

XXIII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

CONSIDERAÇÃO DE INCERTEZA E NÃO ESTACIONARIEDADE NA ANÁLISE DE FREQUÊNCIA DE CHEIAS NO BRASIL

Daniel Bartiko¹; Debora Y. Oliveira²; Nadia B. Bonumá³ & Pedro L. B. Chaffe³

RESUMO – A análise de frequência de cheias é essencial para o projeto, operação, gerenciamento e análise de risco de estruturas hidráulicas. No entanto, as incertezas inerentes a esse tipo de análise e a possível não estacionariedade de séries temporais de vazões máximas ainda são temas pouco explorados no Brasil. Neste trabalho foi avaliada a presença de tendências em séries temporais de vazões máximas anuais do Brasil e a aplicação de modelos estacionário e não estacionário do tipo GEV para a análise de frequência de cheias, além das incertezas associadas ao uso dos mesmos. Há presença de tendências significativas para cheias no Brasil bem como um claro padrão espacial para sua ocorrência. Onde existe presença de tendências, há o favorecimento do uso de modelos não estacionários para a análise de frequência de cheias. Por outro lado, há preferência do modelo estacionário quando séries temporais não apresentam tendências significativas. Na validação, o modelo não estacionário obteve melhor desempenho em grande parte das séries temporais que apresentaram tendência significativa, mesmo quando levada em consideração a incerteza adicional associada ao uso deste tipo de modelo.

ABSTRACT – Flood frequency analysis is essential for hydraulic structures design, operation, management and risk analysis. However, the uncertainties inherent to this type of analysis and the possible nonstationarity in the time series are still little explored in Brazil. This work evaluated the presence of trends in maximum annual flows time series from Brazil, the application of GEV stationary/nonstationary models for flood frequency analysis and the uncertainties associated to the use of these two models. There are significant floods trends in Brazil, with a clear spatial pattern for their occurrence. When trends are (not identified) identified in the time series, the (stationary) nonstationary GEV model received more support for use in flood frequency analysis. In the validation period, the nonstationary model obtained better performance for most of the time series that presented a significant trend, even when considering the additional uncertainty associated with its use.

Palavras-Chave – Eventos extremos, tendências, tempo de retorno.

INTRODUÇÃO

A análise de frequência de cheias é um passo básico para o projeto, operação, análise de risco e gerenciamento de estruturas hidráulicas (PROSDOCIMI *et al.*, 2014). Métodos tradicionais desenvolvidos para a análise de frequência de cheias são geralmente baseados na hipótese da estacionariedade, o que implica que a variável sob análise tem função densidade de probabilidade invariável (PETROW; MERZ, 2009; READ; VOGEL, 2015; READ; VOGEL, 2016; SRAJ *et al.*, 2016; VOGEL *et al.*, 2011). No entanto, essa hipótese pode tornar-se inválida devido a inúmeros

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

2) Department of Civil and Environmental Engineering, University of California Irvine, Irvine, California, USA

3) Departamento de Engenharia Sanitária e Ambiental, Universidade Federal de Santa Catarina (UFSC)

fatores que influenciam a produção do escoamento, como mudanças hidroclimáticas (MILLY *et al.*, 2008), urbanização (VOGEL; *et al.*, 2011), práticas agrícolas (FOUFOULA-GEORGIU *et al.*, 2015) e reservatórios (RASANEN *et al.*, 2017; ZAJAC *et al.*, 2017).

A incerteza associada à detecção e estimativa de tendência nas séries históricas de vazão, assim como àquela intrínseca ao se realizar qualquer previsão de cenários futuros, fazem com que ainda não exista um consenso quanto à utilização de modelos estacionários ou não estacionários para a estimativa das vazões associadas a diferentes tempos de retorno (SERAGO; VOGEL, 2018). Montanari e Koutsoyiannis (2014) aconselham cautela no uso de modelos não estacionários, pontuando que são necessárias relações determinísticas que expliquem a evolução de um certo processo ao longo do tempo para que o uso deste tipo de abordagem seja adequado. No entanto, mesmo nas situações em que há conhecimento do processo hidrológico associado a não estacionariedade, sempre há incerteza adicional associada a análise de frequência a partir de modelos não estacionários. Segundo Luke *et al.* (2017) esta é uma das maiores desvantagens destes modelos, de forma que sugerem que qualquer comparação entre modelos estacionário e não estacionário deve levar em conta a incerteza adicional introduzida por esse tipo de abordagem.

