de um teste não paramétrico e é utilizado para verificar se uma amostra segue uma determinada distribuição. A estatística do teste KS (D_N) é calculada através do módulo da máxima diferença entre as distribuições de probabilidade acumulada (CDF) da distribuição de interesse (F_1) e das observações (F_2):

$$D_N = |\max (F_1 - F_2)| \quad (7)$$

Caso D_N seja maior que um valor crítico (dado em função do nível de confiança adotado e do tamanho da amostra), rejeita-se a hipótese nula de que F_1 e F_2 possuem uma mesma distribuição.




Figura 7. Representação do teste de Kolmogorov-Smirnov. As linhas azul e vermelha representam as CDFs F_1 e F_2 , respectivamente. A linha preta representa a máxima diferença entre F_1 e F_2 .

Adicionalmente, a aderência dos dados a distribuição GEV foi verificada através da comparação entre as observações e as estimativas com a distribuição GEV. Nesta etapa, os parâmetros da distribuição GEV foram estimados pelo método de máxima verossimilhança com o uso do algoritmo *Expectation Maximization* (EM). Similarmente a Serago e Vogel (2018) e Ragno et al. (2019), duas métricas foram utilizadas: (1) *probability plot correlation coeficiente* (PPCC), que é o valor do coeficiente de correlação de Pearson calculado entre as observações e as estimativas com a distribuição GEV, e (2) *root mean square error* (RMSE).

Estimativa dos parâmetros

Neste trabalho, a estimativa conjunta dos valores dos parâmetros dos modelos ST e NS e da incerteza relativa a esta estimativa foram feitas a partir da inferência Bayesiana. A utilização da inferência Bayesiana permite a obtenção de uma distribuição probabilística para os parâmetros dos modelos e não de um único valor, sendo especialmente útil para o teste de hipóteses e análise de incertezas. Na abordagem Bayesiana para estimativa de parâmetros, as variáveis hidrológicas são consideradas como variáveis probabilística e então o teorema de Bayes é utilizado para atualizar a probabilidade de uma hipótese (modelo e conjunto de parâmetros) com base em uma evidência (observações). Segundo este teorema, a distribuição a *posteriori*, $P(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j)$ do modelo \mathcal{M}_j com parametrização $\boldsymbol{\theta}_j$ é calculada a partir da distribuição a *priori*, $P(\boldsymbol{\theta}_j|\mathcal{M}_j)$, da função de verossimilhança, $L(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j)$, e da evidência $P(\mathbf{X}|\mathcal{M}_j)$ dos respectivos modelos \mathcal{M}_j com parametrização $\boldsymbol{\theta}_j$, i.e.,

$$P(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j) = \frac{P(\boldsymbol{\theta}_j|\mathcal{M}_j) L(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j)}{P(\mathbf{X}|\mathcal{M}_j)} \quad (8)$$

em que o subscrito j denota o modelo, sendo $j = s$ para o modelo ST e $j = n$ para o modelo NS. e \mathbf{X} é um vetor de n observações $\mathbf{X} = \{X_1, \dots, X_n\}$, i.e., série de vazões máximas anuais contendo os dados referentes ao período de calibração (primeiros 30 anos).

Conceitualmente, a distribuição a *priori* resume a informação a respeito dos valores dos parâmetros dos modelos antes da inclusão das informações fornecidas pelos dados no processo de inferência. A escolha de $P(\boldsymbol{\theta}_j|\mathcal{M}_j)$ é, muitas vezes, subjetiva e depende do conhecimento do modelador, da informação disponível na literatura em relação ao processo de interesse ou então via regressão regional (regionalização hidrológica). Neste trabalho foram utilizadas como distribuição a *priori* uma distribuição uniforme para os parâmetros de posição e de escala, em que foram definidos os limites inferior e superior de cada parâmetro. Para o parâmetro de forma, utilizou-se informação regional disponível em Papalexiou e Koutsoyiannis (2013), i.e., que é representada por uma distribuição normal com média $\mu = 0,093$ e desvio padrão $\sigma = 0,12$ i.e., $P(K|\mathcal{M}_j) \sim \mathcal{N}(\mu, \sigma)$. Esta distribuição a *priori* foi obtida com dados de mais de 15.000 séries de precipitação máxima anual em todo o mundo e é bastante similar à distribuição a *priori* geofísica disponível em Martins e Stedinger (2000), que também é utilizada para restringir os valores do parâmetro de forma. Sabe-se que há uma diferença entre a forma da distribuição para extremos de chuvas e vazão. Entretanto, a distribuição a *priori* geofísica é limitada no intervalo

de -0,5 a 0,5, e uma vez que valores fora deste intervalo foram observados por Papalexiou e Koutsoyiannis (2013), a informação disponibilizada pelos autores foi utilizada, permitindo a amostragem de valores fora do limite -0,5 a 0,5 com uma baixa probabilidade. A Tabela 3 mostra um exemplo de definição da distribuição *a priori* e especificações dos parâmetros dos modelos ST e NS

Tabela 3. Exemplo de definição da distribuição *a priori* e especificações dos parâmetros dos modelos ST e NS. As especificações dos parâmetros do modelo NS são relativas ao modelo que utiliza o tempo como covariável. a e b são os valores dos limites inferior e superior da distribuição uniforme ($\mathcal{U}(a, b)$) de cada parâmetro e μ e σ são os valores da média e de desvio padrão da distribuição normal ($\mathcal{N}(\mu, \sigma)$) disponível em Papalexiou e Koutsoyiannis (2013).

| Distribuição a <i>Priori</i> | | a | b | Unidade |
|--|----------------------------|----------|----------|--------------------------------------|
| Parâmetros \mathcal{M}_s | | | | |
| K | $\mathcal{N}(\mu, \sigma)$ | 0,093 | 0,12 | - |
| β | $\mathcal{U}(a, b)$ | 0 | 150 | mm d ⁻¹ |
| α | $\mathcal{U}(a, b)$ | 0 | 250 | mm d ⁻¹ |
| Parâmetros \mathcal{M}_n | | | | |
| K | $\mathcal{N}(\mu, \sigma)$ | 0,093 | 0,12 | - |
| ξ | $\mathcal{U}(a, b)$ | 0 | 50 | mm d ⁻¹ |
| α_0 | $\mathcal{U}(a, b)$ | 0 | 250 | mm d ⁻¹ |
| α_1 | $\mathcal{U}(a, b)$ | -5 | 5 | mm d ⁻¹ ano ⁻¹ |

A função de verossimilhança representa probabilisticamente o quão plausível é uma amostra dado um determinado conjunto de parâmetros e é responsável por sumarizar as informações fornecidas pelos dados utilizados na calibração. Matematicamente, $L(\boldsymbol{\theta}_j | \mathbf{X}, \mathcal{M}_j)$ é a calculada a partir da PDF da distribuição GEV, que representa a densidade de probabilidade dos valores de \mathbf{X} para o modelo \mathcal{M}_j com parametrização $\boldsymbol{\theta}_j$, i.e.,

$$L(\boldsymbol{\theta}_j | \mathbf{X}, \mathcal{M}_j) = \prod_{i=1}^n P(X_i | \boldsymbol{\theta}_j, \mathcal{M}_j) \quad (9)$$

em que n é o número de observações no período de calibração e X_i é a i ésima observação de \mathbf{X} .

Para o modelo ST, tem-se que $\boldsymbol{\theta}_s = \{K, \beta, \alpha\}$ é constante ao longo do tempo e, portanto, a função de verossimilhança é calculada para uma parametrização fixa da distribuição GEV.

Entretanto, sob a suposição de não estacionariedade, tem-se $\boldsymbol{\theta}_n = \{K, \xi, \alpha_0, \alpha_1\}$ e então a parametrização da distribuição GEV varia linearmente no tempo de acordo com a covariável adotada:

$$\boldsymbol{\theta}_n^i = \left\{ K, \frac{(\alpha_0 + c_i \alpha_1)}{\xi}, \alpha_0 + c_i \alpha_1 \right\} \quad (10)$$

em que c_i é o valor da covariável no tempo $i = \{1, \dots, n\}$.

O denominador do teorema de Bayes, também chamado de probabilidade marginal ou evidência, atua como uma constante de normalização para que a distribuição a posteriori tenha área unitária e é definida como:

$$P(\mathbf{X}|\mathcal{M}_j) = \int P(\boldsymbol{\theta}_j|\mathcal{M}_j) L(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j) d\boldsymbol{\theta}_j \quad (11)$$

O procedimento de inferência dos parâmetros pode ser feito através dos valores não normalizados da distribuição *a posteriori*, i.e.,

$$P(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j) \propto P(\boldsymbol{\theta}_j|\mathcal{M}_j) L(\boldsymbol{\theta}_j|\mathbf{X}, \mathcal{M}_j) \quad (12)$$

Normalmente, a expressão da distribuição *a posteriori* não possui solução analítica, sendo então necessário a utilização de métodos de amostragem para sua solução. Portanto, para aproximar a distribuição *a posteriori* foram utilizadas simulações de Monte Carlo via Cadeias de Markov (MCMC) com o algoritmo *Differential Evolution Adaptive Metropolis* (DREAM_(ZS); VRUGT, 2016). 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; e número de gerações. O algoritmo foi executado com 3 Cadeias de Markov e 8.000 iterações em cada cadeia, conforme sugerido por Luke et al. (2017). Para garantir que a distribuição *a posteriori* fosse estacionária, 50% dos valores iniciais de cada cadeia foram descartados, resultando em uma distribuição *a posteriori* com 12.000 conjuntos de parâmetros.

3.4. INFLUÊNCIA DAS COVARIÁVEIS NO REGIME DE CHEIAS

A análise da influência das covariáveis no regime de cheias foi feita de duas maneiras (1) correlação de Spearman, e (2) análise da distribuição *a posteriori* do coeficiente angular do modelo NS (parâmetro de α_1) e são descritas a seguir.

Correlação de Spearman

O coeficiente de correlação de Spearman foi utilizado para verificar a correlação entre as covariáveis e as cheias, com nível de confiança de 95%. O coeficiente de correlação, ρ , é calculado como:

$$\rho = 1 - \frac{6 \sum_{i=1}^n R_i^2}{n(n^2 - 1)} \quad (13)$$

em que R_i é a diferença entre duas variáveis ranqueadas na posição i . Sob a hipótese nula, espera-se que ρ seja normalmente distribuído com média zero e variância (V) igual a:

$$V(\rho) = \frac{1}{1 - n} \quad (14)$$

O teste estatístico padronizado é então calculado como:

$$Z = \frac{\rho}{V(\rho)} \quad (15)$$

Por fim, o p-valor é calculado através da distribuição normal padrão e é considerado como significativo se o $|Z|$ for maior que um valor crítico, calculado em através da distribuição normal padrão em função do nível de confiança adotado. A hipótese nula é que não há correlação e a hipótese alternativa é de que há correlação.

Análise da distribuição a *posteriori* do parâmetro α_1

Similar a Steirou et al. (2019), analisou-se a distribuição a *posteriori* dos valores do coeficiente angular do modelo NS (parâmetro α_1) para cada covariável. As covariáveis foram consideradas estatisticamente significativas no regime de cheias se o intervalo de credibilidade de 95% da distribuição a *posteriori* (valores entre os percentis 2,5 e 97,5) de α_1 concordarem com o sinal de mudança, i.e., o valor zero não se encontra nesse intervalo. Para melhor ilustrar este procedimento, a Figura 8 mostra um exemplo de influência de sinal negativo (Figura 8a), influência não significativa (Figura 8b) e influência de sinal positivo (Figura 8c).




Figura 8. Exemplo de análise da influência da covariável no regime de cheias para: (a) influência de sinal negativo, (b) influência não significativa e (c) influência de sinal positivo. As linhas tracejadas

representam um intervalo de credibilidade de 95% do parâmetro α_1 e o marcador em formato de x representa o valor zero.

3.5. ANÁLISE DE PERFORMANCE

Segundo a teoria da Navalha de Ockham, quando modelos com diferentes níveis de complexidade são comparados, e estes apresentam capacidade similar e satisfatória em representar um processo, o mais simples deve ser selecionado – conceito de parcimônia aplicado a modelagem hidrológica. Em geral, um aumento na complexidade do modelo implica em uma maior habilidade deste em se ajustar à série utilizada para inferência dos parâmetros. Assim, para evitar a escolha de um modelo super ajustado a série de calibração e que resultaria em um alto erro quando utilizado para estimar dados independentes dos utilizados na calibração (devido a maior incerteza acerca da estimativa de seus parâmetros), medidas de controle de complexidade devem ser consideradas. Neste trabalho, dois métodos foram adotados na seleção dos modelos: (1) uso dos critérios de informação e (2) validação.

Critérios de informação

Os critérios de informação são utilizados para identificar o modelo que recebe maior suporte pelas observações e representam uma medida relativa da informação que é perdida se um modelo é utilizado para descrever uma série de dados (VOLPI et al., 2017). A formulação matemática dos critérios de informação leva em consideração o desempenho do modelo, i.e., sua habilidade em reproduzir a série de dados utilizada na inferência dos parâmetros do modelo e o seu nível de complexidade, i.e.,

$$I_j = -2 \log_e \left(L(\hat{\theta}_j | \mathbf{X}, \mathcal{M}_j) \right) + C \quad (16)$$

em que I_j representa o valor do critério de informação, sendo $I = \{AICc, BIC\}$; $L(\hat{\theta}_j | \mathbf{X}, \mathcal{M}_j)$ é o valor da função de verossimilhança associado ao conjunto ótimo de parâmetros $(\hat{\theta}_j)$ - conjunto de parâmetros que maximiza a distribuição a *posteriori* (*maximum a posteriori* – MAP). C é uma constante de valor positivo que penaliza a complexidade do modelo. Assim, o aumento de complexidade do modelo (adição de novos parâmetros) é justificado apenas quando o ganho de desempenho do modelo supera o incremento no termo que penaliza a sua complexidade. Como critérios de informação, utilizou-se os critério de informação de Akaike para pequenas amostras (AICc; SUGIURA, 1978) e o critério de informação de Bayes (BIC; SCHWARZ, 1978). O termo que penaliza a complexidade dos modelos para o AICc

e BIC depende do número de parâmetros do modelo (d) e do tamanho da série de dados utilizada na inferência dos parâmetros (n). Para o AICc, tem-se que $C = 2d \left(\frac{d+1}{n-d-1} \right)$, enquanto que para o BIC tem-se $C = d \log_e(n)$.

