

INCERTEZA NA ANÁLISE DE FREQUÊNCIA DE VAZÕES MÁXIMAS ANUAIS UTILIZANDO MODELOS ESTACIONÁRIO E NÃO ESTACIONÁRIO APLICADOS À REGIÃO SUL DO BRASIL

Debora Yumi de Oliveira¹; Daniel Bartiko² & Pedro Luiz Borges Chaffe³

ABSTRACT – The detection of trends in annual maxima series has prompted the development and use of nonstationary models for flood frequency analysis. However, whether we should use (and how to use) nonstationary models for prediction is still under discussion. In this work, we compared the use of stationary and nonstationary models for flood frequency analysis using the lognormal distribution. This analysis was conducted using discharge records of fluvimetric gauges located in Southern Brazil. The parameters of the lognormal distribution were inferred using Bayesian inference. We found that model selection based on information criteria or maximum a posteriori parameter estimates may lead to the selection of a nonstationary model for prediction, especially when a trend is detected in the fitting period. However, taking into account the uncertainty associated with the estimated parameters, the nonstationary model was never preferred. This result indicates that the higher uncertainty associated with nonstationary models is still a limitation for its extrapolation and use for predicting return periods of extreme fluvimetric events.

Palavras-Chave – Incerteza, análise de frequência, não estacionariedade

1 - INTRODUÇÃO

A identificação de tendências em séries temporais fluviométricas levaram ao desenvolvimento de modelos não estacionários para a análise de frequência de eventos fluviométricos extremos. Porém, devido à incerteza associada à detecção e estimativa de tendência nas séries históricas disponíveis, assim como à incerteza intrínseca ao se realizar qualquer previsão de cenários futuros, ainda não existe um consenso quanto à utilização de modelos estacionários ou modelos não estacionários para a estimativa das vazões associadas a diferentes tempos de retorno (Serago e Vogel, 2018).

Neste trabalho, foi realizada uma comparação de desempenho entre modelos estacionário e não estacionário aplicados à análise de frequência de cheias de séries temporais relativas à região Sul do Brasil, considerando a incerteza na estimativa dos parâmetros dos dois modelos. A

1) Programa de Pós-graduação em Engenharia Ambiental (PPGEA), Universidade Federal de Santa Catarina (UFSC), debora.ydo@gmail.com

2) Programa de Pós-graduação em Engenharia Ambiental (PPGEA), Universidade Federal de Santa Catarina (UFSC), danielbartiko@hotmail.com

3) Departamento de Engenharia Sanitária e Ambiental (ENS), Universidade Federal de Santa Catarina (UFSC), pedro.chaffe@ufsc.br

incerteza associada aos valores dos parâmetros foi quantificada a partir da utilização da inferência Bayesiana. A não estacionariedade de séries fluviométricas da região Sul do Brasil também foi investigada em Bartiko et al. (2017), com a consideração de tendência monotônica e mudança abrupta nas séries de vazões máximas anuais.

2 - MATERIAIS E MÉTODOS

2.1 - Seleção das séries

As séries históricas das estações fluviométricas localizadas na região Sul do Brasil foram obtidas a partir do Portal HidroWeb (www.snirh.gov.br/hidroweb). Do total de séries disponíveis, apenas as séries com no mínimo 30 anos de dados foram consideradas. Além disso, visando a obtenção de um período de tempo em comum para todas as séries e assim possibilitar a comparação entre os resultados das diferentes estações fluviométricas, as análises realizadas neste trabalho foram restringidas àquelas que possuíam, necessariamente, dados referentes ao ano de 2005, conforme metodologia adotada por Villarini et al. (2013) e Mallakpour e Villarini (2016). A partir das séries históricas selecionadas, foram geradas séries de vazões máximas anuais (*annual maxima series*, AMS). As séries com percentual de falhas maior que 30% para os anos com os 40% menores valores de vazão máxima anual foram descartadas, conforme Papalexou e Koutsoyiannis (2013). Este procedimento de seleção das séries fluviométricas resultou num total de 131 séries temporais. O tamanho médio das séries consideradas é de 43 anos.

