

INCERTEZA E NÃO ESTACIONARIEDADE NA ANÁLISE DE FREQUÊNCIA DE PRECIPITAÇÕES MÁXIMAS ANUAIS NO SUL DO BRASIL

Gabriel Anzolin¹; Debora Y. de Oliveira² & Pedro L. B. Chaffe³

Palavras-Chave – incerteza, não estacionariedade, análise de frequência.

INTRODUÇÃO

Os extremos hidrológicos têm um papel fundamental no projeto de infraestrutura hidráulica e na avaliação de riscos (Hailegeorgis e Alfredsen, 2017; Veneziano et al., 2006). Tradicionalmente, as técnicas desenvolvidas para análise de frequência de extremos se apoiam na premissa de estacionariedade das séries temporais. Entretanto, devido as mudanças hidroclimáticas observadas nas últimas décadas, esta premissa vem sendo questionada. Assim, a identificação de tendências em séries temporais de precipitação favoreceu o uso e o desenvolvimento de modelos capazes de considerar a não estacionariedade destas séries na estimativa de precipitações para diferentes períodos de retorno. Dada à incerteza em detectar e estimar tendências nos registros históricos disponíveis, bem como à incerteza associada a extrapolação de tendências observadas até o futuro, ainda não existe um consenso na comunidade científica em relação a necessidade de se usar estes modelos (e como devem ser utilizados) (Serago e Vogel, 2018).

Neste trabalho, testou-se a hipótese de que a presença de tendências significativas (i.e., não estacionariedade) em registros históricos de precipitação justifica a utilização de modelos não estacionários para a análise de frequência de extremos. Foram avaliados os desempenhos de modelos estacionário e não estacionário para 489 séries históricas de precipitação do Sul do Brasil (SB), levando em consideração a incerteza associada a estimativa dos parâmetros da distribuição Generalizada de Valor Extremo (GEV).

METODOLOGIA E DADOS

Foram utilizados dados diários de precipitação do Portal HidroWeb (www.snirh.gov.br/hidroweb) da Agência Nacional de Águas (ANA, 2017). Do total de séries disponíveis no SB, foram consideradas apenas aquelas com dados disponíveis no período de 1976-2015 (40 anos) e 1976-2005 ou 1986-2015 (30 anos), e com no máximo 30% de falhas nos anos com os 40% menores valores de precipitação máxima diária anual (*annual maximum series*, AMS), similar a Papalexiou e Koutsoyiannis (2013). Um procedimento de análise exploratória destes dados foi conduzido para excluir séries inconsistentes, resultando em 489 registros históricos de precipitação.

A distribuição Generalizada de Valor Extremo (GEV) foi utilizada para análise de frequência de precipitações máximas anuais (e.g., Cheng e AghaKouchak, 2014; Ragno et al., 2017, 2019). A Função Densidade de Probabilidade (PDF) da distribuição GEV, $f(x)$, é dada por:


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

em que μ é o parâmetro de localização, σ é o parâmetro de escala, e ξ é o parâmetro de forma. Dois modelos foram considerados neste estudo: (i) modelo estacionário (ST), em que os parâmetros da distribuição GEV são assumidos como sendo constantes; e (ii) modelo não estacionário (NS). Em um modelo NS, um ou mais parâmetros da PDF da GEV variam de acordo com uma covariável. Aqui, considerou-se que o parâmetro de localização aumenta ou diminui linearmente com o tempo, i.e., $\mu_t = \mu_0 + \alpha t$. Portanto, o modelo ST possui três parâmetros a serem inferidos, $\theta = \{\mu, \sigma, \xi\}$, enquanto o modelo NS possui quatro parâmetros, $\theta = \{\mu_0, \alpha, \sigma, \xi\}$.

1) Programa de Pós-Graduação em Engenharia Ambiental (UFSC), e-mail: gabriel_anzolin@hotmail.com.