Para uma melhor visualização dos resultados, foram calculados os valores de suporte relativo à utilização do modelo estacionário, i.e.,

$$\Delta I_j = I_s - I_{\text{MIN}} \quad (17)$$

em que ΔI_j é o suporte relativo à utilização do modelo estacionário para cada critério de informação, I_s é o valor do critério de informação para o modelo estacionário e I_{MIN} é o valor do critério de informação para o melhor modelo (menor valor do critério de informação entre todos os modelos considerados). Segundo Burnham e Anderson (2003), valores de ΔI entre 0 e 2 indicam suporte considerável, entre 4 e 7 indicam suporte consideravelmente menor, e valores maiores que 10 indicam a inexistência de suporte ao modelo estacionário.

Validação

Uma vez que modelos NS podem ser utilizados para extrapolar a tendência inferida no período de calibração para o futuro, é importante que a habilidade destes modelos em estimar dados independentes dos utilizados na inferência de seus parâmetros seja testada. Portanto, os últimos 9 registros de cada AMS (\mathbf{X}^*) foram reservados para avaliar a habilidade preditiva dos modelos.

O procedimento de validação dos modelos consiste em utilizar os parâmetros inferidos na calibração para estimar as observações do período de validação. Similarmente ao que foi apresentado para calibração, para o modelo ST, os parâmetros da distribuição GEV são assumidos como constantes ao longo do tempo. Para o modelo NS, duas abordagens foram consideradas: (1) extrapolação da tendência inferida, em que se assume que os parâmetros de posição (e consequentemente de escala) da distribuição GEV variam no tempo de acordo com o valor da covariável ao longo do período de validação, e (2) utilização de um modelo estacionário atualizado (uST). Nesta segunda abordagem, os parâmetros do modelo NS ao final do período de calibração (parâmetros mais atuais) são utilizados para estimar as observações do período de validação como um modelo ST – um modelo ST é atualizado a partir dos parâmetros do modelo NS. Neste caso, a mudança observada nos parâmetros de posição (e consequentemente de escala) da distribuição GEV são considerados, entretanto, não é extrapolada. A Figura 9a ilustra as estratégias de validação adotadas neste trabalho para os modelos ST (azul), modelo

uST (amarelo) e NS (vermelho). Na Figura 9(b-d) são mostradas a PDF empírica das observações do período da validação (histograma em cinza) e a PDF dos modelos ST, uST e NS.




Figura 9. (a) Estimativas MAP do parâmetro de posição da distribuição GEV (linhas sólidas) para os modelos ST (azul), uST (amarelo) e NS (vermelho) inferidos a partir da série máxima anual da estação fluviométrica Óbidos (linha preta), localizada na bacia do rio Amazonas (ANA N° 17050001) para o período de calibração (1980 – 2009). As faixas sombreadas em azul, amarelo e vermelho representam um intervalo de credibilidade de 90% da estimativa do parâmetro de posição para os modelos ST, uST e NS, respectivamente. (b-d) Os histogramas em cinza representam a PDF empírica dos dados referentes ao período de validação (2010-2018) e as linhas em azul, amarelo e vermelho representam as estimativas MAP da PDF da distribuição GEV para os modelos ST, uST e NS (extrapolação de 45 anos em relação ao final do período de calibração), respectivamente. O modelo não estacionário mostrado é o que utiliza o tempo como covariável.

A habilidade preditiva dos modelos durante o período de validação foi avaliada com o uso da evidência do teorema de Bayes. A evidência (Equação 11) é definida como um valor médio da função de verossimilhança ao longo da distribuição *a priori*. O modelo com maior valor de evidência é estatisticamente preferido. Em geral, quanto maiores e mais uniformemente distribuídos forem os valores da função de verossimilhança, maior o valor da evidência. Modelos mais simples tendem a produzir um maior valor médio nos hiperespaços de parâmetros e menores picos na função de verossimilhança. Por outro lado, modelos mais complexos apresentam um maior hiperespaço dos parâmetros e tendem a apresentar maiores picos na função de verossimilhança quando comparado a modelos mais simples. Isso ocorre pois o modelo mais complexo tenta aumentar sua probabilidade marginal, fazendo com que a região do hiperespaço dos parâmetros em que a função de verossimilhança é maximizada compense regiões em que a habilidade preditiva do modelo é menor. Portanto, a utilização da evidência na seleção dos

modelos pode ser interpretada como uma formalização do conceito de parcimônia, automaticamente penalizando incerteza e adição de complexidade - um modelo mais simples e com um hiperespaço de parâmetros mais compacto é preferido, a não ser que o uso de um modelo mais complexo seja significativamente melhor em representar as observações (VOLPI et al., 2017).

A comparação da habilidade preditiva através da evidência dos modelos foi feita através do uso do fator de Bayes (BF), que resume a evidência fornecida pelos dados em favor de um modelo estatístico em relação a outro (KASS; RAFTERY, 1995). Matematicamente, o BF é definido como:

$$B_{j,k} = 2 \log_e \left(\frac{P(\mathbf{X}^* | \mathcal{M}_j)}{P(\mathbf{X}^* | \mathcal{M}_k)} \right) \quad (18)$$

em que $B_{j,k}$ é o valor do BF do modelo \mathcal{M}_j em relação ao modelo \mathcal{M}_k . Optou-se por utilizar uma escala logarítmica do BF por simples interpretação dos resultados: um valor positivo de $B_{j,k}$ favorece a seleção do modelo \mathcal{M}_j , enquanto um valor negativo favorece a seleção do modelo \mathcal{M}_k . Segundo Kass e Raftery (1995), valores de $B_{j,k}$ entre 0 e 2 indicam um suporte fraco, valores entre 2 e 6 um suporte positivo, valores entre 6 e 10 um suporte forte e valores maiores que 10 indicam um suporte muito forte ao modelo \mathcal{M}_j .

Neste trabalho, a estimativa da evidência de cada modelo foi feita com o uso do algoritmo *Gaussian Mixture Importance Sampling* (GAME; VOLPI et al., 2017), disponível no *DREAM Package* versão 2.0. Essencialmente, o GAME consiste em uma técnica de integração de Monte Carlo no hiperespaço dos parâmetros. O uso do GAME exige que o usuário forneça como entrada a distribuição a *posteriori*, neste caso, referente ao período de validação, i.e.,

$$P(\boldsymbol{\theta}_j | \mathbf{X}^*, \mathcal{M}_j) \propto P(\boldsymbol{\theta}_j | \mathcal{M}_j) L(\boldsymbol{\theta}_j | \mathbf{X}^*, \mathcal{M}_j) \quad (19)$$

em que $P(\boldsymbol{\theta}_j | \mathbf{X}^*, \mathcal{M}_j)$ é a distribuição a *posteriori*, $P(\boldsymbol{\theta}_j | \mathcal{M}_j)$ é a distribuição a *priori* e $L(\boldsymbol{\theta}_j | \mathbf{X}^*, \mathcal{M}_j)$ é a função de verossimilhança, referentes ao período de validação.

Similarmente a Luke et al. (2017), a distribuição a *priori* do período de validação dos modelos ST, uST e NS foi definida a partir da distribuição a *posteriori* do período de calibração de cada um dos modelos através do ajuste de um *Gaussian Mixture Model* (GMM) com m componentes. O GMM foi escolhido para aproximar a distribuição a *priori* do período de validação uma vez que é capaz de representar um grande número de classes de distribuições. Os parâmetros do GMM foram estimados por máxima verossimilhança, com o aumento sucessivo do número de componentes até que $BIC_m - BIC_{m+1} < 2$ com o uso do algoritmo EM. A Figura

10 mostra um exemplo de GMM ajustado a distribuição *a posteriori* dos modelos ST (Figura 10a), uST (Figura 10b) e NS (Figura 10c).

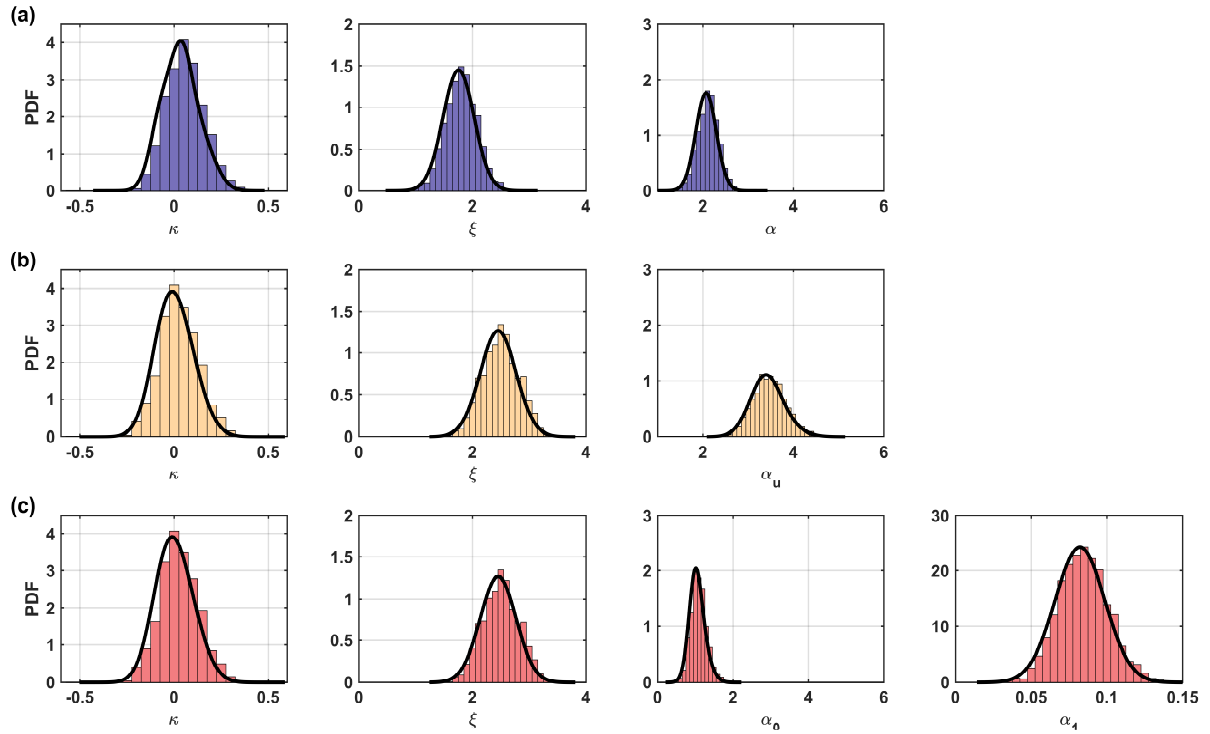


Figura 10. Exemplo de GMM ajustado à distribuição *a posteriori* (linha preta) para os modelos (a) ST (histogramas em azul), (b) uST (histogramas em amarelo) e (c) NS (histogramas em vermelho), inferidos a partir da série máxima anual da estação fluviométrica Esperantina, localizada na bacia hidrográfica do Atlântico, trecho Norte/Nordeste (ANA N° 33170000). O modelo não estacionário mostrado é o que utiliza o tempo como covariável.

A função de verossimilhança do período de validação é calculada com a Equação 20 através dos conjuntos de parâmetros inferidos na calibração avaliados para os dados do período de validação, i.e.,

$$L(\boldsymbol{\theta}_j | \mathbf{X}^*, \mathcal{M}_j) = \prod_{i=1}^{n^*} P(X_i | \boldsymbol{\theta}_j, \mathcal{M}_j) \quad (20)$$

em que n^* é o número de observações no período de validação. Matematicamente, não há diferença na expressão utilizada para calcular a função de verossimilhança para os modelos ST e uST, uma vez que para ambos os modelos a função de verossimilhança é calculada para valores fixos de $\boldsymbol{\theta}_s$ para o modelo ST e $\boldsymbol{\theta}_u$ para o modelo uST.

4. RESULTADOS E DISCUSSÃO

4.1. ADERÊNCIA DOS DADOS À DISTRIBUIÇÃO GEV

A aderência dos dados à distribuição GEV foi verificada com o uso do teste de Kolmogorov-Smirnov (KS) e de duas métricas baseadas na comparação entre as observações e as estimativas com a distribuição GEV, i.e., *probability plot correlation coefficient* (PPCC) e *root mean square error* (RMSE). Os resultados desta etapa são mostrados na Figura 11.

Os resultados mostram que os três métodos utilizados na verificação concordam que a distribuição GEV é adequada para representar estatisticamente os eventos de cheia. Os dados das séries de vazão máxima anual (período de calibração) de todas as 379 bacias hidrográficas utilizadas neste trabalho tiveram aderência à distribuição GEV de acordo com o teste KS, com um nível de confiança 99%, em que não foi possível rejeitar a hipótese nula de que os dados seguem uma distribuição GEV (Figura 11a). O uso das métricas baseadas na comparação entre as observações e as estimativas com a distribuição GEV também confirmam os resultados obtidos com o teste KS. Os resultados com a métrica PPCC (Figura 11b) mostram que há forte correlação entre as observações e as estimativas obtidas com a distribuição GEV, sendo estas correlações significativas para um nível de confiança de 99% e com baixos valores de RMSE (Figura 11c).




Figura 11. Resultados para a verificação da aderência dos dados à distribuição GEV para (a) teste de Kolmogorov-Smirnov, (b) *probability plot correlation coefficient* (PPCC) e (c) *root mean square error* (RMSE).