Apesar da análise de frequência de cheias sobre condições não estacionárias ser um tópico amplamente discutido na Europa (PROSDOCIMI *et al.*, 2014; SRAJ *et al.*, 2016), América do Norte (GADO; NGUYEN, 2016; VOGEL *et al.*, 2011) e Ásia (DU *et al.*, 2015; ZHANG *et al.*, 2015), ainda é um assunto timidamente explorado no Brasil, principalmente sobre a perspectiva da análise da incerteza associada a esses modelos. A alguns poucos exemplos de trabalhos que abordaram a não estacionariedade no Brasil, Bartiko *et al.* (2017); Detzel *et al.* (2011) e Silva *et al.* (2016).

O objetivo deste trabalho foi avaliar a aplicação e incerteza de modelos estacionário e não estacionário na análise de frequência de cheias no Brasil. Foram analisadas as seguintes questões: i. Há tendências significativas em séries históricas de vazões máximas anuais no Brasil? ii. Qual tipo da tendência (positiva/negativa) se manifesta e qual é o padrão espacial para sua ocorrência? iii. Qual é o tipo de modelo (estacionário ou não estacionário) mais adequado para a análise de frequência de cheias no Brasil, em especial quando há presença de tendência significativa?

MATERIAIS E MÉTODOS

Área de Estudo e Dados Hidrológicos

Foram obtidas séries temporais de vazões diárias de 3254 postos fluviométricos de todo o Brasil a partir do Portal HidroWeb (www.snirh.gov.br/hidroweb). Todavia, o presente estudo limitou-se àquelas séries temporais que possuíam 40 anos de dados, correspondentes ao período entre 1976 e 2015, a partir das quais foram geradas séries de vazões máximas anuais. Adicionalmente, conforme metodologia de Papalexiou e Koutsoyiannis (2013), foram descartadas séries com percentual de

falhas maior que 30% para os anos com os 40% menores valores de vazão máxima anual, o que resultou em 275 séries temporais (Figura 1). Algumas importantes regiões, como as Bacias do Rio Paraná e do Tocantins Araguaia, não tiveram séries que atendessem aos critérios preestabelecidos.

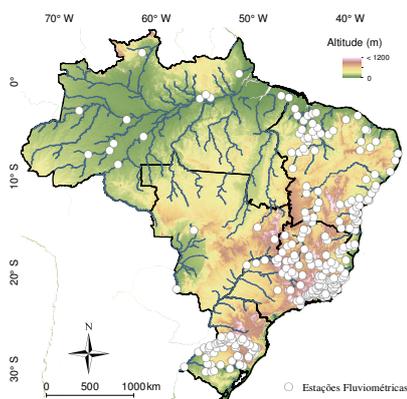


Figura 1 – Área de estudo e localização das 275 séries temporais que atenderam aos critérios de seleção.

Análise de Tendência

O teste de Mann-Kendall (Kendall, 1975) foi utilizado para verificação da existência de tendência monotônica nas séries temporais ao nível de significância de 5% ($p < 0,05$). 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 Sem (THEIL, 1950; SEN, 1968) 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.

Análise de Frequência de Cheias

A distribuição Generalizada de Valores Extremos (GEV) foi adotada para a análise de frequência de vazões, a qual incorpora três formas assintóticas de valores máximos em uma única expressão (NAGHETTINI; PINTO, 2007). A função de probabilidades acumuladas da GEV é dada por:

$$F(y) = \exp \left\{ - \left[1 - \kappa \left(\frac{y - \beta}{\alpha} \right) \right]^{\frac{1}{\kappa}} \right\} \quad (1)$$

onde κ , α e β são os parâmetros de forma, escala e posição, respectivamente, e $\mathbf{y} = \{y_1, y_2, \dots, y_n\}$ é a série de vazões máximas anuais. A função densidade de probabilidade da GEV é dada por:

$$f(y) = \frac{1}{\alpha} \left[1 - \kappa \left(\frac{y - \beta}{\alpha} \right) \right]^{1/\kappa - 1} \exp \left\{ - \left[1 - \kappa \left(\frac{y - \beta}{\alpha} \right) \right]^{1/\kappa} \right\} \quad (2)$$