2) Department of Civil and Environmental Engineering (UCI), e-mail: debora.ydo@gmail.com

3) Departamento de Engenharia Sanitária e Ambiental (UFSC), e-mail: pedro.chaffe@ufsc.br.



A estimativa dos valores dos parâmetros e a incerteza relativa a esta estimativa foram feitas a partir da Inferência Bayesiana. Segundo o Teorema de Bayes, a distribuição a *posteriori* dos parâmetros $P(\theta|\tilde{X})$ é proporcional ao produto da distribuição a *priori* $P(\theta)$ e da função de verossimilhança $L(\theta|\tilde{X})$, i.e.,

$$P(\theta|\tilde{X}) \propto P(\theta)L(\theta|\tilde{X}) \quad (2)$$

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). O algoritmo foi executado com 3 Cadeias de Markov e 8.000 iterações em cada cadeia, e 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. Uma distribuição uniforme foi utilizada como distribuição a *priori* e a função de verossimilhança é a PDF da GEV. A avaliação de desempenho foi feita de duas maneiras: calibração utilizando os primeiros 30 registros de cada AMS e (i) comparação através dos critérios de informação de Akaike (AICc; Sugiura, 1978), Bayes (BIC; Schwarz, 1978), e de Desvio (DIC; Spiegelhalter et al., 2002), para todas as séries selecionadas (i.e., 489 séries); (ii) utilização de um período independente do utilizado na calibração para testar a habilidade preditiva dos modelos (i.e., validação), utilizado os últimos 10 registros de cada AMS com 40 anos de observações (i.e., 370 séries). A validação do modelo NS foi conduzida através de um modelo estacionário atualizado (uST) - parâmetros do modelo NS ao final do período de calibração, e com extrapolação da tendência inferida (NS), similar a Luke et al. (2017). A avaliação de desempenho no período de validação foi feita a partir dos valores da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e para considerar a incerteza, valores médios da função de verossimilhança entre todos os 12.000 conjuntos de parâmetros inferidos na calibração ($L_{MÉD}$).

RESULTADOS

Os resultados para o primeiro método de avaliação de desempenho dos modelos (i.e., critérios de informação) sugerem que a presença de uma tendência significativa no período de calibração favorece a escolha do modelo NS – fato comprovado pela alta frequência de maiores valores de ΔAIC , ΔBIC e ΔDIC para estas séries (ver histogramas em vermelho para cada métrica). O BIC mostrou maior suporte ao modelo mais simples (i.e, ST; Figura 1B), enquanto AICc tende a superestimar a adição de complexidade (Westra et al., 2014; Figura 1A), com maior suporte ao modelo NS mesmo para séries sem tendência significativa. Para o DIC (Figura 1C), os resultados são similares ao encontrados para o AICc.

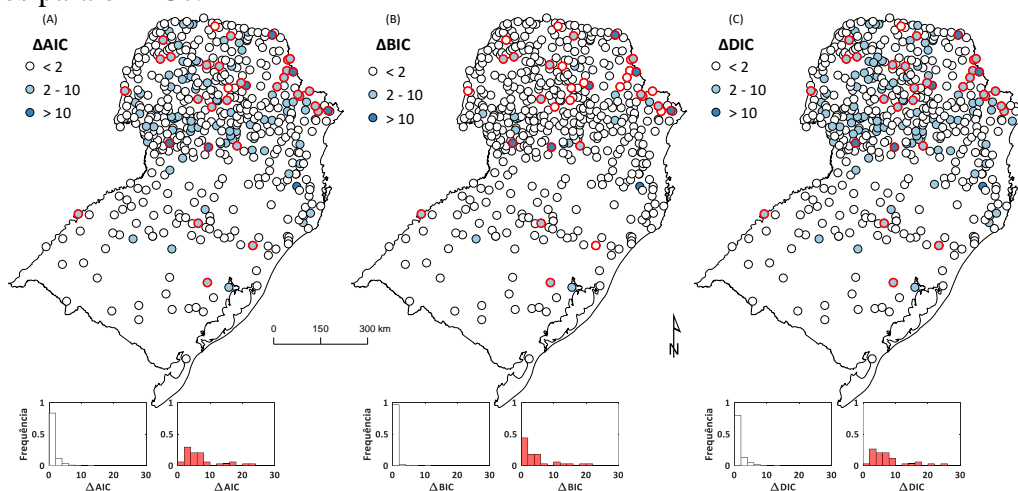
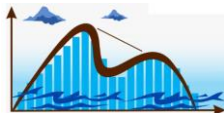