4.2. RELAÇÃO ENTRE CHEIAS E COVARIÁVEIS

A análise da influência das covariáveis no regime de cheias foi feita de duas maneiras (1) teste de correlação de Spearman, com nível de confiança de 95% e (2) análise da distribuição *a posteriori* do coeficiente angular do modelo NS - as covariáveis foram consideradas estatisticamente significativas no regime de cheias se o intervalo de credibilidade de 95% da distribuição *a posteriori* de α_1 (valores entre os percentis 2,5 e 97,5) não contivesse o valor zero. Os resultados para a análise de correlação são mostrados nas Figuras 12 e 13. Há presença de correlação significativa (positivas e negativas) entre as séries de vazão máxima anual e as séries anuais de todas as covariáveis utilizadas neste estudo. Entretanto, o sinal e a distribuição espacial variam ao longo da área de estudo e de acordo com a covariável. Ressalta-se que apesar dos resultados aqui mostrados, não é possível ter sólidas conclusões sobre as relações entre as cheias e as covariáveis no Norte e Centro-Oeste do Brasil, em decorrência da não homogeneidade na distribuição de estações de monitoramento, bem como da limitada quantidade de séries disponíveis referentes a estas duas regiões.

Para a covariável tempo (Figura 12a), correlações positivas foram encontradas em bacias hidrográficas correspondentes ao Sul, Norte e parte do Sudeste do Brasil. Por outro lado, é possível identificar correlações negativas em séries correspondentes a quase todo o Nordeste e ao restante do Sudeste do país. Na região Centro-Oeste do Brasil, não há um padrão espacial claro para as correlações. Os resultados desta análise são equiparáveis com resultados obtidos análise de tendência (e.g., teste de Mann-Kendall) e são similares aos encontrados por outros estudos, tanto para o sinal da correlação/tendência bem como para sua distribuição espacial (e.g., BARTIKO et al., 2019; CHAGAS, 2019).

Para a temperatura média anual (Figura 12b), há uma predominância de correlações de sinal negativo para toda a área de estudo, especialmente para as bacias hidrográficas correspondentes a região Nordeste e Sudeste do Brasil. Em algumas regiões há presença de correlações positivas, e.g., regiões Sul, Sudeste e Centro-Oeste. Entretanto, o padrão espacial encontrado não é tão claro e a maioria destas correlações não foram significativas. Como explicação para este resultado, tem-se como hipótese de que um aumento na temperatura pode alterar as condições de umidade do solo, i.e., atuando como um *proxy* para evaporação, resultando em uma redução na magnitude dos eventos de cheia – um resultado diferente do esperado dada a relação de Clausius-Clapeyron.

O índice do *El Niño* Oscilação Sul (Figura 12c), apresentou correlações significativas para um pequeno número de bacias hidrográficas. As correlações são, em geral positivas (e não significativas) para a maior parte da área de estudo, principalmente para bacias hidrográficas correspondentes as regiões Sul, Sudeste e Nordeste do Brasil, com correlações significativas de sinal positivo para algumas bacias hidrográficas das regiões Sul e Sudeste e de sinal negativo na porção superior da região Nordeste, sendo estas últimas predominantemente negativas.

A chuva média anual (Figura 12d), chuva máxima anual de uma média móvel de 7 dias (Figura 12e) e a umidade máxima do solo de uma média móvel de 7 dias (Figura 12f), apresentaram uma predominância de correlações de sinal positivo distribuídas ao longo de toda a área de estudo, sendo estas significativas para aproximadamente 82%, 84% e 90%, respectivamente. Este resultado sugere que estas covariáveis apresentam bastante influência no regime de cheias no Brasil. Em relação a chuva média anual, resultados semelhantes foram encontrados por Šraj et al. (2016) e Hesarkazzazi et al., (2021), que avaliaram bacias hidrográficas na Eslovênia e Inglaterra, respectivamente. A hipótese levantada para estes resultados é que a chuva anual atua como um *proxy* para a capacidade de armazenamento das bacias hidrográficas, em que anos mais úmidos estão relacionados a eventos de cheia de maior magnitude.

Já para as covariáveis de chuva máxima e umidade máxima do solo, o padrão para o sinal e distribuição espacial encontrado foi semelhante ao reportado por Chagas e Chaffe (2021), em que os autores formularam duas hipóteses para os mecanismos das cheias no Brasil: (1) regiões em que as bacias hidrográficas apresentam maior capacidade de armazenamento, fazendo com que as cheias sejam menos sensíveis à chuva e controladas especialmente pela umidade do solo máxima, e (2) regiões em que as bacias hidrográficas apresentam uma menor capacidade de armazenamento, fazendo com que o solo sature rapidamente devido ao evento de precipitação.

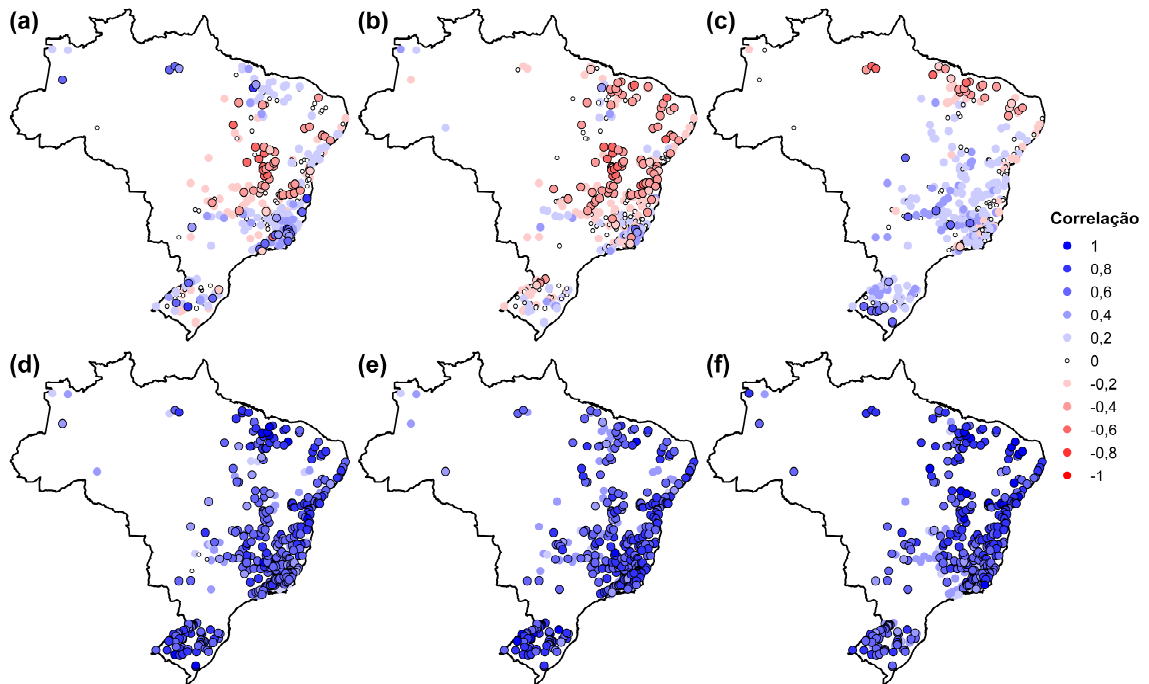


Figura 12. Influência das covariáveis no regime de cheias para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores dos círculos representam o valor do coeficiente de correlação de Spearman entre a covariável e a série de cheias (período de calibração). Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo o teste de correlação de Spearman com nível de confiança de 95%




Figura 13. Histogramas do coeficiente de correlação entre as séries de vazão máxima anual e as séries anuais das covariáveis para (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias.

Os resultados para o segundo método de avaliação da influência das covariáveis no regime de cheias é mostrado na Figura 14. Em geral, tem-se que os resultados obtidos com este método são bastante similares com os encontrados com a análise com a correlação de Spearman,

tanto para o sinal das correlações/influências, bem como para significância estatística e distribuição espacial. A exceção fica por conta covariável de umidade máxima do solo, que apresentou correlação significativa para um grande número de bacias hidrográficas (~90%), mas não foi considerada influente pelo modelo linear de tendência empregado no modelo NS. Isso ocorre porque em geral, as relações encontradas entre as cheias e a umidade máxima do solo não são necessariamente lineares e sim monotônicas (i.e., as variáveis que tendem a aumentar/diminuir simultaneamente, mas não necessariamente a uma taxa constante de mudança). Assim, uma vez que a correlação de Spearman é capaz de capturar estas relações monotônicas, há uma discordância quanto a significância estatística dos dois métodos.

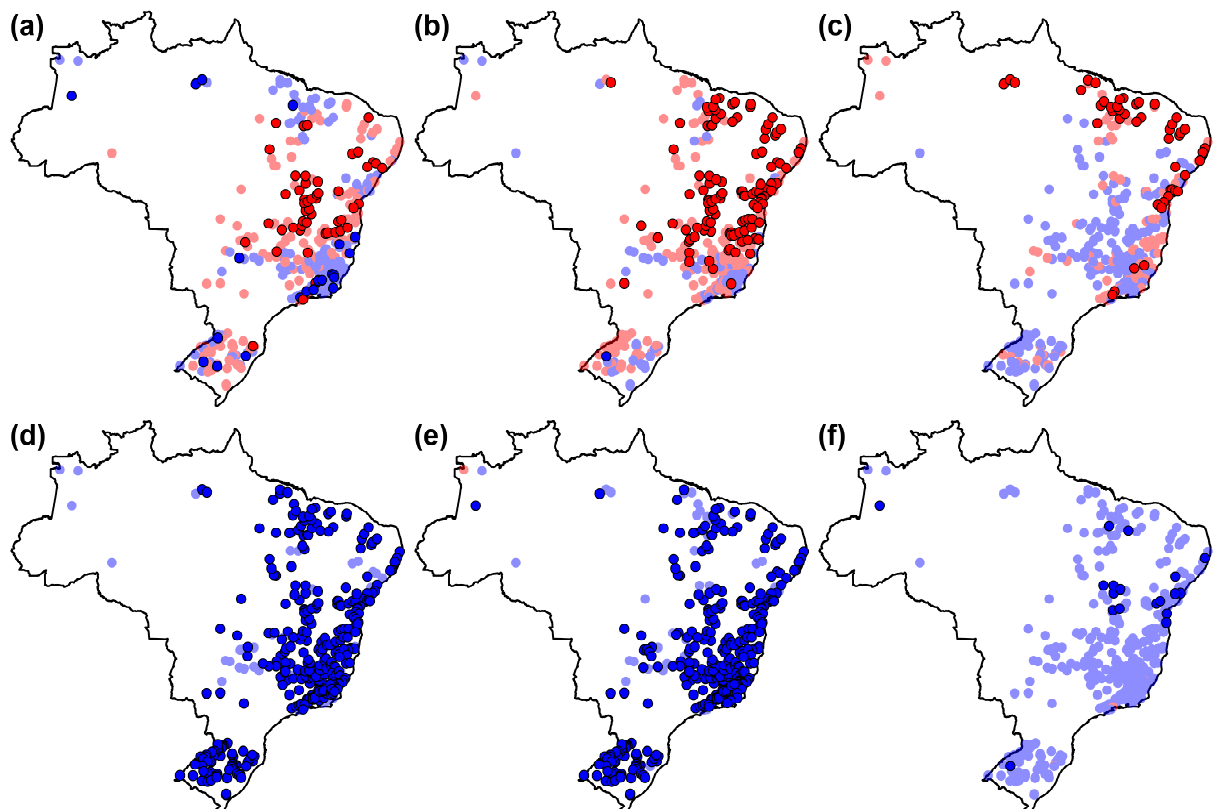


Figura 14. Influência das covariáveis no regime de cheias para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores com transparência indicam uma influência de sinal positivo (azul) e de sinal negativo (vermelho) não significativa. Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo com a análise da distribuição a *posteriori* do coeficiente angular do modelo NS, com nível de confiança de 95%.

4.3. ANÁLISE DE DESEMPENHO DOS MODELOS

A análise de desempenho dos modelos foi feita com dois métodos: (1) uso dos critérios de informação de Akaike e de Bayes e (2) validação dos modelos utilizando um período independente do utilizado na calibração. As Figuras 15 - 18 mostram o suporte relativo à utilização do modelo ST de acordo com o AICc e BIC. Intuitivamente, espera-se um maior suporte à seleção do modelo NS para bacias hidrográficas em que a covariável utilizada foi influente no regime de cheias. Portanto, os resultados foram separados de acordo com a presença ou ausência de significância estatística da covariável no regime de cheias.

Os resultados sugerem que independentemente da covariável utilizada, quando sua influência é significativa no regime de cheias, a seleção do modelo NS é favorecida. Este resultado pode ser facilmente constatado através da presença de valores de ΔAICc e $\Delta\text{BIC} > 2$ para as bacias hidrográficas em destaque nas Figuras 15 e 17 e pela alta frequência de altos valores de ΔAICc e ΔBICc nos histogramas em cinza (Figuras 16 e 18).

Em geral, o AICc mostrou um maior favorecimento para a adição de complexidade, i.e., uma maior preferência para o modelo mais complexo – em aproximadamente 93% das bacias hidrográficas algum dos modelos NS foi selecionado, sendo as covariáveis de chuva média anual e chuva máxima as que apresentaram melhor desempenho em aproximadamente 25% e 59% das bacias hidrográficas, respectivamente. Em algumas situações este critério de informação tende a selecionar o modelo NS mesmo para séries em que a covariável não foi considerada significativa no regime de cheias. Nesta situação, as estimativas de eventos de cheia entre os modelos ST e NS são bastante similares, e então o modelo NS se encontra super parametrizado. Isso mostra uma inabilidade deste critério de informação em penalizar adequadamente a complexidade dos modelos, sendo a escolha do melhor modelo dominada pelo valor da função de verossimilhança, i.e., pela sua habilidade de reproduzir os dados utilizados na calibração, similar ao já reportado por outros estudos (e.g., WESTRA et al., 2014).

O BIC se mostrou mais conservador na adição de complexidade quando comparado ao AICc. Os resultados indicam que este tende a selecionar o modelo NS apenas para as situações em que as covariáveis foram significativas no regime de cheias (maior coerência). Ainda assim, o modelo NS recebeu um grande suporte, sendo selecionado em aproximadamente 89% das bacias hidrográficas. Novamente, as covariáveis de chuva média anual e chuva máxima apresentaram o melhor desempenho para aproximadamente 24% e 58% das bacias hidrográficas, respectivamente.