Dois modelos foram considerados para a análise de frequência de cheias: a forma estacionária, na qual os parâmetros da distribuição são assumidos como sendo constantes; e a não estacionária, na qual é considerado que o parâmetro de posição da distribuição aumenta ou diminui linearmente ao longo do tempo, i.e., $\beta_t = \beta_0 + \beta_1 t$. O modelo estacionário possui três parâmetros a serem inferidos, $\theta = \{\kappa, \alpha \text{ e } \beta\}$, e o modelo não estacionário possui quatro parâmetros, $\theta = \{\kappa, \alpha, \beta_0 \text{ e } \beta_1\}$.

Foi utilizada inferência Bayesiana para obtenção dos parâmetros dos modelos, 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.,

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

$p(\theta|\mathbf{X})$ resume a informação que tem-se a respeito dos valores dos parâmetros antes da análise dos dados disponíveis, $L(\theta|\mathbf{X})$ sumariza a informação fornecida pelos dados utilizados na inferência, enquanto que $p(\mathbf{X})$ 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 $T = 10.000$ iterações para o modelo estacionário e $T = 20.000$ iterações para o modelo não estacionário. Os 50% valores iniciais de cada cadeia foram descartados, e então a distribuição a posteriori para cada um dos parâmetros foi aproximada com um total de 15.000 valores para o modelo estacionário e 30.000 valores para o modelo não estacionário. Uma distribuição uniforme foi utilizada como distribuição a priori para os parâmetros dos modelos, e a função de verossimilhança é a própria distribuição GEV.

A comparação entre os resultados dos modelos estacionário e não estacionário foi realizada de duas maneiras.

Método 1: inferência dos parâmetros dos modelos a partir da série inteira, e comparação realizada a partir de critérios de informação. Os critérios de informação permitem 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 considerados,

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

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

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.

Segundo Burnham e Anderson (2002), a seleção do modelo mais apropriado para a representação de determinado conjunto de dados pode ser feita através do cálculo das diferenças de AIC/BIC entre o modelo candidato i e o que apresenta o menor valor de AIC/BIC, da seguinte forma:

$$\Delta AIC = AIC_i - AIC_{\min} \quad (6)$$

$$\Delta BIC = BIC_i - BIC_{\min} \quad (7)$$

Valores de ΔBIC e ΔAIC até 2 indicam suporte para o uso de modelo estacionário enquanto que valores maiores que 10 indicam que não há suporte para o uso do modelo estacionário.

Método 2: separação de cada uma das séries de dados em duas partes, um período (30 anos) utilizado para inferência dos parâmetros e outro período (10 anos) para avaliação de desempenho dos modelos. A utilização deste método possibilita a obtenção de resultados mais robustos quando comparado ao primeiro método. Quando este método foi aplicado, a validação do modelo não estacionário 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 ($L_{méd}$) calculada para cada um dos conjuntos de parâmetros da distribuição a posteriori.

RESULTADOS

Há presença de tendências significativas para cheias no Brasil e um claro padrão espacial para sua ocorrência (Figura 2). Das 275 séries temporais avaliadas, 51 apresentaram tendências negativas (concentradas ao norte da região Sudeste e no Nordeste) e 17 positivas (concentradas no Norte e em parte do Sul e Sudeste do Brasil). Não é possível aferir se, de fato, as tendências negativas são predominantes no Brasil, uma vez que séries de importantes bacias hidrográficas, como a do Rio Paraná, não foram avaliadas.

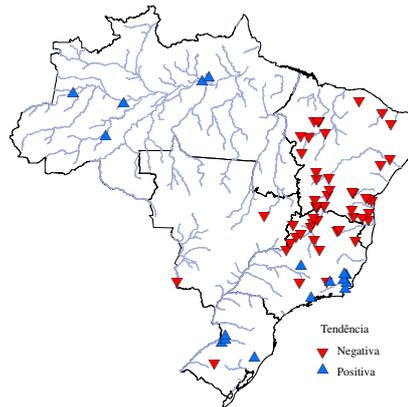


Figura 2 – Localização dos postos fluviométricos cujas séries temporais apresentaram tendências significativas ($p < 0,05$) avaliadas pelo teste de Mann-Kendall e seu respectivo sinal de tendência.