2.2 - Análise de tendência

As séries AMS foram testadas quanto à presença de mudança abrupta utilizando o teste de Pettitt (Pettitt, 1979). Caso verificada a presença de mudança abrupta em uma série AMS, esta foi separada em duas partes – antes e depois da mudança abrupta – e apenas o período mais recente foi utilizado para análise de tendência monotônica, conforme Mallakpour e Villarini (2015) e Villarini et al. (2012). Na verificação da existência de mudança abrupta nas séries AMS, foi assumido a existência de apenas um ponto de mudança abrupta, conforme Villarini et al. (2011a) e Villarini et al. (2011b).

O teste de Mann-Kendall (Kendall, 1975) foi utilizado para verificação da existência de tendência monotônica nas séries AMS. Como a existência de autocorrelação na série analisada pode afetar o resultado do teste de Mann-Kendall, o método TFPW-MK de Yue *et al.* (2002) foi empregado. Este método é composto das seguintes etapas: (1) assumindo que a tendência na série de dados é linear, o coeficiente angular é estimado a partir do método de Theil e Sen e utilizado para remoção da tendência da série de dados; (2) o coeficiente do modelo autorregressivo de primeira ordem AR(1) é estimado e, caso seja significativamente diferente de zero, é utilizado para remoção da autocorrelação da série de dados; (3) a tendência é reinserida na

série de dados – agora livre de autocorrelação mas mantendo a tendência original – e então o teste de Mann-Kendall é aplicado para verificação de existência de tendência monotônica.

2.3 - Análise de frequência de vazões máximas anuais

A distribuição lognormal foi utilizada na análise de frequência de vazões extremas. Uma série de vazões máximas anuais $\mathbf{Q} = \{Q_1, Q_2, \dots, Q_n\}$ segue uma distribuição lognormal (LN) caso a variável aleatória $\mathbf{X} = \log_{10}(\mathbf{Q})$ seja distribuída de acordo com uma distribuição normal, ou seja,

$$\log_{10}(Q) \sim N(\mu_t, \sigma) \quad (1)$$

A função densidade de probabilidade, $f(x)$, da distribuição normal é dada por

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2)$$

Dois modelos foram considerados: modelo estacionário (ST), em que os parâmetros da distribuição são assumidos como sendo constantes; e modelo não estacionário (NS), no qual é considerado que a média da distribuição aumenta ou diminui linearmente ao longo do tempo, i.e., $\mu_t = \mu_0 + \beta t$. O modelo estacionário possui dois parâmetros a serem inferidos, $\theta = \{\mu, \sigma\}$, e o modelo não estacionário possui três parâmetros, $\theta = \{\mu_0, \beta, \sigma\}$.

Geralmente, na análise de frequência de extremos, os parâmetros da distribuição são inferidos diretamente a partir do cálculo da média e do desvio padrão da série de dados disponível. Neste trabalho, a inferência Bayesiana foi utilizada para obtenção dos parâmetros dos modelos ST e NS, permitindo a estimativa de uma distribuição probabilística de valores dos parâmetros ao invés de um único valor. Segundo o teorema de Bayes, a distribuição a posteriori dos parâmetros, $p(\theta | \mathbf{X})$, pode ser obtida a partir da distribuição a priori dos parâmetros, $p(\theta)$, da função de verossimilhança, $L(\theta | \mathbf{X})$, e da evidência, $p(\mathbf{X})$, i.e.,

$$p(\theta | \mathbf{X}) = \frac{p(\theta)L(\theta | \mathbf{X})}{p(\mathbf{X})} \quad (3)$$

A distribuição a priori resume a informação que tem-se a respeito dos valores dos parâmetros antes da análise dos dados disponíveis, a função de verossimilhança sumariza a informação fornecida pelos dados utilizados na inferência, enquanto que a evidência atua como uma constante para que a distribuição a posteriori integre para um.