Figura 15. Suporte relativo à utilização do modelo ST para o critério de informação de Akaike. $\Delta AICc = AICc_s - AICc_{MIN}$. $AICc_s$ representa o valor do critério de informação do modelo ST e $\Delta AICc$ representa o valor mínimo do critério de informação (melhor modelo) para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. Círculos com bordas representam bacias hidrográficas em que a covariável foi estatisticamente significativa no regime de cheias de acordo com a análise da distribuição a *posteriori* do parâmetro α_1 , com nível de confiança de 95%. Resultados interpretados de acordo com Burnham e Anderson (2003), em que valores de $\Delta AICc$ entre 0 e 2 indicam suporte considerável, entre 4 e 7 indicam suporte consideravelmente menor, e valores maiores que 10 indicam a inexistência de suporte ao modelo ST.

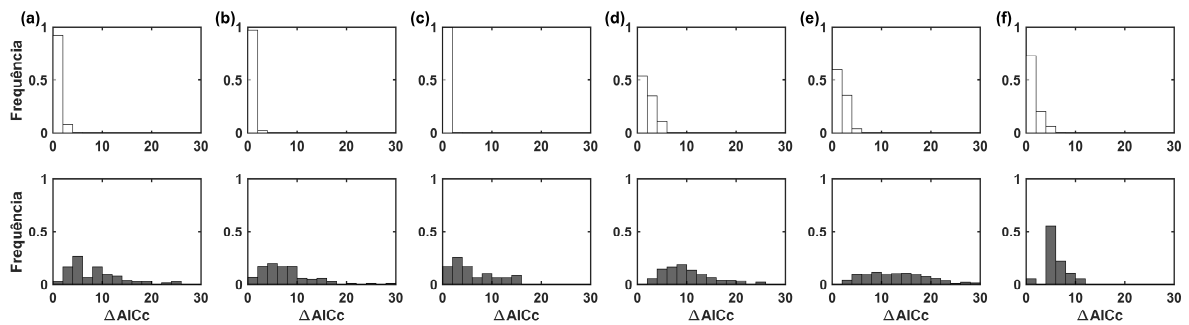


Figura 16. Distribuição dos valores de $\Delta AICc$ para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias para séries em que a não foi considerada estatisticamente significativa no regime de cheias (histogramas brancos) e foi considerada estatisticamente significativa (histogramas em cinza escuro) no regime de cheias de acordo com a análise da distribuição a *posteriori* do parâmetro α_1 .




Figura 17. Suporte relativo à utilização do modelo ST para o critério de informação de Bayes. $\Delta BIC = \Delta BIC - BIC_{\text{MIN}}$. BIC_s representa o valor do critério de informação do modelo ST e BIC_{MIN} representa o valor mínimo do critério de informação (melhor modelo). A descrição dos demais itens é a mesma da Figura 15.

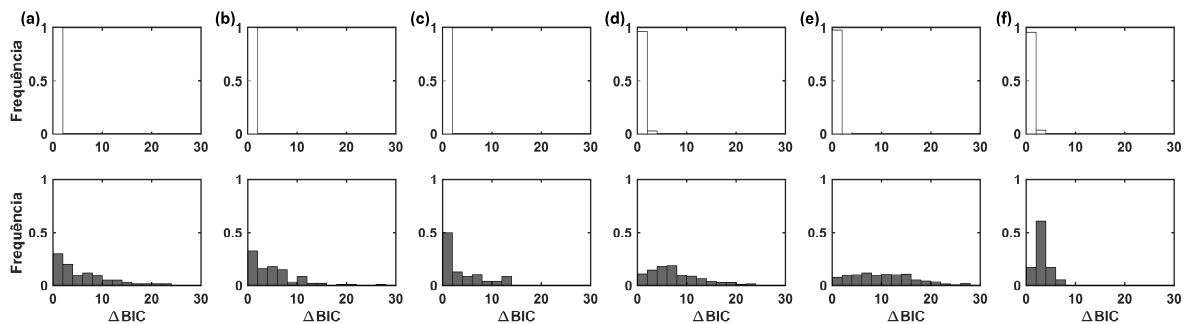


Figura 18. Distribuição dos valores de ΔBIC . A descrição dos demais itens é a mesma da Figura 16.




Figura 19. Comparação entre o modelo ST e NS para cada uma das covariáveis testadas. A figura mostra o percentual de bacias hidrográficas em que cada modelo foi considerado como melhor modelo para (a) AICc e (b) BIC. Foi considerado como melhor modelo aquele em que a covariável foi estatisticamente significativa no regime de cheias e que recebeu suporte pelos critérios de informação.

A seleção de modelos baseada em métricas como AICc e BIC mostram que em geral, modelos NS são uma boa opção para a estimativa de eventos de cheia, especialmente quando a covariável utilizada é significativa no regime de cheias, resultado bastante similar ao encontrado por Luke et al. (2017), que avaliou cheias de mais de 1200 bacias hidrográficas nos estados unidos utilizando o tempo como covariável. Isso ocorre porque para o modelo NS, o parâmetro de posição (e consequentemente de escala) estão mudando ao longo do tempo de acordo com a tendência observada entre a covariável e as cheias. Assim, há uma mudança na posição/escala da distribuição, provocando um aumento na densidade de probabilidade próximo as observações quando comparado ao valor fixo dos parâmetros do modelo ST, resultando em uma maior habilidade do modelo NS em maximizar o valor da função de verossimilhança.

Mesmo que AICc e BIC penalizem a complexidade adicional promovida pela adição do parâmetro do modelo NS, a seleção dos modelos depende da sua capacidade de representar a série de dados utilizada na inferência de seus parâmetros. Entretanto, há uma discussão na comunidade científica de quão relevante é a habilidade do modelo NS em reproduzir registros históricos. Quando diferentes modelos ST são comparados este paradigma é útil, uma vez que se assume que as características da série de dados são invariantes ao longo do tempo. No contexto da não estacionariedade, uma vez que modelos NS podem ser utilizados para extrapolar a tendência inferida no período histórico até o futuro, é importante que estes apresentem também habilidade preditiva satisfatória (BURNHAM; ANDERSON, 2003; RENARD; SUN; LANG, 2013).

Os Resultados para o segundo método de avaliação de desempenho, i.e., utilização de um período independente do utilizado na calibração para avaliar a habilidade preditiva dos modelos ST, uST (parâmetros do modelo NS ao final do período de calibração) e modelo NS (extrapolação da tendência inferida) são mostrados na Figura 20. Esta figura mostra os resultados de acordo com os valores de $B_{j,k}$, em que de $B_{j,k} > 0$ sugere a seleção do modelo \mathcal{M}_j enquanto $B_{j,k} < 0$ sugere a seleção do modelo \mathcal{M}_k . Diferentemente do que foi observado com o uso do AICc e BIC, não foi possível estabelecer um padrão tão claro para qual situação cada modelo foi preferido, sendo os resultados dependentes da covariável utilizada.

Para a covariável tempo (Figura 20a), os resultados mostram que a evidência do teorema de Bayes favorece a seleção do modelo ST para aproximadamente 55% das bacias hidrográficas, com um suporte positivo para o modelo ST em aproximadamente 17% das bacias hidrográficas, i.e., para a maioria das bacias hidrográficas o modelo ST possui uma melhor habilidade preditiva. O modelo uST também apresentou habilidade preditiva ligeiramente superior quando comparado ao modelo ST (Figura 20a, painel central). Ainda, tem-se que a habilidade preditiva utilizando um valor fixo dos parâmetros do modelo NS ao final do período de calibração resultou em uma maior habilidade preditiva daquelas obtidas com extrapolação da tendência inferida (~61% das bacias hidrográficas, Figura 20a, painel direito). Entretanto, tem-se que para a maioria dos casos, o suporte dado aos modelos é em geral fraco (predominância de cores claras nos histogramas). Este resultado sugere que em geral, a inclusão desta informação não melhorou significativamente a habilidade preditiva do modelo NS. Luke et al., (2017), que também avaliaram a habilidade preditiva dos modelos utilizando o tempo como covariável chegou a resultados similares aos aqui encontrados. Na análise conduzida pelos autores, a habilidade do modelo ST superior para um maior número de bacias hidrográficas (70%). Como hipótese para esta diferença, tem-se que os autores avaliaram a habilidade preditiva dos modelos em longo prazo (em média 40 anos no futuro em relação ao final do período de calibração). Neste estudo a validação foi feita com apenas 9 anos no futuro, em que a validação com curtos períodos podem resultar em uma menor perda de performance quando comparada a longos períodos.

Para as covariáveis ENSO e a umidade máxima do solo (Figura 20c e Figura 20f), observou-se que o modelo ST foi fortemente preferido (85% e 73%, respectivamente) quando comparado com o modelo NS (painel esquerdo), sendo este suporte ao menos positivo em 75% e 45% das bacias hidrográficas. O modelo ST também recebeu grande suporte em relação ao modelo uST que utiliza estas covariáveis (painel central na Figura 20c e Figura 20f) e para

ambos os casos o modelo uST apresentou performance superior ao modelo NS (painel direito), em especial para o ENSO. O grande suporte recebido pelo modelo ST não é surpreendente nestes casos, uma vez que a maioria das bacias hidrográficas não foi considerada como não estacionária pela análise do coeficiente angular do modelo NS que utilizam estas duas covariáveis. Nesta situação, tem-se que as estimativas dos modelos uST e NS são similares aos do modelo ST, e como a evidência penaliza adição de complexidade, o modelo ST foi preferido nestas condições.

Similarmente ao ENSO e umidade máxima do solo, para a temperatura média anual (Figura 20b) o modelo ST também foi preferido para a maioria das bacias hidrográficas quando comparado com o modelo NS (85% das bacias hidrográficas). Entretanto, o modelo uST apresentou uma habilidade preditiva superior quando comparado aos modelos ST e NS, sendo preferido em 67% e 88% das bacias hidrográficas, respectivamente, recebendo um suporte pelo menos positivo em aproximadamente 23% e 78% das bacias hidrográficas.

Para a chuva média anual (Figura 20d) e chuva máxima anual (Figura 20e), o modelo NS foi fortemente preferido em relação ao modelo ST (84% e 77% das bacias hidrográficas). Este resultado pode ser facilmente observado a partir da alta frequência de altos valores de $B_{n,s}$ no painel da direita – para aproximadamente 63% e 60% das bacias apresentaram um suporte ao menos positivo para estes modelos. Este resultado sugere que a inclusão destas informações no modelo NS melhora significativamente sua habilidade preditiva, mesmo considerando a complexidade e incerteza adicional promovida pelo uso de um modelo mais robusto. Extrapolações com o modelo NS também foram preferidas em relação ao modelo uST. Isso se deve ao fato de que as correlações entre as covariáveis de chuva e as cheias são bastante importantes, fazendo com que um valor fixo do parâmetro de posição (e conseqüentemente de escala) dificilmente sejam representativos ao longo do período de validação, mesmo que para um curto período.

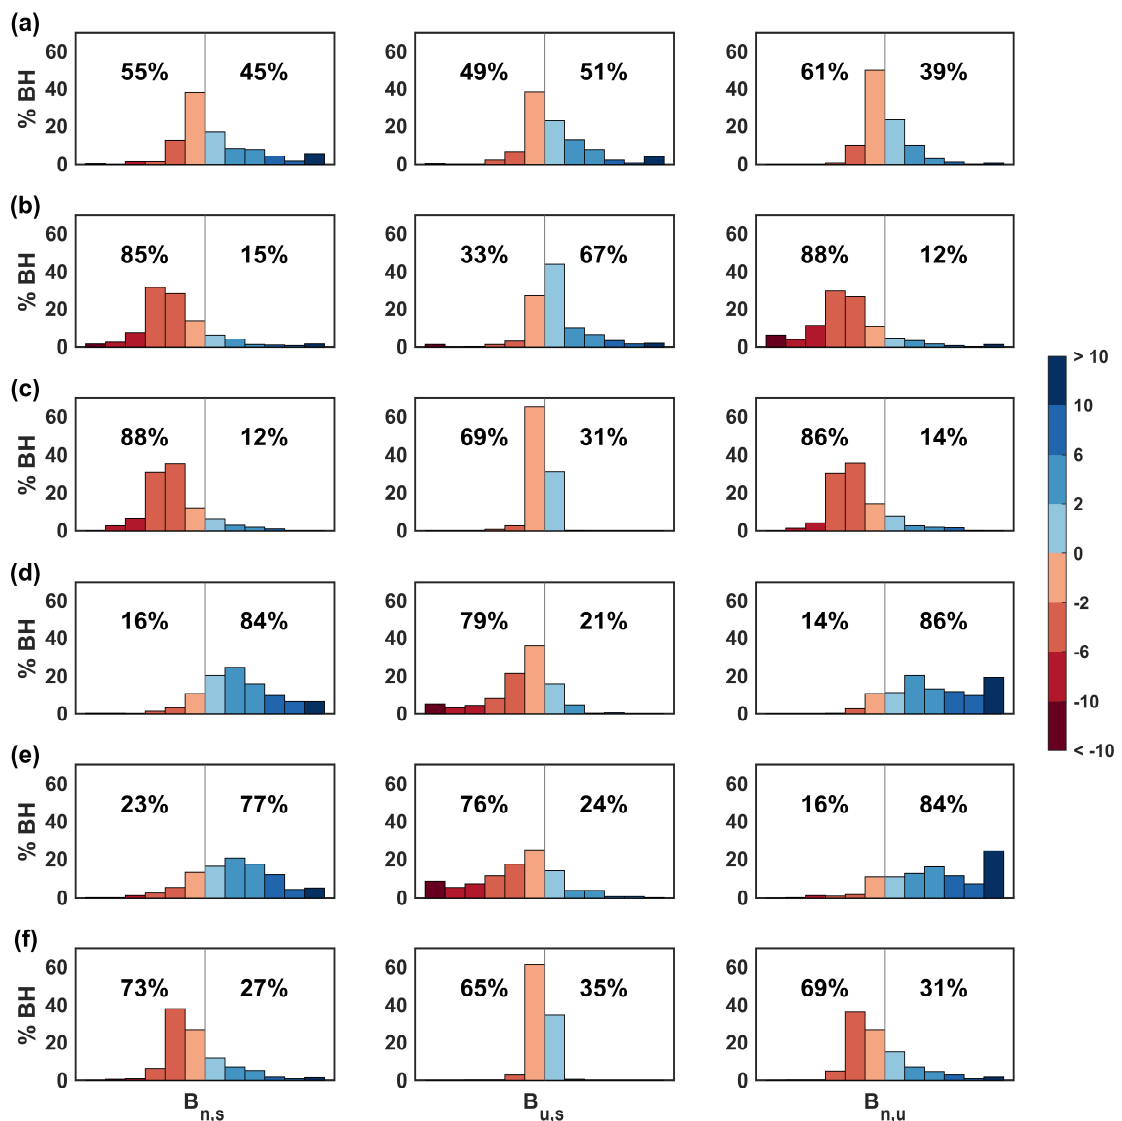


Figura 20. Comparação entre a habilidade preditiva dos modelos ST, uST e NS através do uso do fator de Bayes para todas as bacias hidrográficas avaliadas neste estudo, para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores representam o valor de $B_{j,k}$. Segundo Kass e Raftery (1995), valores de $B_{j,k}$ entre 0 e 2 indicam um suporte fraco, valores entre 2 e 6 um suporte positivo, valores entre 6 e 10 um suporte forte e valores maiores que 10 indicam um suporte muito forte ao modelo \mathcal{M}_j . Os números no interior de cada painel mostram o percentual de bacias hidrográficas em que cada modelo obteve melhor habilidade preditiva.