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 3. Os resultados foram separados de acordo com a presença ou não de tendências significativas avaliadas pelo teste de Mann-Kendall. De modo geral, pode ser constatado que não há o favorecimento do uso de modelos NS para a análise de frequência de cheias quando tendências significativas não se manifestam nas séries temporais. No entanto, quando avaliadas as séries que apresentaram tendência significativa, é possível constatar maiores valores de ΔAIC e ΔBIC , representando assim maior favorecimento nessas séries ao modelo NS. Para as duas situações avaliadas, 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 do modelo ST.

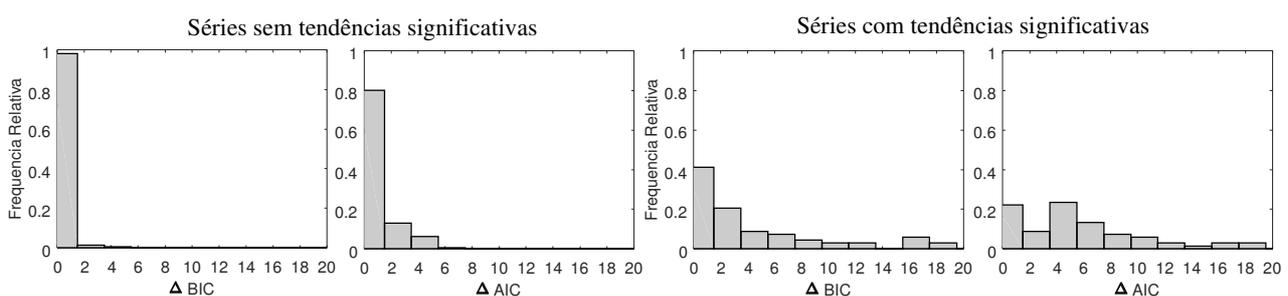


Figura 3 – Distribuição dos valores ΔBIC e ΔAIC para séries temporais que apresentaram ou não tendências significativas no teste de Mann-Kendall.

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 (i. e., maior número de parâmetros). Em 196 séries houve o favorecimento do modelo NS ($\Delta AIC > 0$) quando utilizado o critério de informação da Akaike, contra 71 séries temporais quando utilizado o critério de informação de Bayes.

Este resultado sugere uma inabilidade do critério de informação de Akaike 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. A Figura 4 ilustra a distribuição espacial dos valores de ΔBIC e ΔAIC , bem como a relação entre a existência de tendências significativas.

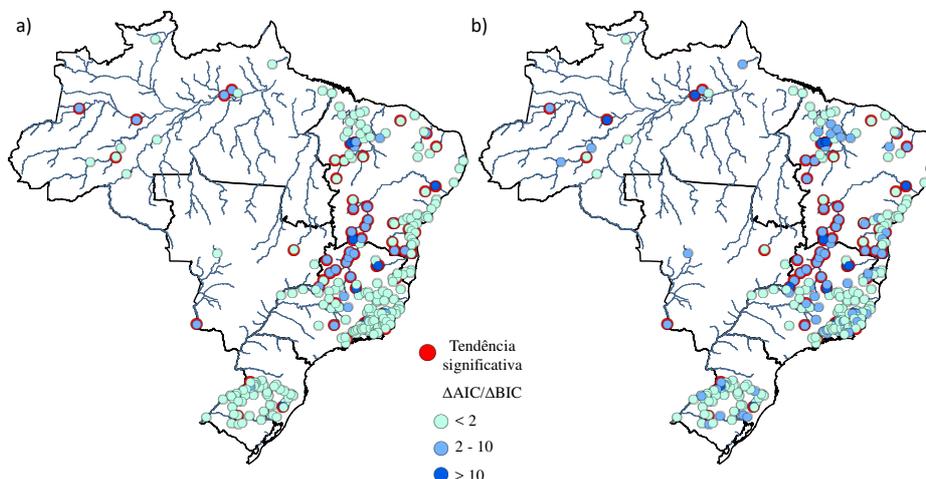


Figura 4 – Distribuição espacial dos valores de (a) ΔBIC e (b) ΔAIC e relação entre a existência de tendências significativas.