Para aproximação da distribuição a posteriori dos parâmetros foi utilizado o algoritmo DREAM_(zs), que é um amostrador do tipo Markov chain Monte Carlo (MCMC). O funcionamento deste algoritmo é descrito em Vrugt et al. (2016). Foram utilizadas 3 cadeias de Markov com $T = 8.000$ amostragens em cada uma. Os 50% iniciais de cada cadeia foram descartados, e então a distribuição a posteriori para cada um dos parâmetros foi aproximada com um total de 12.000 valores. Uma distribuição uniforme foi utilizada como distribuição a priori para os parâmetros dos modelos ST e NS, e a função de verossimilhança é a própria distribuição lognormal.

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

- Método 1: inferência dos parâmetros dos modelos ST e NS a partir da série AMS inteira, e comparação realizada a partir dos critérios de informação. Os critérios de informação são utilizados para se estimar a redução de desempenho de um modelo ao ser utilizado em um período diferente do utilizado para inferência dos parâmetros, sem a necessidade de se reservar uma parte da série de dados disponível exclusivamente para esta finalidade. Os critérios de informação possuem um termo relacionado ao desempenho do modelo e um termo que penaliza pela complexidade do modelo. Os critérios de informação de Akaike (AIC_c) e de Bayes (BIC) foram utilizados,

$$AIC_c = -2\ln(L^*) + \frac{2d(d+1)}{(n-d-1)} \quad (4)$$

e

$$BIC = -2\ln(L^*) + d \ln(n) \quad (5)$$

em que L^* é o valor máximo da função de verossimilhança (para o conjunto ótimo de parâmetros), d é o número de parâmetros do modelo e n é o número de dados utilizados na inferência. A utilização de critérios de informação para comparação entre modelos permite que a série disponível seja utilizada em sua totalidade na inferência dos parâmetros.

- Método 2: separação de cada uma das séries de dados em duas partes, um período utilizado para inferência dos parâmetros e outro período para avaliação de desempenho dos modelos. Neste método, apenas séries com mais de 60 anos foram consideradas, com o objetivo de se ter no mínimo 30 anos de dados para a inferência dos parâmetros da distribuição de extremo e 30 anos de dados para validação do modelo. A utilização deste método possibilita a obtenção de resultados mais robustos quando comparado ao primeiro método; porém, reduziu significativamente o número de séries analisadas (de 131 para 20 séries). Quando este método foi aplicado, a validação do modelo NS foi conduzida de duas maneiras: (1) utilização do modelo não estacionário, com a extrapolação da tendência inferida (NS); e (2) utilização de um modelo estacionário atualizado, sendo utilizados os valores dos parâmetros do modelo não estacionário do final do período de calibração (uST). A avaliação de desempenho do período de validação foi realizada a partir do cálculo do valor da função de verossimilhança associado ao conjunto ótimo de parâmetros (L_{MAP}) e, para consideração da incerteza associada à estimativa dos parâmetros, do valor médio da função de verossimilhança calculada para cada um dos 12.000 conjuntos de parâmetros da distribuição a posteriori ($L_{méd}$).

3 - RESULTADOS E DISCUSSÃO

Os resultados dos critérios de informação, utilizados para a avaliação de desempenho dos modelos ST e NS com parâmetros inferidos a partir da série completa (método 1), são apresentados na Figura 1. O critério de informação de Bayes (BIC) foi mais conservador em termos de adição de complexidade do que o critério de informação de Akaike (AIC_c), resultando em um maior favorecimento à utilização de um modelo estacionário (mais simples). As oito séries que apresentaram tendência monotônica significativa (destacadas em vermelho na Figura 1), avaliada pelo teste de Mann-Kendall com um nível de significância de 0,05, resultaram em maiores valores de ΔAIC e ΔBIC (Figura 2). Este resultado indica que a presença de uma tendência no período utilizado para inferência dos parâmetros da distribuição de extremo favorece a escolha do modelo NS.