Intuitivamente, espera-se que os modelos com características não estacionárias (i.e., uST e NS) tenham uma melhor performance no período de validação quando a tendência entre a covariável e as cheias persistirem ao longo do período de validação. Portanto, foram selecionadas apenas bacias hidrográficas em que as covariáveis apresentaram influência no regime de cheias tanto no período de calibração quanto no registro completo – um indicativo de que a influência observada no período de calibração persistiu durante o período de validação (mesmo que não necessariamente com a mesma taxa de mudança). Foram consideradas como influência persistente aquelas bacias hidrográficas em que: (1) a covariável foi significativa no regime de cheias no período de calibração de acordo com a análise da distribuição a *posteriori* do coeficiente angular do modelo NS e, (2) com correlação significativa entre a covariável e as cheias de acordo com o teste de correlação de Spearman para o registro completo, ambas com 95% de confiança. Com exceção da covariável ENSO (Figura 21c), em que o modelo ST recebeu grande suporte em relação aos modelos uST e NS (78% e 87% das bacias hidrográficas), observou-se que em geral, modelos com características não estacionárias foram favorecidos na situação de tendências persistentes entre a covariável e cheias.

Para o tempo (Figura 21a), os modelos NS e uST receberam um maior suporte quando comparados ao modelo ST, sendo o modelo uST fortemente preferido em relação ao modelo ST (71%) e NS (55%). Resultados similares foram reportados por Luke et al. (2017), que também encontrou melhores resultados com o modelo uST para o caso de tendências persistentes utilizando o tempo como covariável.

Para a temperatura média anual (Figura 21b) observou-se que mesmo na situação de tendências persistentes, extrapolações com o modelo NS não foram preferidas, sendo o modelo ST preferido para 71% das bacias hidrográficas. Entretanto, o modelo uST que utiliza esta covariável foi preferido em relação aos modelos ST e NS (75 e 74%).

Para a umidade máxima do solo (Figura 21f), também houve uma melhora no desempenho do modelo NS nestas condições, sendo preferido para 56% das bacias hidrográficas (sendo este suporte ao menos positivo em 44%) quando comparado ao modelo ST. Entretanto, os resultados são pouco conclusivos para esta covariável, já que apenas 18 bacias hidrográficas atenderam aos critérios de tendência persistente.

Para as covariáveis de chuva média anual e chuva máxima anual (Figuras 21d e 21e), o aumento no percentual de bacias hidrográficas em que o modelo NS foi preferido foi pouco evidente, já que a maioria das bacias hidrográficas atenderam aos critérios de influência persistente.

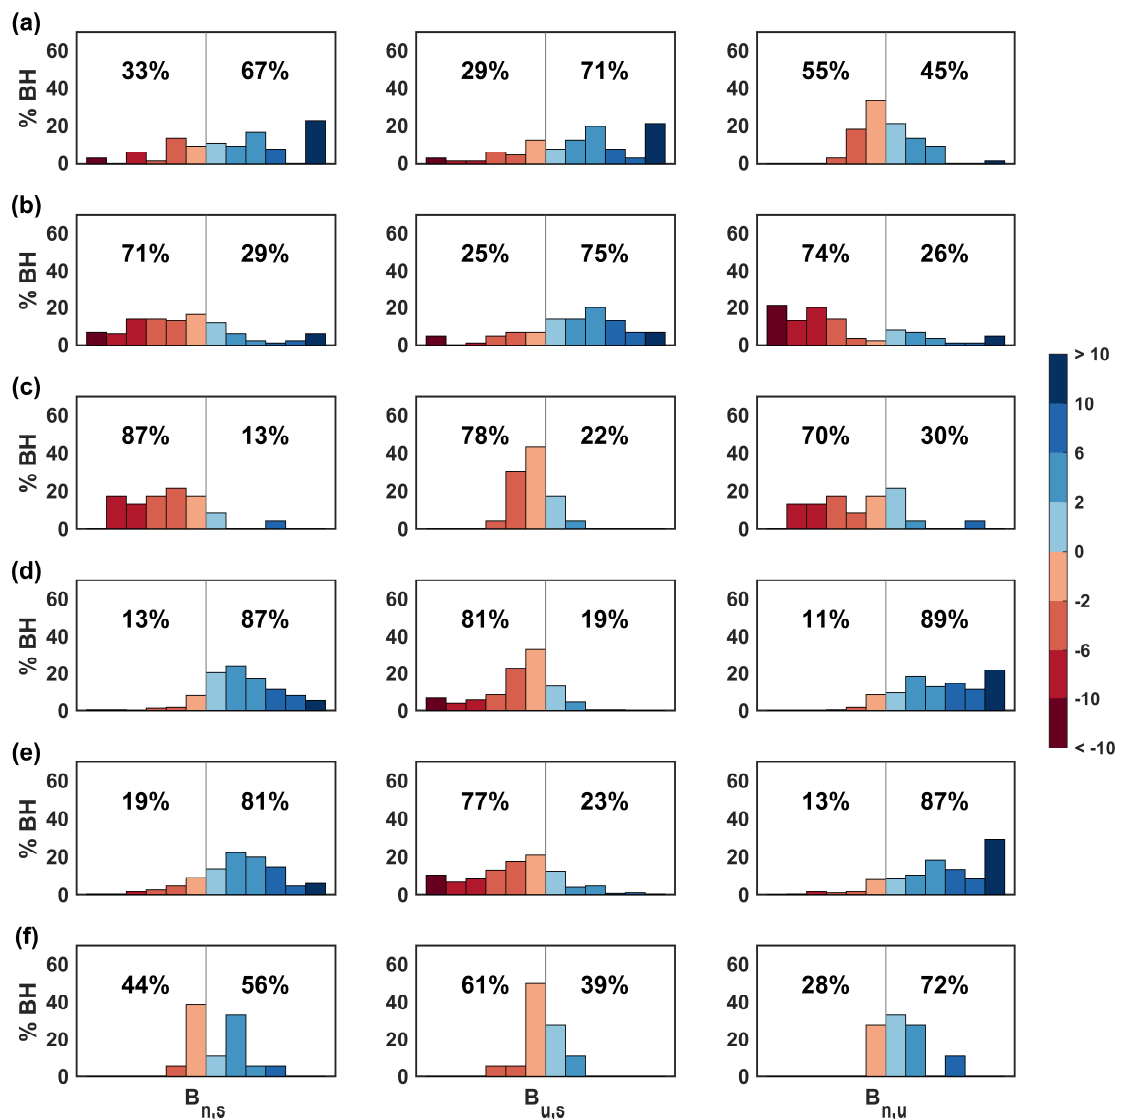


Figura 21. Comparação entre a habilidade preditiva dos modelos ST, uST e NS através do uso do fator de Bayes para bacias hidrográficas em que a influência das covariáveis no regime de cheias foi considerada como persistente durante o período de validação. A descrição dos demais itens é a mesma da Figura 20.

Os resultados aqui encontrados com a validação dos modelos sugerem que quando a informação fornecida pela covariável é relevante para explicar a evolução do regime de cheias ao longo do tempo, o modelo NS apresenta uma habilidade preditiva superior quando comparados ao modelo ST, mesmo considerando a maior incerteza introduzida pela utilização de um modelo mais robusto. Novamente, destaca-se as covariáveis de chuva média anual e chuva máxima anual, que resultaram na formulação de modelo NS com maior habilidade preditiva.

4.4. ANÁLISE DOS QUANTIS DE CHEIA

Avaliar a forma como cada formulação de modelo representa os quantis de cheia, i.e., magnitude de um evento de cheia associado a um certo tempo de retorno é importante para a escolha de qual modelo será utilizado para a concepção de projetos destinados a evitar que eventos extremos se tornem desastres naturais. Os quantis de cheia foram calculados para os modelos ST, uST (parâmetros do modelo NS ao final do período de calibração) e modelo NS (considerando o valor máximo da covariável observado no período de calibração) para o conjunto de parâmetros MAP, i.e., aquele que maximiza a distribuição *a posteriori*.

Os resultados mostram que há uma diferença entre as estimativas feitas a partir das suposições de estacionariedade e de não estacionariedade. Em algumas situações os modelos uST/NS superestimam ou subestimam a magnitude dos eventos de cheia quando comparado ao modelo ST. Este resultado pode ser facilmente constatado através das Figuras 21 e 22, com a presença pontos acima e abaixo da reta 1:1, respectivamente. Estas superestimativas/subestimativas estão atreladas a tendência observada entre as cheias e a covariável considerada (i.e., relação positiva/negativa) e ao valor da covariável de referência utilizada para calcular os quantis de cheia.

Em geral, quando a relação entre as covariáveis não foram consideradas significativas, as estimativas entre os modelos ST e uST/NS são bastante similares (pontos sem borda próximos à reta 1:1). Por outro lado, quando as covariáveis foram consideradas influentes no regime de cheias, as diferenças entre as estimativas são mais evidentes. Este resultado pode ser observado por meio da Figura 23, uma vez que o valor máximo da covariável selecionado como valor de referência para o cálculo dos quantis de cheias evidencia o comportamento observado.

Para as covariáveis tempo, temperatura média anual e ENSO (Figura 23(a-c)), que apresentaram relações significativas de sinal negativo para uma quantidade considerável de bacias hidrográficas, os quantis de cheia estimados pelos modelos NS que utilizam estas covariáveis são em geral menores quando comparados ao modelo ST para aproximadamente 55%, 82% e 50% das bacias hidrográficas avaliadas, respectivamente. Por outro lado, para as covariáveis de chuva média anual e chuva máxima anual (Figura 23(d-e)), que apresentaram relações significativas predominantemente positivas, tem-se que os quantis de cheias dos modelos NS são de maior magnitude quando comparados ao modelo ST para praticamente todas as bacias hidrográficas (~99%).

Para o modelo uST (Figura 22), tem-se que os valores dos quantis de cheia estão atrelados ao valor da covariável ao final do período de calibração. Assim, caso este valor seja maior (menor) aos preponderantemente observados na série de dados, os quantis de cheia observados são de maior (menor) magnitude.

A exceção é a covariável umidade máxima do solo, que independentemente do valor adotado resultou em estimativas muito similares à aquelas feitas com o modelo ST. Isso se deve por dois motivos: (1) a umidade máxima do solo foi considerada como efetiva no regime de cheias para um pequeno número de bacias hidrográficas, e (2) o desvio padrão médio desta covariável é de $0,0099 \text{ m}^3/\text{m}^3$, com intervalo de confiança de 95% de $0,0045 \text{ m}^3/\text{m}^3$ (limite inferior) e $0,0366 \text{ m}^3/\text{m}^3$ (limite superior). A baixa variabilidade dos valores de umidade máxima do solo pode ser explicada pelo fato de que todo ano o solo satura, resultando em um valor máximo de umidade muito parecido todos os anos. Assim, independentemente do valor utilizado para a covariável, as estimativas serão bastante similares entre si.




Figura 22. Dispersão entre as estimativas MAP da magnitude de um evento de cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$, escala logarítmica) para os modelos ST e uST (parâmetros do modelo NS ao final do período de calibração) para as covariáveis (a) tempo, (b) temperatura média anual, (c) ENSO, (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias. As cores dos círculos representam o valor do coeficiente de correlação de Spearman entre a covariável e a série de cheias (período de calibração). Marcadores com borda indicam bacias hidrográficas em que a covariável foi significativa no regime de cheias de acordo com a análise da distribuição a *posteriori* do coeficiente angular do modelo NS, com nível de confiança de 95%. A linha preta é a reta 1:1.