Quando observado apenas o período de calibração (**Método 2**), composto pelos primeiros trinta anos das séries temporais, o modelo não estacionário foi preferido por 140 séries temporais quando aplicado o critério de informação de Akaike e por 41 séries temporais quando aplicado o critério de informação de Bayes. Os resultados obtidos para a validação do modelo NS, a partir dos dez últimos anos das séries temporais são apresentados na Tabela 1. Foram avaliadas a utilização dos modelos (1) estacionário (ST); (2) não estacionário, com a extrapolação da tendência inferida (NS); e (3) estacionário atualizado (uST), sendo utilizados os valores dos parâmetros do modelo não estacionário do final do período de calibração.

Tabela 1. Número de séries, dentre as consideradas não estacionárias no período de calibração, com melhor desempenho na validação para cada um dos modelos considerando o valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança ($L_{méd}$).

Calibração	AIC		BIC	
	L_{MAP}	$L_{méd}$	L_{MAP}	$L_{méd}$
Validação				
ST	14 (10%)	64 (46%)	3 (7%)	11 (27%)
uST	26 (19%)	24 (17%)	7 (17%)	09 (22%)
NS	100 (71%)	52 (37%)	31 (76%)	21 (51%)

ST: Estacionário; uST: Estacionário atualizado; NS: Não estacionário.

O modelo NS resultou, para o período de validação, em um melhor desempenho em parte significativa das séries temporais (maior que 50% em três das quatro situações avaliadas). Quando

levado em conta também o modelo uST, que tem características não estacionárias, houve o favorecimento de modelos deste tipo em todos os casos. O modelo ST somente obteve leve melhor desempenho para aquelas séries temporais que receberam, no período de calibração, suporte para a não estacionariedade através do critério de Akaike e quando observada a incerteza na estimativa dos parâmetros, ou seja, analisado os valores da média do valor da função de verossimilhança calculado para cada um dos conjuntos de parâmetros da distribuição a posteriori ($L_{méd}$).

De maneira geral, o modelo NS recebeu maior suporte quando observado os valores da função de verossimilhança considerando apenas o conjunto ótimo de parâmetros. Quando levada em consideração a incerteza na estimativa dos parâmetros, o suporte ao modelo NS diminuiu, mas ainda foi significativo. O comportamento distinto quando usado o L_{MAP} e $L_{méd}$ fica mais evidente quando observados os resultados de todas as 275 séries avaliadas neste trabalho, ficando clara a preferência do modelo ST quando levado em conta a incerteza na estimativa dos parâmetros (Tabela 2). 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). Na Figura 5 é representada a comparação entre os referidos modelos para a estação fluviométrica 74295000 – Linha Jatai (Bacia do Uruguai), que apresentou tendência significativa (positiva).

Tabela 2 – Número de séries com melhor desempenho na validação para os modelos ST, uST e NS considerando os valores da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e o valor médio da função de verossimilhança ($L_{méd}$) e todas as 275 séries temporais usadas neste trabalho.

Modelo	L_{MAP}	$L_{méd}$
ST	40	146
uST	42	40
NS	193	89

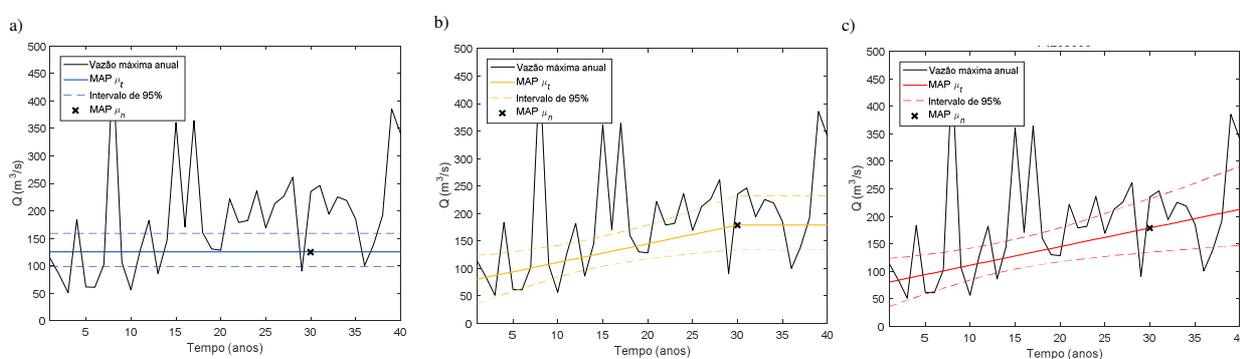


Figura 5 – Comparação entre os modelos (a) ST; (b) uST e (c) NS para a estação fluviométrica 74295000 – Linha Jatai.