Considerando o critério de informação de Akaike, o modelo NS recebeu mais suporte em relação ao modelo ST mesmo em séries que não apresentaram tendência significativa, devido a seu maior potencial em maximizar a função de verossimilhança (maior número de parâmetros). Este resultado sugere uma inabilidade deste critério de informação em penalizar a complexidade do modelo de maneira adequada, sendo a seleção entre os modelos ST e NS dominada pelo valor máximo da função de verossimilhança, ou seja, relacionada à habilidade do modelo em reproduzir os dados da série histórica.

Os resultados obtidos com a utilização do segundo método de avaliação de desempenho dos modelos ST e NS, i.e., com a separação da série de dados de um período de validação independente do período utilizado para a obtenção dos valores dos parâmetros da distribuição de extremo (método 2), são apresentados na Tabela 1. O modelo não estacionário resultou em maiores valores da função de verossimilhança considerando o conjunto ótimo de parâmetros (L_{MAP}) para algumas séries de dados, mesmo para aquelas que não apresentaram tendência significativa (Tabela 1). Porém, quando a incerteza na estimativa dos parâmetros foi considerada, ou seja, analisando os valores da média do valor da função de verossimilhança calculado para cada um dos conjuntos de parâmetros da distribuição a posteriori ($L_{méd}$), em nenhuma série o modelo NS foi superior aos modelos ST e uST, sendo que para a maioria das séries (16 de 20) o modelo ST foi preferido (Tabela 1). Este resultado vai ao encontro ao constatado em alguns estudos (e.g., Serinaldi e Kilsby, 2015), de que a incerteza promovida pelo aumento de complexidade é uma das principais limitações da utilização de modelos não estacionários. Esta constatação demonstra a importância de se considerar a incerteza na comparação entre modelos ST e NS, conforme sugerido por Luke et al. (2017).

Considerando a única série que apresentou tendência para a série completa e também para a série de calibração (primeira metade da série), os melhores resultados na validação foram

obtidos para o modelo estacionário atualizado (Figura 3). A Figura 4 ilustra a influência da utilização dos modelos ST e uST na estimativa das vazões para diferentes tempos de retorno.