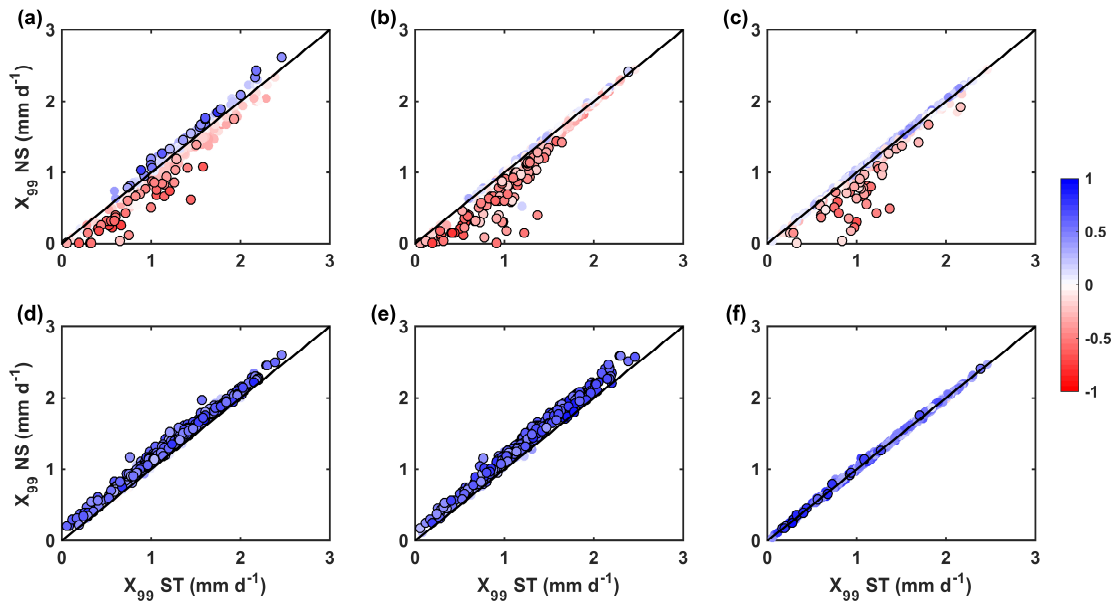


Figura 23. Dispersão entre as estimativas MAP da magnitude de um evento de cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$, escala logarítmica) para os modelos ST e NS (aumento de 5 anos para a covariável tempo e valor máximo da covariável observado no período de calibração). A descrição dos demais itens é a mesma da Figura 22.

A maior parte dos resultados aqui discutidos para os quantis de cheia podem ser visualizados em detalhe na Figura 24, que mostra as curvas de frequência para os modelos ST, uST e NS e densidade de probabilidade para uma cheia com tempo de retorno de 100 anos para todas as covariáveis testadas neste estudo. Primeiro, nota-se que a incerteza para a estimativa dos quantis de cheia é elevada, especialmente devido ao tamanho da série de dados utilizada no período de calibração (i.e., 30 anos). Segundo, o tamanho do intervalo de confiança para os modelos uST e NS pode ser maior ou menor do que os do modelo ST, em que esta diferença é um reflexo da relação entre a complexidade do modelo e das informações fornecidas pelo parâmetro adicional do modelo, e.g., Figuras 24c e 24e, em que os valores dos quantis de cheia estão mais concentrados em uma região em comum e com maior densidade de probabilidade ou Figura 24a em que o intervalo de credibilidade é maior e com os valores dos quantis de cheia mais dispersos, resultando em uma maior incerteza. Terceiro, os intervalos de credibilidade podem ser assimétricos e não são incomuns de serem observados, diferentes daqueles calculados sob premissas de normalidade assintótica (e.g., STEIROU et al., 2019; ZENG et al., 2017 e muitos outros).

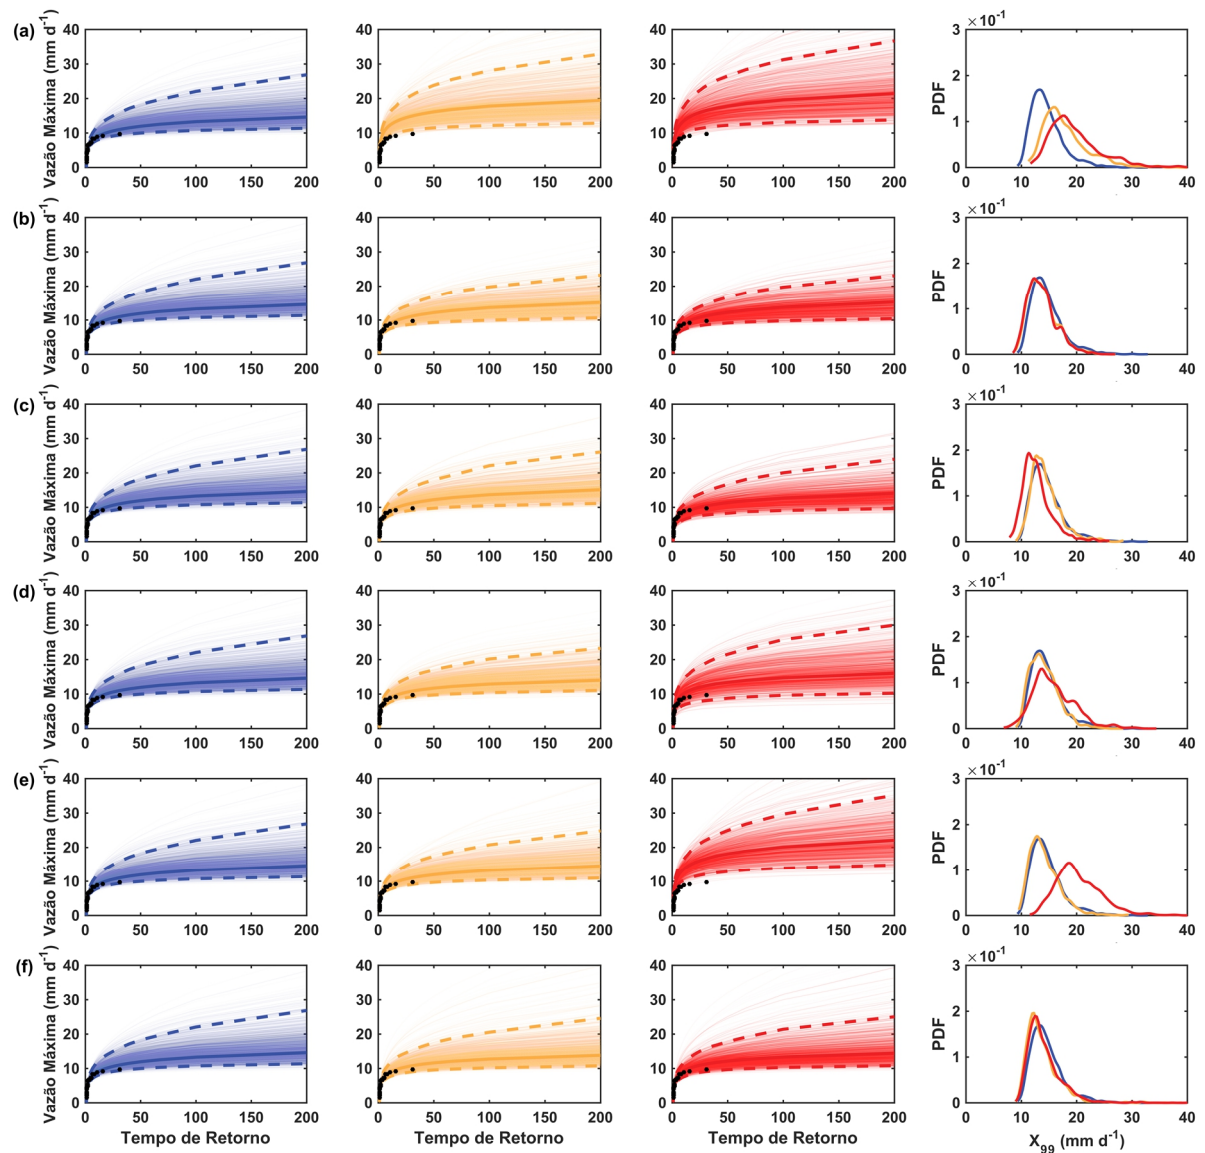


Figura 24. Curvas de frequência, i.e., eventos de cheias associados a diferentes tempos de retorno (em anos), e densidade de probabilidade para uma cheia de tempo de retorno de 100 anos (probabilidade de não excedência $p = 99\%$) para os modelos ST (azul), uST (amarelo, com parâmetros do modelo NS ao final do período de calibração) e NS (vermelho, aumento de 5 anos para a covariável tempo e valor máximo da covariável observado no período de calibração) para covariáveis: (a) tempo, (b) temperatura média anual, (c) ENSO e (d) chuva média anual, (e) chuva máxima anual de uma média móvel de 7 dias e (f) umidade máxima do solo de uma média móvel de 7 dias para estação fluviométrica Itamaraju, localizada na bacia hidrográfica do Atlântico, trecho leste (ANA N° 55340000). Linhas cheias representam as estimativas MAP (conjunto ótimo de parâmetros), as linhas tracejadas representam um intervalo de credibilidade de 95%, e as bolas pretas representam as observações para o tempo de retorno empírico (estacionário).

Os resultados da análise de performance dos modelos aliados com a maneira que cada modelo representa os quantis de cheia podem ajudar técnicos e engenheiros na escolha do melhor modelo. Por exemplo, na situação em que a covariável e as cheias apresentam uma relação de sinal negativo, é preciso considerar que além da incerteza adicional promovida pela adição de um novo parâmetro, os quantis de cheia são em geral, menores que aqueles estimados pelo

modelo ST. Uma vez que obras de engenharia devem ser conservadoras (no sentido de que devem apresentar uma margem de segurança), o uso de modelos NS nessas situações resulta na assunção de maiores riscos e devem ser evitados. Por outro lado, quando observadas relações de sinal de positivo, os quantis de cheia tendem a apresentar maior magnitude quando comparados a premissa de estacionariedade, podendo resultar em obras superestimadas. Portanto, deve ser avaliado os benefícios e danos evitados versus o investimento necessário quando levado em conta um determinado cenário, técnica conhecida como *risk-based decision approach* (SERAGO; VOGEL, 2018)

4.5. IMPACTO DA ADIÇÃO DE COMPLEXIDADE NA INFERÊNCIA DOS PARÂMETROS

A análise do impacto da adição de complexidade do modelo na inferência dos parâmetros foi feita por meio da inspeção visual da distribuição a *posteriori* dos parâmetros dos modelos. Como exemplo desta análise, tem-se a Figura 25, que mostra a distribuição a *posteriori* inferida a partir da estação fluviométrica Esperantina, localizada na bacia hidrográfica do Atlântico, trecho Norte/Nordeste, que foi escolhida por representar um *proxy* do que foi observado nos resultados aqui encontrados. Nesta figura, os histogramas mostram a distribuição a *posteriori* dos parâmetros dos modelos ST (azul), uST (amarelo) e NS (vermelho). A linha preta no primeiro quadro de cada linha representa a distribuição a *priori* do parâmetro de forma e a cruz em cinza em cada quadro representa a estimativa dos parâmetros pelo método de máxima verossimilhança (i.e., conjunto de parâmetros que maximiza a Equação 9, sem o uso de informação regional). O impacto da adição de complexidade do modelo foi notado principalmente para os parâmetros de forma e posição.

Os resultados mostram que a distribuição a *posteriori* do parâmetro de forma encontra-se entre a estimativa do parâmetro por máxima verossimilhança e a moda da distribuição a *priori*. Uma vez que a estimativa do parâmetro de forma por máxima verossimilhança representa a informação local (i.e., foi inferido sem informação regional) e a distribuição a *priori* representa a informação regional, tem-se que a distribuição a *posteriori* representa uma combinação entre estas informações. Ainda, pode-se notar que a distribuição a *posteriori* para os modelos ST e NS são bastante similares, sendo a do modelo ST levemente deslocada para a direita (em direção a menores valores). Entretanto, as estimativas feitas pelo método de máxima verossimilhança divergem dos encontrados com o uso da informação regional. Para ambos os

modelos, tem-se que a estimativa do parâmetro de forma se encontram próximos a cauda direita da distribuição *a priori*, em especial a do modelo NS. De fato, o teste KS confirma que há uma diferença entre as estimativas MAP (com uso da informação regional) e das estimativas do método de verossimilhança, com um nível de confiança de 99% para os modelos ST e NS (todas as covariáveis; resultado não mostrado). Este resultado sugere que em geral o método de máxima verossimilhança comumente empregado para análise de frequência de cheias pode resultar em valores bastante improváveis para o parâmetro de forma – a quantidade limitada de dados (30 anos) utilizada para estimativa dos parâmetros aliada a falta de informação regional impede que o método de máxima verossimilhança obtenha uma estimativa adequada deste parâmetro, que é desafiadora até mesmo sob a hipótese de estacionariedade. Assim, o uso de informação regional para restringir os valores do parâmetro de forma às faixas física e estatisticamente razoáveis, em especial para o modelo NS, são bastante relevantes já que a estimativa dos quantis da distribuição GEV são bastante sensíveis a este parâmetro.

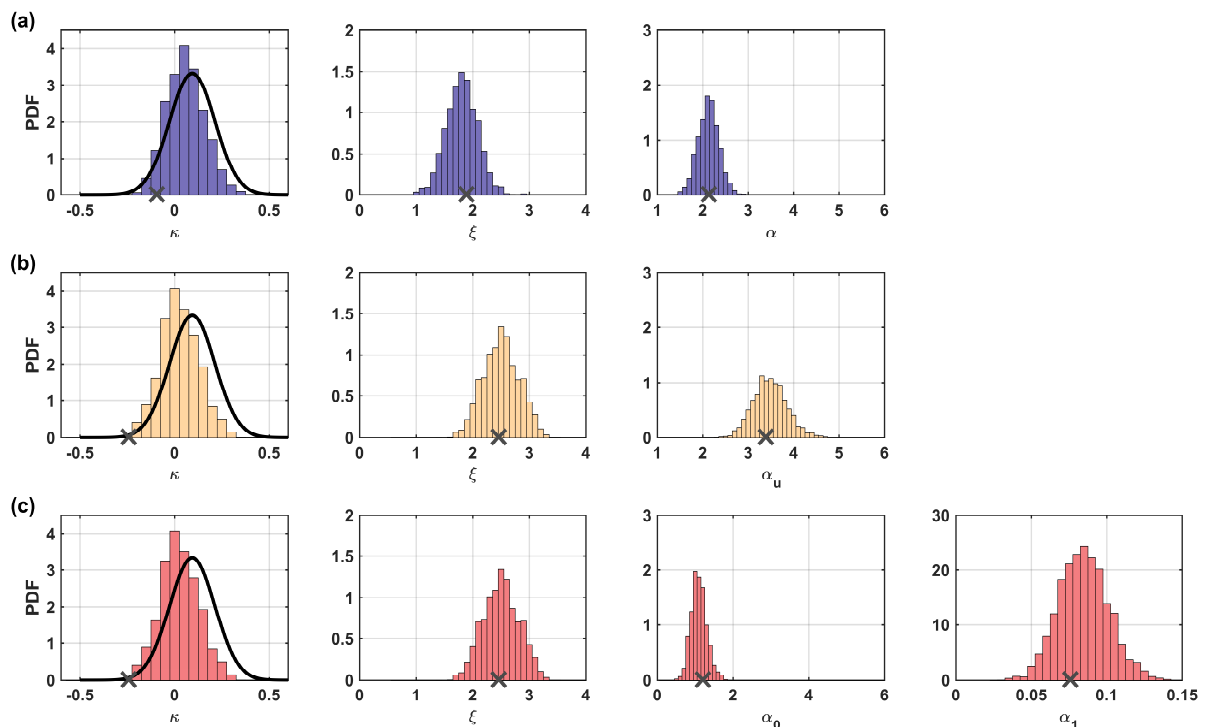


Figura 25. Distribuição *a posteriori* dos parâmetros para os modelos (a) ST (azul), (b) uST (amarelo) e (c) NS (vermelho). A linha preta no primeiro quadro de cada painel representa a distribuição *a priori* do parâmetro de forma e a cruz em cinza em cada quadro representa a estimativa dos parâmetros pelo método de máxima verossimilhança. O modelo NS mostrado é o que utiliza o tempo como covariável.

