

XV SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE

PREVISÃO DE VAZÕES DIÁRIAS NO RIBERÃO SERRA AZUL EM MINAS GERAIS EMPREGANDO A PROGRAMAÇÃO GENÉTICA MULTI-GENE(MGGP)

David Antonio Jimenez. ¹ ; Eber José de Andrade Pinto ²

RESUMO – Os avanços tecnológicos das últimas décadas têm permitido a incorporação de novos enfoques e metodologias na previsão de vazões. No presente trabalho foi empregada a técnica de programação genética multi-gene (MGGP) para prever vazões diárias no ribeirão Serra Azul em Faz. Pasto Grande, localizado na região central de Minas Gerais, com área de drenagem de 55 km². Utilizaram-se como variáveis preditoras dados pluviométricos, de evaporação do Tanque Classe-A e de vazões. Foram gerados modelos a partir de quatro diferentes configurações das variáveis preditoras. O rendimento dos modelos foi avaliado a partir dos coeficientes de Nash-Sutcliffe (NSE), Kling-Gupta (KGE) e a raiz do erro médio quadrático (RMSE). A avaliação da etapa de validação, indicou que o melhor modelo utiliza como variáveis preditoras a precipitação média de 5 estações pluviométricas, os registros de 1 estação evaporimétrica e os dados de vazão de Faz. Pasto Grande defasados um dia. Apesar de não considerar as relações conhecidas dos processos físicos e hidrológicos, a técnica de programação genética, MGGP, mostrou-se eficiente na previsão de vazões.

ABSTRACT– The technological advances of the last decades have allowed the incorporation of new approaches and methodologies in the forecast of streamflows. In the present work, the multigene genetic programming technique (MGGP) was used to predict daily flows in the Serra Azul in Faz. Pasto Grande, located in the central region of Minas Gerais, with a drainage area of 55 km². Rainfall, evaporation data from the Class-A tank and flow rates were used as predictor variables. Models were generated from four different configurations of the predictor variables. The performance of the models was evaluated using the Nash-Sutcliffe (NSE), Kling-Gupta (KGE) coefficients and the root of the mean square error (RMSE). The evaluation of the validation stage indicated that the best model uses the average precipitation of 5 pluviometric stations, the records of 1 evaporimetric and the flow data from Faz as predictor variables. Pasture Grande lagged by one day. Despite not considering the known relationships of physical and hydrological processes, the genetic programming technique, MGGP, proved to be efficient in predicting flows.

Palavras-Chave – MGGP, Chuva-vazão.

¹) Mestrando em Recursos Hídricos-UFMG: Endereço: Avenida Antônio Carlos, 6627 Bloco 1, Sala 4619 - CEP 31270-901, Fone : +(55-31) 985816373, E-mail: dajimenezoo30@gmail.com.

²) SMARH-UFMG e CPRM – Serviço Geológico do Brasil, Endereço: Avenida Brasil, 1731 CEP: 30.140-002 Belo Horizonte, MG Brasil, Fone : +(55-31) 3878-0376, E-mail: eber.andrade@cprm.gov.br.r

1. INTRODUÇÃO.

Um problema recorrente em hidrologia e em engenharia de recursos hídricos é a estimação das relações chuva-vazão (Morán,1989). A transformação da chuva em vazão é um processo complicado, devido à alta complexidade existente entre suas variáveis, ao dinamismo das bacias hidrográficas, e às relações não lineares entre as variáveis que governam o processo.

Os avanços tecnológicos das últimas décadas têm permitido a evolução dos modelos hidrológicos, assim como a incorporação de novos enfoques, metodologias e ferramentas computacionais ao campo da hidrologia, e especialmente a previsão de vazões. Atualmente, a simulação dos processos hidrológicos sob enfoque de mineração de dados e aprendizado de máquina (*machine learning*) tem adquirido grande relevância, pelo qual, tem existido um aumento substancial dos estudos relacionados com inteligência artificial aplicados à estimação das relações chuva-vazão. Dentro dos enfoques mais empregados atualmente destacam-se: Os modelos baseados em Redes Neurais Artificiais-ANNs (*e.g.* Lee *et al.* (2008); Sungwon (2011); Kisi *et al.* (2013)), modelos baseados nos sistemas de inferência adaptativos Neuro-Fuzzy -AFINS (*e.g.* Bartoletti *et al.* (2018)), modelos baseados em programação genética-PG (*e.g.* Savid *et al.* (1999); Danandeh e Nourani (2017); Danandeh e Nourani (2018)) e modelos híbridos (*e.g.* Dorado *et al.* (2010); Tan *et al.* (2018)).