Figura 1 – Área de estudo, SB e localização das estações pluviométricas selecionadas para este estudo e valores de magnitude de suporte à utilização do modelo ST para (A) ΔAIC , (B) ΔBIC e (C) ΔDIC . Valores entre 0 e 2 indicam suporte considerável, 4 e 7 consideravelmente menor, e valores maiores que 10 indicam a inexistência de suporte para o modelo ST. Os círculos e histogramas em vermelho referem-se a séries com tendência estatisticamente significativa de acordo com a versão modificada por Yue et al. (2002) do teste de Mann-Kendall (Mann, 1945; Kendall, 1975), com um nível de confiança de 95%.



Considerando o segundo método de avaliação de desempenho (i.e., validação - Tabela 1), o modelo NS resultou em maiores valores para a função de verossimilhança (i.e., maior habilidade preditiva) para o conjunto ótimo de parâmetros (L_{MAP}). Entretanto, quando a incerteza foi considerada ($L_{MÉD}$), o modelo ST foi preferido mesmo para séries com tendência persistente. Isso sugere que o acréscimo de incerteza promovido pela adição de complexidade é uma das principais limitações do uso do modelo NS, como foi sugerido por Serinaldi e Kilsby (2015) e Luke et al. (2017).

Modelo	L_{MAP}	$L_{MÉD}$
ST	73 ₍₅₎	224 ₍₁₀₎
uST	52 ₍₃₎	44 ₍₂₎
NS	245 ₍₉₎	102 ₍₅₎

Tabela 1 – Número de séries com melhor desempenho no período de validação para cada um dos modelos, i.e., ST, uST e NS, para valores da função de verossimilhança derivados do conjunto ótimo de parâmetros (L_{MAP}) e para valores médios da função de verossimilhança ($L_{MÉD}$). Os valores da tabela são para todas as séries com 40 anos de observação (370 séries) e em subscrito são séries com tendência persistente, i.e., no período de calibração e registro completo (17 séries).


CONCLUSÕES

Como principais conclusões deste trabalho, tem-se que (i) resultados derivados de métricas de desempenho como os critérios de informação e a avaliação da performance dos modelos derivadas do conjunto ótimo de parâmetros levam a crer que o modelo NS deve ser selecionado para a estimativa de precipitações para diferentes períodos de retorno; (ii) quando a incerteza relativa à inferência dos parâmetros é levada em consideração, o suporte ao modelo NS diminuiu substancialmente, com performance superior do modelo ST mesmo para séries com tendências persistentes. Estes resultados revelam que a presença de tendência significativa em uma AMS não justifica a seleção de um modelo NS, e reforça a necessidade de se considerar a incerteza na comparação entre modelos ST e NS.

Para trabalhos futuros, recomenda-se a utilização de relações determinísticas que expliquem a evolução das tendências ao longo do tempo (e.g., Montanari e Koutsoyiannis, 2014; Merz et al., 2014), além da utilização de informação regional para calibração dos modelos, em especial para o parâmetro de forma da distribuição de extremos.