Luke et al. (2017) reportaram que para a distribuição Log-Pearson 3 o modelo NS tende a favorecer menores valores para o desvio padrão quando comparado ao modelo ST. Esta diferença se deve pela forma pela qual cada modelo representa séries de dados, em especial as com

tendência acentuada. Para o modelo ST, o aumento observado na série de vazões ao longo do tempo (causado pela presença de tendência) é representado por um valor relativamente grande de desvio padrão, sendo este simplesmente a dispersão dos dados em relação à média. No entanto, para o modelo NS, a tendência faz com que a média da distribuição aumente ao longo do período de calibração. Assim, o aumento observado nas vazões máximas é representado por uma alteração na média e não com um grande valor de variância - no modelo NS o desvio padrão não descreve a variância da amostra como um todo, mas sim a variância da mudança da média ao longo do tempo. Entretanto, analogamente, este resultado não foi observado para o parâmetro de escala na análise conduzida neste estudo. Pode-se notar que o valor de ξ é ligeiramente maior sob a hipótese de não estacionariedade (segunda coluna, modelos uST e NS), entretanto, os valores do parâmetro de posição também são maiores nesta condição (terceira coluna, comparando modelos ST e uST). Esta diferença pode estar relacionada a estrutura do modelo NS utilizada neste trabalho, em que o parâmetro de escala varia proporcionalmente o parâmetro de posição, enquanto que o modelo NS utilizado em Luke et al. (2017) considera apenas mudança na média da distribuição e com desvio padrão fixo.

Por fim, tem-se que o parâmetro de posição para o modelo ST apresenta valores de densidade de probabilidade mais elevados e menos dispersos quando comparado aos valores do parâmetro de posição do modelo uST, em que a distribuição *a posteriori* apresenta valores de densidade de probabilidade menores e mais dispersos, i.e., maior incerteza. Ainda, caso os valores do parâmetro de posição sejam extrapolados, maiores são as incertezas acerca deste parâmetro. Este resultado pode ser visualizado na Figura 9, em que o intervalo de credibilidade de 90% do modelo NS aumenta conforme a tendência inferida na calibração é extrapolada.

5. CONCLUSÕES

Este trabalho realizou uma comparação entre a performance de modelos estacionário e não estacionário para testar a hipótese de que a inclusão de informações físicas (principalmente informação climática) melhora a habilidade descritiva e preditiva de modelos não estacionário para análise de frequência de cheias, utilizando dados de 379 bacias hidrográficas do Brasil. Aqui, tentou-se avançar na compreensão de quais são as covariáveis físicas mais influentes e que fornecem os melhores resultados em termos de performance dos modelos.

Os resultados da análise da influência das covariáveis no regime de cheias mostram que há presença de relações significativas de sinal positivo e negativo entre as cheias e as covariáveis físicas no Brasil. As covariáveis climáticas foram as mais influentes no regime de cheias, e.g., temperatura média anual, chuva média anual e chuva máxima anual, sendo as duas últimas as de maior relevância. Destaca-se ainda a umidade máxima do solo, que também apresentou alta correlação com o regime de cheias.

A seleção de modelos baseada em métricas de qualidade de ajuste como os critérios de informação (i.e., AICc e BIC) estimados para o período de calibração favorecem a seleção do modelo não estacionário, especialmente para o caso em que a covariável utilizada é estatisticamente influente no regime de cheias. As covariáveis de chuva média anual e chuva máxima anual foram as que demonstraram maior habilidade em reproduzir os dados do período de calibração, sendo fortemente preferidas tanto em relação ao modelo estacionário bem como a utilização das outras covariáveis testadas. Com a utilização de um período independente do utilizado na calibração dos modelos tem-se que em geral, quando a tendência observada entre a covariável e as cheias persiste durante o período de validação, modelos com características não estacionárias (i.e., uST e NS) apresentam maior habilidade preditiva quando comparados ao modelo estacionário. Para as covariáveis tempo e temperatura média anual, melhores resultados foram alcançados através do modelo estacionário atualizado. Novamente, destaca-se o papel das covariáveis de chuva média anual e chuva máxima anual de uma média móvel de 7 dias na modelagem de eventos de cheia, em que extrapolações com o modelo NS forneceram os melhores resultados na validação dentre todas as covariáveis testadas. Para a covariável de umidade máxima do solo, tem-se que o modelo linear de tendência utilizado neste estudo não foi o suficiente para explicar a variabilidade do regime de cheias, mesmo havendo altas correlações entre as cheias e esta covariável.

Com exceção da covariável de umidade máxima do solo, que apresentou estimativas de quantis de cheia muito próximas das obtidas com o modelo estacionário, o uso de modelos não estacionários pode resultar em estimativas de eventos de cheia bastante diferentes daquelas obtidas com o modelo estacionário, sendo essa diferença controlada pela magnitude e sinal da tendência observada entre as covariáveis e as cheias. Quando a tendência observada é de sinal negativo, os quantis de cheia do modelo NS tendem a subestimar as estimativas feitas com o modelo estacionário e seu uso deve ser evitado devido ao maior risco assumido nessa condição, comportamento observado para as covariáveis tempo, temperatura média anual e ENSO. Já para as covariáveis de chuva média anual e chuva máxima anual, que foram as covariáveis com maior habilidade descritiva e preditiva, tem-se que o modelo estacionário subestima a estimativa de eventos de cheia – resultado preocupante do ponto de vista da concepção de projetos de infraestrutura hidráulica que atualmente são feitos a partir da suposição de estacionariedade.

Os resultados aqui encontrados sugerem que a inclusão de informações físicas, especialmente as climáticas como chuva média anual e chuva máxima anual representam uma abordagem promissora para mitigar uma das principais limitações relatadas na literatura quanto ao uso de modelos não estacionários, i.e., o acréscimo de incerteza promovido pela adição de complexidade (modelos mais robustos).

Para trabalhos futuros, tem-se as seguintes recomendações:

- (1) Distribuição/abordagem. Avaliar o desempenho dos modelos baseados distribuição de extremos que considerem uma abordagem diferente das séries máximas anuais utilizadas neste trabalho (e.g., distribuição Generalizada de Pareto utilizando séries *peak-over-threshold*);
- (2) Escala da análise. Este trabalho avaliou a influência das covariáveis e o desempenho dos modelos de maneira local, i.e., estação por estação. Recomenda-se que trabalhos futuros considerem aspectos regionais na análise de frequência de cheias, e.g., utilização do *False Discovery Rate* (FDR; BENJAMINI; HOCHBERG, 1995)
- (3) Estrutura do modelo. Este trabalho utilizou uma relação linear entre as covariáveis. Isso é uma simplificação dos processos observados na natureza, podendo resultar em subestimativa/superestimativa de possíveis relações não lineares existentes;
- (4) Covariáveis. Este trabalho avaliou o efeito individual de cada uma das covariáveis no regime de cheias. Sendo assim, a metodologia pode ser estendida para que múltiplos efeitos sejam considerados simultaneamente.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ALEXANDRE, A.; JUNIOR, D.; MARTINS, E. Uso de Informação Regional na Estimativa de Quantis de Cheia GEV. *Revista Brasileira de Recursos Hídricos*, v. 13, n. 2, p. 127–139, 2008.

BARNETT, T. P.; HASSELMANN, K.; CHELLIAH, M.; DELWORTH, T.; HEGERL, G.; JONES, P.; RASMUSSEN, E.; ROECKNER, E.; ROPELEWSKI, C.; SANTER, B.; TETT, S. Detection and attribution of recent climate change: A status report. *Bulletin of the American Meteorological Society*, v. 80, n. 12, p. 2631–2659, 1999.

BARTIKO, D.; OLIVEIRA, D. Y.; BONUMÁ, N. B.; CHAFFE, P. L. B. Spatial and seasonal patterns of flood change across Brazil. *Hydrological Sciences Journal*, v. 64, n. 9, p. 1071–1079, 4 jul. 2019.

BARTIKO, D.; CHAFFE, P. L. B.; BONUMÁ, N. B. Nonstationarity in maximum annual daily streamflow series from Southern Brazil. *RBRH*, v. 22, 18 set. 2017.

BENJAMINI, Y.; HOCHBERG, Y. Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society: Series B (Methodological)*, v. 57, n. 1, p. 289–300, jan. 1995.

BLÖSCHL, G.; BIERKENS, M. F. P.; CHAMBEL, A.; CUDENNEC, C.; DESTOUNI, G.; ZHANG, Y.; et al. Twenty-three unsolved problems in hydrology (UPH) – a community perspective. *Hydrological Sciences Journal*, v. 64, n. 10, p. 1141–1158, 27 jul. 2019.

BROWN, S. J.; MURPHY, J. M.; SEXTON, D. M. H.; HARRIS, G. R. Climate projections of future extreme events accounting for modelling uncertainties and historical simulation biases. *Climate Dynamics*, v. 43, n. 9–10, p. 2681–2705, 7 nov. 2014.

BURNHAM, K. P.; ANDERSON, D. R. *Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach*. [s.l.] Springer Sci. and Bus. Media, 2003.

CHAGAS, V. B. P.; L. B. CHAFFE, P.; ADDOR, N.; M. FAN, F.; S. FLEISCHMANN, A.; C. D. PAIVA, R.; SIQUEIRA, V. A. CAMELS-BR: Hydrometeorological time series and landscape attributes for 897 catchments in Brazil. *Earth System Science Data*, v. 12, n. 3, p. 2075–2096, 2020.

CHAGAS, V. P. B. **MUDANÇAS NOS REGIMES DE CHUVA E VAZÃO**. [s.l.]

Universidade Federal de Santa Catarina, 2019.

CHAGAS, V. P. B.; CHAFFE, P. L. B. Mecanismos da sazonalidade de cheias no brasil. *Simpósio Brasileiro de Recursos Hídricos*, p. 1–10, 2021.

CHENG, L.; AGHAKOUCHAK, A. Nonstationary precipitation intensity-duration-frequency curves for infrastructure design in a changing climate. *Scientific Reports*, v. 4, p. 1–6, 2014.

COLES, S. *An introduction to statistical modelling of extreme values*. [s.l: s.n.].

DOOCY, S.; DANIELS, A.; MURRAY, S.; KIRSCH, T. D. The Human Impact of Floods : a Historical Review of Events 1980-2009 and Systematic Literature Review. p. 1–30, 2021.

DU, T.; XIONG, L.; XU, C.-Y.; GIPPEL, C. J.; GUO, S.; LIU, P. Return period and risk analysis of nonstationary low-flow series under climate change. *Journal of Hydrology*, v. 527, p. 234–250, ago. 2015.

FOUFOULA-GEORGIU, E.; TAKBIRI, Z.; CZUBA, J. A.; SCHWENK, J. The change of nature and the nature of change in agricultural landscapes: Hydrologic regime shifts modulate ecological transitions. *Water Resources Research*, v. 51, n. 8, p. 6649–6671, 2015.

GOMES, G. J. C.; VARGAS JÚNIOR, E. DO A. A coupled system based on Differential Evolution for the determination of Rainfall intensity equations. *RBRH*, v. 23, n. 0, 23 nov. 2018.

HAILEGEORGIS, T. T.; ALFREDSEN, K. Analyses of extreme precipitation and runoff events including uncertainties and reliability in design and management of urban water infrastructure. *Journal of Hydrology*, v. 544, p. 290–305, 2017.

HESARKAZZAZI, S.; ARABZADEH, R.; HAJIBABAEI, M.; RAUCH, W.; KJELDSSEN, T. R.; PROSDOCIMI, I.; CASTELLARIN, A.; SITZENFREI, R. Stationary vs non-stationary modelling of flood frequency distribution across northwest England. *Hydrological Sciences Journal*, v. 66, n. 4, p. 729–744, 12 mar. 2021.

JENKINSON, A. F. The frequency distribution of the annual maximum (or minimum) values of meteorological elements. *Quarterly Journal of the Royal Meteorological Society*, v. 81, n. 348, p. 158–171, abr. 1955.

JONKMAN, S. N. Global Perspectives on Loss of Human Life Caused by Floods. v. 34, p. 151–175, 2005.

KARL, T.; MELILLO, J.; PETERSON, T. *Climate change impacts in the United States: Climate trends and regional impacts* Third National Climate Assessment. [s.l: s.n.]. Disponível em: <https://energypolicy.columbia.edu/sites/default/files/pictures/DeutchCarbonTax-CGEP_Commentary_NEW.pdf>.

KASS, R. E.; RAFTERY, A. E. Bayes factors. *Journal of the American Statistical Association*, v. 90, n. 430, p. 773–795, dez. 1995.

LEE, O.; CHOI, J.; WON, J.; KIM, S. Uncertainty analysis of the rate of change of quantile due to global warming using uncertainty analysis of non-stationary frequency model of peak-over-threshold series. *Hydrology and Earth System Sciences*, v. 56, n. 8, p. 1–35, 2 ago. 2020.

LÓPEZ, J.; FRANCÉS, F. Non-stationary flood frequency analysis in continental Spanish rivers, using climate and reservoir indices as external covariates. *Hydrology and Earth System Sciences*, v. 17, n. 8, p. 3189–3203, 2013.