A capacidade de simulação dos processos chuva-vazão oferecida por modelos baseados em PG, ANNs e AFINS foi analisada por Kisi *et al.*(2013), os resultados da pesquisa evidenciaram que os modelos baseados em técnicas de PG são os que possuem a melhor capacidade de representação dos processos chuva-vazão.

O presente trabalho tem por objetivo aplicar uma técnica de PG, ou seja, a programação genética Multi-gene, na previsão de vazões no rib. Serra Azul em Faz. Pasto Grande com área de drenagem de 55 km² na região central de Minas Gerais. Serão testados modelos com quatro diferentes configurações das variáveis preditoras, as quais são dados pluviométricos, de evaporação do Tanque Classe-A e de vazões.

2. PROGRAMAÇÃO GÉNÉTICA MULTI-GENE (MGGP)

A PG é uma técnica de aprendizado de máquina desenvolvida por Koza (1992), encontra-se caracterizada pela evolução automática de programas de computadores com o propósito de fornecer solução a uma ampla gama de problemas. A PG encontra-se inspirada nas técnicas de seleção natural de Darwin, inicialmente, é gerada uma população aleatória de programas, a partir da qual são produzidas novas gerações (Mehr *et al.* (2018)).

Como é indicado por Mehr *et al.* (2018), na PG os programas se encontram representados por genes em forma de árvore, os quais contém nodos e ramos, cada nodo pode conter uma função (*i.e* +, -, x, /, sin, cos, e, ln, entre outras) ou um terminal. As funções incluem operadores booleanos e funções matemáticas ou aritméticas, por outro lado, os terminais estão constituídos por variáveis ou constantes numéricas. Na Figura 1.a é apresentada a estrutura básica de um programa na PG.

Com o propósito de melhorar a capacidade de resolução dos problemas, têm surgido algumas variantes da PG, dentro da qual se encontra a MGGP, a qual, se caracteriza por combinar árvores de pouca profundidade. A MGGP (Hinchliffe *et al.* (1996) foi desenvolvida principalmente visando à regressão simbólica, a qual, estabelece uma relação entre a variável a ser predita (predição) e as variáveis predictoras, através de uma expressão matemática. Na Figura 1.b é apresentada a estrutura básica de um programa na MGGP.

A MGGP tem sido empregada no desenvolvimento de múltiplos estudos na área dos recursos hídricos, entre os estudos que visaram identificar as relações chuva-vazão se encontram os desenvolvidos por: Heřmanovský *et al.* (2017); Mehr e Nourani, (2017); Mehr e Nourani, (2018) e Vargas e Obregón, (2011).



$$y = -2x_1 * \frac{2}{x_1 x_2} \quad [1]$$

$$y = d_0 + d_1 [3.1 * (x_2 - x_1)] + d_2 \left[x_1 - \frac{x_3}{x_2} \right] \quad [2]$$

a). Representação de um Programa na PG. b). Exemplo dum programa na MGGP que envolve 2 genes.

Figura 1 Representação dos programas na PG e na MGGP.

Onde y = Predição; x_1, x_2 e x_3 = variáveis predictoras; d_1 e d_2 = Ponderação dos genes 1 e 2 e d_0 = Termo irregular. As ponderações dos genes são os coeficientes de regressão, os quais geralmente são determinados a partir do método de mínimos quadrados.

3. MATERIAL E MÉTODOS.

3.1 Caracterização da Área de Estudo.

O modelo de previsão foi treinado e avaliado para o ribeirão Serra Azul em Pasto Grande, a qual forma parte da bacia representativa de Juatuba – Minas Gerais (Figura 1). A área de drenagem da estação fluviométrica de Pasto Grande se encontra localizada entre as coordenadas: 551817,85 – 559458,00m E e 7780942,46 – 7769686,21m S UTM-23S, possui uma área de drenagem de 55,56

km², uma declividade média do canal principal do 2,6%, um perímetro de 40,6 km e um coeficiente de compacidade de 1,52. O curso da água principal é o ribeirão serra azul, o qual percorre 12 km até a estação fluviométrica de Pasto Grande.

3.1.1 Clima.

O regime pluviométrico da sub-bacia do ribeirão Serra Azul, encontra-se caracterizado pela presença de chuvas durante os meses de outubro até março, enquanto que o período de estiagem desenvolve-se durante os meses de abril a setembro. Na Tabela 1 são resumidas as principais características climatológicas da área de estudo.

Variável	Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
Temperatura Média Mensal [°C]	22,6	23,2	21,3	21,3	18,9	17,3	17,3	18,4	20,1	22,1	22,0	22,5
Precipitação Média Mensal [mm]	289,8	162,4	162,7	65,6	34,7	17,0	11,4	12,0	51,6	96,6	209,5	320,7
Vazão média diária (m ³ /s)	1,57	1,17	1,05	0,73	0,55	0,45	0,38	0,32	0,31	0,32	0,54	1,12

Tabela 1 Caracterização climatológica da sub-Bacia Pasto Grande.