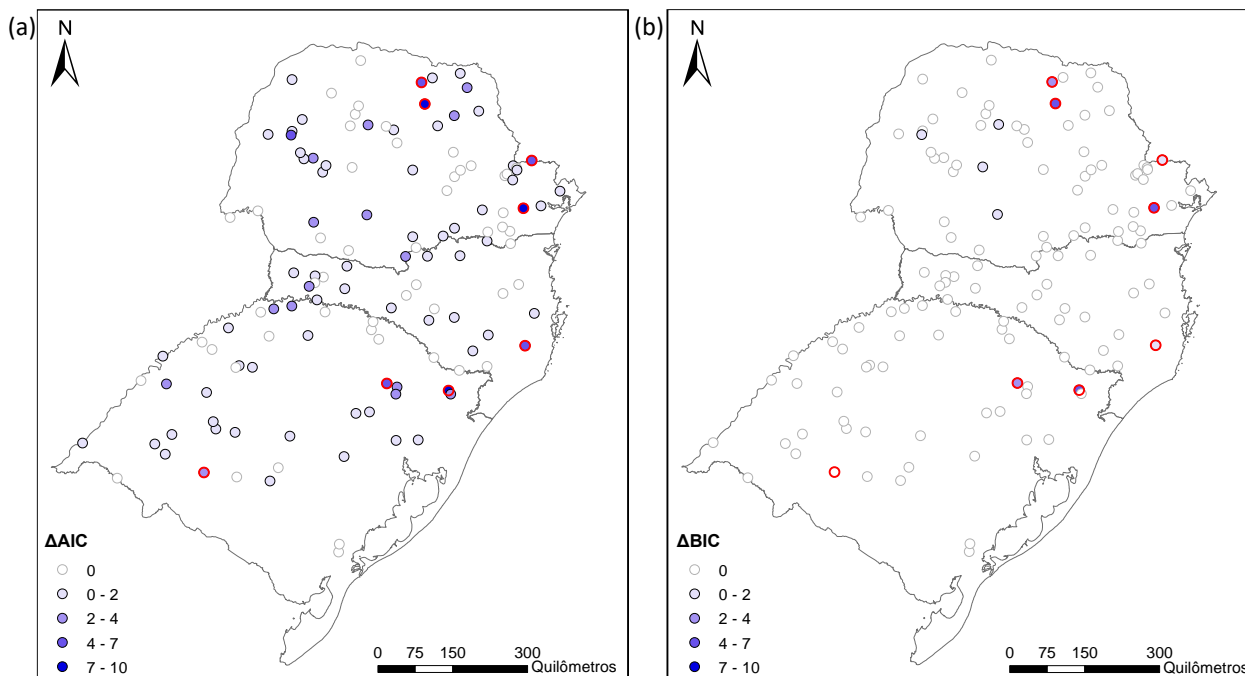


Figura 1 – Localização das estações fluviométricas selecionadas neste estudo e apresentação dos valores de (a) ΔAIC e (b) ΔBIC . As estações fluviométricas em vermelho são as que apresentaram tendência significativa. Os valores apresentados estão relacionados à magnitude de suporte à utilização do modelo estacionário. Valores de 0 a 2 indicam suporte considerável à utilização do modelo estacionário. Valores de 7 a 10 indicam a inexistência de suporte para o modelo ST.




Figura 2 – Comparação entre os valores de ΔAIC ($= AIC_s - AIC_{\min}$) e de ΔBIC ($= BIC_s - BIC_{\min}$) para séries (a) sem tendência significativa e (b) com tendência significativa. AIC_s (BIC_s) é o valor de AIC (BIC) do modelo estacionário, e AIC_{\min} (BIC_{\min}) é o menor valor de AIC (BIC).

Tabela 1 – Número de séries com melhor desempenho na validação para cada um dos modelos (estacionário – ST, estacionário atualizado – uST e não estacionário – NS) considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança ($L_{méd}$).

Modelo	L_{MAP}	$L_{méd}$
ST	8	16
uST	7	4
NS	5	0




Figura 3 – Exemplo de comparação entre os modelos estacionário (ST), estacionário atualizado (uST) e não estacionário (NS) para a estação fluviométrica 84520000, que apresentou tendência significativa (quando avaliada para a série inteira).




Figura 4 – Exemplo dos valores de vazão para diferentes tempos de retorno utilizando os modelos (a) estacionário (ST) e (b) estacionário atualizado (uST) para a estação fluviométrica 84520000. (c) Densidade de probabilidade para a vazão de tempo de retorno de 100 anos.

4 - CONCLUSÃO

Neste trabalho foi realizada uma comparação entre a utilização de modelos estacionário e não estacionário para análise de frequência de vazões extremas na região Sul do Brasil. A incerteza associada aos valores dos parâmetros da distribuição de extremo foi quantificada a partir da inferência Bayesiana.

A utilização de métodos de seleção de modelos como os critérios de informação de Akaike (AIC) e de Bayes (BIC), assim como a consideração do desempenho associado ao conjunto ótimo de parâmetros, podem sugerir a seleção de um modelo não estacionário para a previsão de eventos extremos. Porém, considerando a incerteza associada à estimativa dos parâmetros da distribuição, o modelo estacionário apresentou melhor desempenho, mesmo para séries em que foi verificada a existência de tendência significativa no período de calibração. Este resultado indica que a presença de tendência na série não é uma condição suficiente para justificar a utilização de um modelo não estacionário na análise de frequência de vazões extremas, e mostra a importância da quantificação explícita da incerteza associada aos parâmetros da distribuição.

Para trabalhos futuros sugere-se a análise da utilização de diferentes distribuições de extremo além da lognormal considerada neste estudo. Além disso, poderia ser verificado o desempenho da extrapolação do modelo não estacionário em um curto prazo (10 ou 15 anos).