LU, F.; SONG, X.; XIAO, W.; ZHU, K.; XIE, Z. Detecting the impact of climate and reservoirs on extreme floods using nonstationary frequency models. *Stochastic Environmental Research and Risk Assessment*, v. 34, n. 1, p. 169–182, 2020.

LUKE, A.; VRUGT, J. A.; AGHAKOUCHAK, A.; MATTHEW, R.; SANDERS, B. F. Predicting nonstationary flood frequencies: Evidence supports an updated stationarity thesis in the United States. *Water Resources Research*, v. 53, n. 7, p. 5469–5494, 2017.

LUO, Y.; ZHU, L. S. Investigation of trends in extreme significant wave heights in the South China Sea. *Aquatic Ecosystem Health & Management*, v. 22, n. 1, p. 53–64, 1 jan. 2021.

MARTENS, B.; MIRALLES, D. G.; LIEVENS, H.; VAN DER SCHALIE, R.; DE JEU, R. A. M.; FERNÁNDEZ-PRIETO, D.; BECK, H. E.; DORIGO, W. A.; VERHOEST, N. E. C. GLEAM v3: satellite-based land evaporation and root-zone soil moisture. *Geoscientific Model Development*, v. 10, n. 5, p. 1903–1925, 17 maio 2017.

MARTINS, E. S.; STEDINGER, J. R. Generalized maximum-likelihood generalized extreme-value quantile estimators for hydrologic data. *Water Resources Research*, v. 36, n. 3,

p. 737–744, mar. 2000.

MASSEY, F. J. The Kolmogorov-Smirnov Test for Goodness of Fit. *Journal of the American Statistical Association*, v. 46, n. 253, p. 68, mar. 1951.

MATALAS, N. C. Stochastic hydrology in the context of climate change. *Climatic Change*, v. 37, n. 1, p. 89–101, 1997.

MAZDIYASNI, O.; AGHAKOUCHAK, A. Substantial increase in concurrent droughts and heatwaves in the United States. *Proceedings of the National Academy of Sciences*, v. 112, n. 37, p. 11484–11489, 15 set. 2015.

MCPHILLIPS, L. E.; CHANG, H.; CHESTER, M. V.; DEPIETRI, Y.; FRIEDMAN, E.; GRIMM, N. B.; KOMINOSKI, J. S.; MCPHEARSON, T.; MÉNDEZ-LÁZARO, P.; ROSI, E. J.; SHAFIEI SHIVA, J. Defining Extreme Events: A Cross-Disciplinary Review. *Earth's Future*, v. 6, n. 3, p. 441–455, 10 mar. 2018.

MILLY, P. C. D.; BETANCOURT, J.; FALKENMARK, M.; HIRSCH, R. M.; KUNDZEWICZ, Z. W.; LETTENMAIER, D. P.; STOUFFER, R. J. Climate change: Stationarity is dead: Whither water management? *Science*, v. 319, n. 5863, p. 573–574, 2008.

MILLY, P. C. D.; BETANCOURT, J.; FALKENMARK, M.; HIRSCH, R. M.; KUNDZEWICZ, Z. W.; LETTENMAIER, D. P.; STOUFFER, R. J.; DETTINGER, M. D.; KRYSANOVA, V. On Critiques of “stationarity is Dead: Whither Water Management?” *Water Resources Research*, v. 51, n. 9, p. 7785–7789, 2015.

MIRALLES, D. G.; HOLMES, T. R. H.; DE JEU, R. A. M.; GASH, J. H.; MEESTERS, A. G. C. A.; DOLMAN, A. J. Global land-surface evaporation estimated from satellite-based observations. *Hydrology and Earth System Sciences*, v. 15, n. 2, p. 453–469, 3 fev. 2011.

MONTANARI, A.; KOUTSOYIANNIS, D. Modeling and mitigating natural hazards: Stationarity is immortal! *Water Resources Research*, v. 50, n. 12, p. 9748–9756, dez. 2014.

NATALINA, A.; SILVINO, D. O.; SILVEIRA, A.; MUSIS, C. R. DE; WYREPKOWSKI, C. C.; TOMAZINI, F. Períodos De Retorno Para O Rio Paraguai. *Geociências*, v. 26, n. October, p. 369–378, 2007.

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

v. 134, n. October, p. 1–23, dez. 2019.

PACHAURI, R. K.; ALLEN, M. R.; BARROS, V. R.; BROOME, J.; CRAMER, W.; CHRIST, R. *Climate Change 2013 - The Physical Science Basis*. Cambridge: Cambridge University Press, 2014.

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

PETROW, T.; MERZ, B. Trends in flood magnitude, frequency and seasonality in Germany in the period 1951-2002. *Journal of Hydrology*, v. 371, n. 1–4, p. 129–141, 2009.

PROSDOCIMI, I.; KJELDEN, T. Parametrisation of change-permitting extreme value models and its impact on the description of change. *Stochastic Environmental Research and Risk Assessment*, v. 35, n. 2, p. 307–324, 10 fev. 2021.

PROSDOCIMI, I.; KJELDEN, 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*, v. 54, n. 3, p. 1751–1764, 2018.

RAGNO, E.; AGHAKOUCHAK, A.; CHENG, L.; SADEGH, M. A generalized framework for process-informed nonstationary extreme value analysis. *Advances in Water Resources*, v. 130, n. November 2018, p. 270–282, ago. 2019.

RÄSÄNEN, T. A.; SOMETH, P.; LAURI, H.; KOPONEN, J.; SARKKULA, J.; KUMMU, M. Observed river discharge changes due to hydropower operations in the Upper Mekong Basin. *Journal of Hydrology*, v. 545, p. 28–41, fev. 2017.

READ, L. K.; VOGEL, R. M. Reliability, return periods, and risk under nonstationarity. *Water Resources Research*, v. 51, n. 8, p. 6381–6398, ago. 2015.

READ, L. K.; VOGEL, R. M. Hazard function theory for nonstationary natural hazards. *Natural Hazards and Earth System Sciences*, v. 16, n. 4, p. 915–925, 11 abr. 2016.

RENARD, B.; LANG, M.; BOIS, P. Statistical analysis of extreme events in a non-

stationary context via a Bayesian framework: case study with peak-over-threshold data. *Stochastic Environmental Research and Risk Assessment*, v. 21, n. 2, p. 97–112, 16 nov. 2006.

RENARD, B.; SUN, X.; LANG, M. Bayesian Methods for Non-stationary Extreme Value Analysis. In: AGHAKOUCHAK, A. et al. (Eds.). . *Extremes in a Changing Climate*. Water Science and Technology Library. Dordrecht: Springer Netherlands, 2013. v. 65p. 39–95.

SADEGH, M.; VRUGT, J. A.; XU, C.; VOLPI, E. The stationarity paradigm revisited: Hypothesis testing using diagnostics, summary metrics, and DREAM (ABC). *Water Resources Research*, v. 51, n. 11, p. 9207–9231, 28 nov. 2015.

SALES, L. O.; SILVEIRA, D.; JUNIOR, R. ANÁLISE NÃO-ESTACIONÁRIA DAS CHEIAS ANUAIS DA REGIÃO. *Simpósio Brasileiro de Recursos Hídricos*, 2021.

SCHIERMEIER, Q. The Real Holes in Climate Science. *Nature*, v. 463, n. January, p. 284–287, 2010.

SCHOUPS, G.; GIESEN, N. C. VAN DE; SAVENIJE, H. H. G. Model complexity control for hydrologic prediction. v. 44, n. January, p. 1–14, 2008.

SCHWARZ, G. Estimating the Dimension of a Model. *The Annals of Statistics*, v. 6, n. 2, p. 461–464, 1 mar. 1978.

SENEVIRATNE, S.; NICHOLLS, N.; EASTERLING, D.; GOODESS, C.; KANAE, S.; KOSSIN, J.; LUO, Y.; MARENGO, J.; MCINNES, K.; RAHIMI, M.; REICHSTEIN, M.; SORTEBERG, A.; VERA, C.; ZHANG, X. *Changes in climate extremes and their impacts on the natural physical environment: An overview of the IPCC SREX report*. [s.l.: s.n.].

SERAGO, J. M.; VOGEL, R. M. Parsimonious Nonstationary Flood Frequency Analysis. *Advances in Water Resources*, 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.

SILLMANN, J.; THORARINSDOTTIR, T.; KEENLYSIDE, N.; SCHALLER, N.; ALEXANDER, L. V.; HEGERL, G.; SENEVIRATNE, S. I.; VAUTARD, R.; ZHANG, X.; ZWIERS, F. W. Understanding, modeling and predicting weather and climate extremes: Challenges and opportunities. *Weather and Climate Extremes*, v. 18, p. 65–74, dez. 2017.

SILVA, A. T.; PORTELA, M. M.; NAGHETTINI, M.; FERNANDES, W. A Bayesian

peaks-over-threshold analysis of floods in the Itajaí-açu River under stationarity and nonstationarity. *Stochastic Environmental Research and Risk Assessment*, v. 31, n. 1, p. 185–204, 19 jan. 2017.

SILVA, A. T.; NAGHETTINI, M.; PORTELA, M. M. On some aspects of peaks-over-threshold modeling of floods under nonstationarity using climate covariates. *Stochastic Environmental Research and Risk Assessment*, v. 30, n. 1, p. 207–224, 19 jan. 2015.

SILVA, A. T.; PORTELA, M. M.; NAGHETTINI, M. On peaks-over-threshold modeling of floods with zero-inflated Poisson arrivals under stationarity and nonstationarity. *Stochastic Environmental Research and Risk Assessment*, v. 28, n. 6, p. 1587–1599, 19 ago. 2014.

SLATER, L. J.; ANDERSON, B.; BUECHEL, M.; DADSON, S.; HAN, S.; HARRIGAN, S.; KELDER, T.; KOWAL, K.; LEES, T.; MATTHEWS, T.; MURPHY, C.; WILBY, R. L. Nonstationary weather and water extremes: a review of methods for their detection, attribution, and management. *Hydrology and Earth System Sciences*, v. 25, n. 7, p. 3897–3935, 7 jul. 2021.

SPECKHANN, G. A.; BORGES CHAFFE, P. L.; FABRIS GOERL, R.; ABREU, J. J. DE; ALTAMIRANO FLORES, J. A. Flood hazard mapping in Southern Brazil: a combination of flow frequency analysis and the HAND model. *Hydrological Sciences Journal*, v. 63, n. 1, p. 87–100, 2 jan. 2018.

ŠRAJ, M.; VIGLIONE, A.; PARAJKA, J.; BLÖSCHL, G. The influence of non-stationarity in extreme hydrological events on flood frequency estimation. *Journal of Hydrology and Hydromechanics*, v. 64, n. 4, p. 426–437, 2016.

STEIROU, E.; GERLITZ, L.; APEL, H.; SUN, X.; MERZ, B. Climate influences on flood probabilities across Europe. *Hydrology and Earth System Sciences*, v. 23, n. 3, p. 1305–1322, 7 mar. 2019.

STRUPCZEWSKI, W. G.; SINGH, V. P.; FELUCH, W. Non-stationary approach to at-site flood frequency modelling I. Maximum likelihood estimation. *Journal of Hydrology*, v. 248, n. 1–4, p. 123–142, 2001.

SUGIURA, N. Further Analysis of the Data by Anaike' S Information Criterion and the Finite Corrections. *Communications in Statistics - Theory and Methods*, v. 7, n. 1, p. 13–26,

1978.

TRAMBLAY, Y.; NEPPEL, L.; CARREAU, J.; NAJIB, K. Non-stationary frequency analysis of heavy rainfall events in southern France. *Hydrological Sciences Journal*, v. 58, n. 2, p. 280–294, fev. 2013.

TRENBERTH, K. E. Changes in precipitation with climate change. *Climate Research*, v. 47, n. 1–2, p. 123–138, 2011.

VENEZIANO, D.; LANGOUSIS, A.; FURCOLO, P. Multifractality and rainfall extremes : A review. v. 42, n. June, p. 1–18, 2006.

VILLARINI, G.; SMITH, J. A.; SERINALDI, F.; BALES, J.; BATES, P. D.; KRAJEWSKI, W. F. Flood frequency analysis for nonstationary annual peak records in an urban drainage basin. *Advances in Water Resources*, v. 32, n. 8, p. 1255–1266, 2009.

VOGEL, R. M.; LALL, U.; CAI, X.; RAJAGOPALAN, B.; WEISKEL, P. K.; HOOPER, R. P.; MATALAS, N. C. Hydrology: The interdisciplinary science of water. *Water Resources Research*, v. 51, n. 6, p. 4409–4430, 2015.

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.

VOLPI, E.; SCHOUPS, G.; FIRMANI, G.; VRUGT, J. A. Sworn testimony of the model evidence: Gaussian Mixture Importance (GAME) sampling. *Water Resources Research*, v. 53, n. 7, p. 6133–6158, jul. 2017.

VRUGT, J. A. Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation. *Environmental Modelling & Software*, v. 75, n. January 2015, p. 273–316, jan. 2016.

WESTRA, S.; THYER, M.; LEONARD, M.; KAVETSKI, D.; LAMBERT, M. A strategy for diagnosing and interpreting hydrological model nonstationarity. *Water Resources Research*, v. 50, n. 6, p. 5090–5113, jun. 2014.

ZAGHLOUL, M.; PAPALEXIOU, S. M.; ELSHORBAGY, A.; COULIBALY, P. Revisiting flood peak distributions: A pan-Canadian investigation. *Advances in Water Resources*, v. 145, n. August, 2020.

ZENG, H.; SUN, X.; LALL, U.; FENG, P. Nonstationary extreme flood/rainfall frequency analysis informed by large-scale oceanic fields for Xidayang Reservoir in North China. *International Journal of Climatology*, v. 37, n. 10, p. 3810–3820, ago. 2017.

ZHANG, Q.; GU, X.; SINGH, V. P.; XIAO, M.; CHEN, X. Evaluation of flood frequency under non-stationarity resulting from climate indices and reservoir indices in the East River basin, China. *Journal of Hydrology*, v. 527, p. 565–575, ago. 2015.