REFERÊNCIAS

- AKAIKE, H. A new look at the statistical model identification. **IEEE Transactions on Automation Control**, v.19 n.6, p. 716–723, 1974.
- ANA - AGÊNCIA NACIONAL DE ÁGUAS. **HidroWeb: Sistema de Informações Hidrológicas**. 2015 Disponível em:<<http://www.snirh.gov.br/hidroweb/apresentacao>>. Acesso em 12 jan. 2017.
- CHENG, L.; AGHAKOUCHAK, A. Nonstationary precipitation intensity-duration-frequency curves for infrastructure design in a changing climate. **Scientific Reports**, v. 4, p. 7093, 2014.
- HAILEGEORGIS, T.T., ALFREDSSEN, K. Analyses of extreme precipitation and runoff events including uncertainties and reliability in design and management of urban water infrastructure. **J Hydrol (Amst)** **544**, v. 544, p.290–305, 2017.
- KENDALL, M. G. Rank Correlation Methods. 4 ed. **London: Charles Griffin**, 1975;
- LUKE, A.; VRUGT, J. A.; AGHAKOUCHAK, A; MATTHEW, R.; SANDERS, B. F. Predictiong nonstationarity flood frequencies: Evidence supports and updated stationarity thesis in the United States. **Water Resources Research**, p. 1–26, 2017.



- MANN, H. B. Nonparametric tests against trend. **Econometrica: Journal of the Econometric Society**, p. 245-259, 1945;
- MERZ, B.; et al. (2014). Floods and climate: Emerging perspectives for flood risk assessment and management. **Natural Hazards and Earth System Sciences**, v. 14, n. 7, p. 1921–1942;
- MONTANARI, A.; KOUTSOYIANNIS, D. Modeling and mitigating natural hazards: Stationary is immortal. **Water Resources Research**, p. 9748–9756, 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;
- RAGNO, E.; AGHAKOUCHAK, A.; LOVE, C. A.; CHENG, L.; VAHEDIFARD, F & LIMA, C. H. R. Quantifying changes in future Intensity-Duration-Frequency curves using multimodel ensemble simulations. **Water Resources Research**, 54, p. 1751–1764, 2018;
- RAGNO, E; AghaKouchak, A; CHENG, L; SADEGH, M. A generalized framework for process informed nonstationary extreme value analysis. **Advances in Water Resources**, v 130, p. 270-282, 2019;
- SCHWARZ, G. Estimating the dimension of a model. **Annals of Statistics**, v.6, n.2, p. 461–464, 1978;
- SERAGO, J. M.; VOGEL, R. M. Parsimonious nonstationary flood frequency analysis. **Advances in Water Resources**, v. 112, p. 1–16, 2018;
- SERINALDI, F.; KILSBY, C. G. Stationarity is undead: Uncertainty dominates the distribution of extremes. **Advances in Water Resources**, v. 77, p. 17–36, 2015;
- SPIEGELHALTER, D. J; N. G; BEST, B; P. CARLIN, and A. VAN DER LINDE. Bayesian measures of model complexity and fit, **J. R. Stat. Soc., Ser. B**, 64, p. 583–639, 2002;
- SUGIURA, N. Further analysis of the data by Akaike’s information criterion and the finite corrections. **Communications in Statistics, Theory and Methods** A7, p. 13–26, 1978;
- VENEZIANO, D.; A. LANGOUSIS; P. FURCOLO. ‘Multifractality and rainfall extremes: A review. **Water Resources Research**, v.42, p. 1-18, 2006;
- VRUGT, J. A. Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation. **Environmental Modelling and Software**, v. 75, p. 273–316, 2016;
- WESTRA, S.; THYER, M.; LEONARD, M.; KAVETSKI, D.; LAMBERT, M. A strategy for diagnosing and interpreting hydrological model nonstationarity. **Water Resources Research**, v. 50, p. 5090–5113, 2014;
- YUE, S.; PILON, P.; PHINNEY, B.; CAVADIAS, G. The influence of autocorrelation on the ability to detect trend in hydrological series. **Hydrological Processes**, v. 16, n. 9, p. 1807–1829, 2002;

AGRADECIMENTOS

Gabriel Anzolin e Debora Y. de Oliveira agradecem o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Códigos de Financiamento: 88887.477406/2020-00 e 88881.174456/2018-01, respectivamente.