Melhores resultados da utilização de modelos não estacionários poderiam ser obtidos com o desenvolvimento de modelos em que as mudanças na distribuição de extremo estejam condicionadas a outras variáveis ao invés do tempo, buscando-se entender o que causou as tendências verificadas nas séries históricas, como sugerido por outros estudos (e.g., Merz et al., 2014).

REFERÊNCIAS BIBLIOGRÁFICAS

- BARTIKO, D.; CHAFFE, P. L. B.; BONUMÁ, N. B. (2017). *Nonstationarity in maximum annual daily streamflow series from Southern Brazil*. Revista Brasileira de Recursos Hídricos, v. 22, e48.
- KENDALL, M.G. (1975). *Rank Correlation Methods*, 4th edition, Charles Griffin, London.
- LUKE, A.; VRUGT, J. A.; AGHAKOUCHAK, A.; MATTHEW, R.; SANDERS, B. F. (2017). *Predicting nonstationary flood frequencies: Evidence supports an updated stationarity thesis in the United States*. Water Resources Research, v. 53.
- MALLAKPOUR, I.; VILLARINI, G. (2015). *The changing nature of flooding across the central United States*. Nature Climate Change, v. 5, n. 3, p. 250–254.
- MALLAKPOUR, I.; VILLARINI, G. (2016). *Investigating the relationship between the frequency of flooding over the central United States and large-scale climate*. Advances in Water Resources, v. 92, p. 159–171.
- 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.
- PAPALEXIOU, S. M.; KOUTSOYIANNIS, D. (2013). *Battle of extreme value distributions: A global survey on extreme daily rainfall*. Water Resources Research, v. 49, n. 1, p. 187–201.
- PETTITT, A. N. (1979). *A Non-Parametric Approach to the Change-Point Problem*. Journal of the Royal Statistical Society, v. 28, n. 2, p. 126–135.
- SEN, P. K. (1968). *Estimates of regression coefficient based on Kendall's Tau*. Journal of the American Statistical Association, v. 63, p. 1379-1389.
- SERAGO, J. M.; VOGEL, R. M. (2018). *Parsimonious nonstationary flood frequency analysis*. Advances in Water Resources, v. 112, p. 1–16.
- SERINALDI, F.; KILSBY, C. G. (2015). *Stationarity is undead: Uncertainty dominates the distribution of extremes*. Advances in Water Resources, v. 77, p. 17–36.
- VILLARINI, G.; SMITH, J. A.; BAECK, M. L.; KRAJEWSKI, W. F. (2011a). *Examining Flood Frequency Distributions in the Midwest U.S.* Journal of the American Water Resources Association, v. 47, n. 3, p. 447–463.
- VILLARINI, G.; SMITH, J. A.; SERINALDI, F.; NTELEKOS, A. A. (2011b). *Analyses of seasonal and annual maximum daily discharge records for central Europe*. Journal of Hydrology, v. 399, n. 3–4, p. 299–312.
- VILLARINI, G.; SMITH, J. A.; SERINALDI, F.; NTELEKOS, A.; SCHWARZ, U. (2012). *Analyses of extreme flooding in Austria over the period 1951 – 2006*. v. 1192, p. 1178–1192.
- VILLARINI, G.; SMITH, J. A.; VITOLO, R.; STEPHENSON, D. B. (2013). *On the temporal clustering of US floods and its relationship to climate teleconnection patterns*. International Journal of Climatology, v. 33, n. 3, p. 629–640.
- VRUGT, J. A. (2016). *Markov chain Monte Carlo simulation using the DREAM software package: Theory, concepts, and MATLAB implementation*. Environmental Modelling and Software, v. 75, p. 273–316.
- YUE, S.; PILON, P.; PHINNEY, B.; CAVADIAS, G. (2002). *The influence of autocorrelation on the ability to detect trend in hydrological series*. Hydrological Processes, v. 16, n. 9, p. 1807–1829.