CONCLUSÕES

Neste trabalho foi avaliada a presença de tendências em séries temporais de vazões máximas e a aplicação de modelos estacionário e não estacionário do tipo GEV para a análise de frequência de cheias no Brasil, bem como as incertezas associadas ao uso desses. Foram utilizados como métodos de seleção do modelo os critérios de informação de Akaike (AIC) e de Bayes (BIC). Quando a série de vazões máximas anuais foi separada em um período de calibração e um período de validação, a avaliação do desempenho dos modelos também foi realizada através do valor da função de verossimilhança para o conjunto ótimo de parâmetros (L_{MAP}) e do valor médio da função de verossimilhança ($L_{méd}$).

Foi verificado que há presença de tendências significativas para cheias no Brasil e um claro padrão espacial para sua ocorrência. Houve o favorecimento do uso do modelo não estacionário nas séries que apresentaram tendências significativas. Os modelos com melhor desempenho na validação foram coerentes com aqueles selecionados na calibração, mesmo quando levada em conta a incerteza. Na validação considerando $L_{méd}$ os modelos com características não estacionárias (uST e NS) resultaram em melhor desempenho em 54% (73%) das séries em que o AIC (BIC) indicou favorecimento do modelo não estacionário no período de calibração. Os resultados indicam a necessidade de considerar a não estacionariedade na análise de frequência de cheias e a validade da extrapolação do modelo não estacionário quando levado em conta um curto prazo (10 anos). O modelo a ser utilizado (uST ou NS) depende da avaliação do fenômeno associado a não estacionariedade e da continuidade de sua atuação sobre a variável hidrológica em análise.

AGRADECIMENTOS

A segunda autora agradece à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão de bolsa de Doutorado Pleno no Exterior. Processo nº 88881.174456/2018-01.

REFERÊNCIAS

- 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.
- BURNHAM, K. P., ANDERSON, D. R. (2001). Kullback–Leibler information as a basis for strong inference in ecological studies. *Wildlife Research*, 28, 111-119.
- DETZEL, D. H. M.; BESSA, M. R.; VALLEJOS, C. A. V.; SANTOS, A. B.; THOMSEN, L. S. Estacionariedade das Afluências às Usinas Hidrelétricas Brasileiras. *Revista Brasileira de Recursos Hídricos*, v. 16, n. 3, p. 95–111, 2011.
- DU, T.; XIONG, L.; XU, C. Y.; *et al.* Return period and risk analysis of nonstationary low-flow series under climate change. *Journal of Hydrology*, v. 527, p. 234–250, 2015.
- FOUFOULA-GEORGIU, E.; TAKBIRI, Z.; CZUBA, J.; SCHWENK, J. The change of

nature and the nature of change in agricultural landscapes: Hydrologic regime shifts modulate ecological transitions. *Water Resources Management*, v. 51, p. 6649–6671, 2015.

GADO, T. A.; NGUYEN, V. An at-site flood estimation method in the context of nonstationarity II. *Statistical analysis of floods in Quebec. Journal of Hydrology*, v. 535, p. 722–736, 2016.

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.

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

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

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

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

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

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, 2016.

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.

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, 2016.

SRAJ, M.; VIGLIONE, A.; PARAJKA, J.; BLÖSCHL, G. The influence of non-stationarity in extreme hydrological events on flood frequency estimation frequency estimation. *Journal of Hydrology and Hydromechanics*, November, 2016.

THEIL, H. A rank-invariant method of linear and polynomial regression analysis, 1, 2, e 3, *Proceedings of the Royal Netherlands Academy of Sciences*, v. 53, 386-392, 521-525, e 1397-1412, 1950.

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

VRUGT, J. A. (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.

ZAJAC, Z.; REVILLA-ROMERO, B.; SALAMON, P.; *et al.* The impact of lake and reservoir parameterization on global streamflow simulation. *Journal of Hydrology*, 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, 2015.