3.2 Informação Hidroclimatológicas.

Como está apresentado na Figura 1, duas estações pluviométricas se encontram instaladas dentro da sub-bacia do Ribeirão Serra Azul, e outras 3 estão na vizinhança. No desenvolvimento do modelo de previsão de vazões foram empregados os registros de evaporação do tanque Classe A da estação Alto da Boa Vista (02044021), vazões da estação Fazenda Pasto Grande (40810800), e precipitação das estações: Alto da Boa Vista (02044021), Calambau (02044020), Fazenda Coqueiros (02044026), Fazenda Laranjeiras (02044041) e Serra Azul (02044054), os quais foram obtidos do site *HIDROWEB* da Agência Nacional de Águas (ANA) para o período 1978-2019.

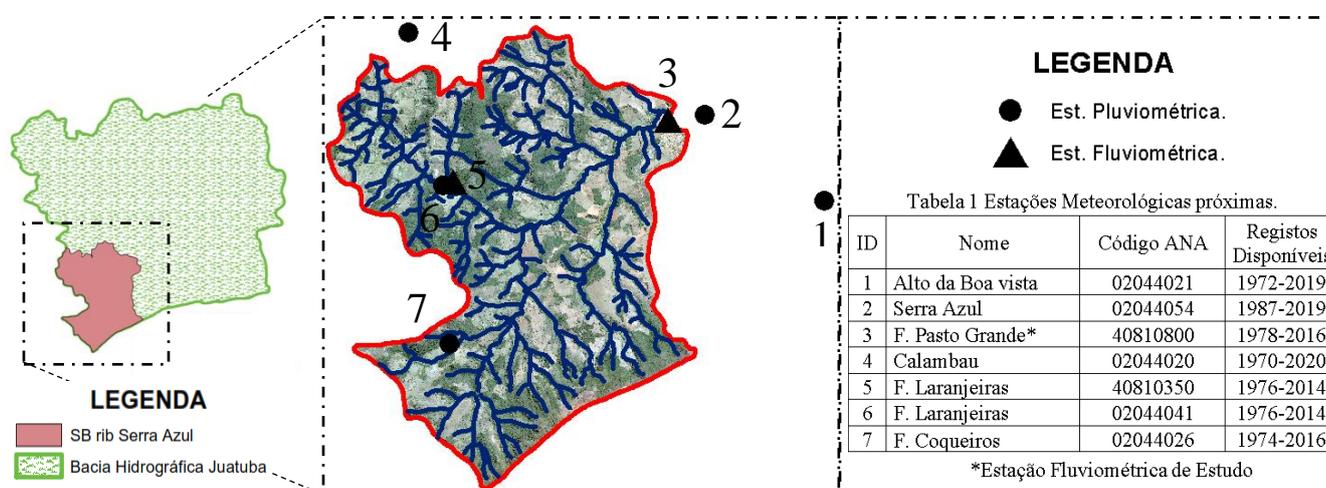


Figura 1 – Sub-Bacia Hidrográfica do ribeirão Serra Azul.

Tendo em conta que a geração de modelos baseados em técnicas de inteligência artificial contempla uma etapa de treinamento e outra de validação, as séries históricas foram subdivididos em duas series. A primeira foi empregada na etapa de treinamento e abarcou o período 1978-2008, enquanto que a segunda foi utilizada na etapa de validação e compreendeu o período de 2009-2019.

3.3 Configuração do Algoritmo MGPP.

Com o propósito de gerar um modelo chuva-vazão em função da precipitação, evaporação e vazão precedente com atraso temporal de um dia (Eq, 1), foram testadas quatro configurações de variáveis predictoras (Tabela 2), procurando identificar os preditores que fornecem o modelo mais eficiente.

$$Q(t) = f(P_{it}, \bar{P}, E_{it}, Q_{t-1}) \quad [1]$$

Onde: $Q(t)$ = Vazão no instante t , E_i = Evaporação- Tanque no posto i no instante t , Q_{t-1} =Vazão de precipitação no instante $t-1$, P_i = Precipitação da Estação i no instante t , \bar{P} = precipitação média das estações pluviométricas da Figura 1.

Tabela 2 Configurações das variáveis Predictoras.

Configuração	Variáveis Predictoras	Código das Estações Empregadas
1	Precipitação (P_i) ³ .	02044020; 02044021; 02044026;02044041;02044054
	Evaporação-Tanque (E).	02044021
2	Precipitação média das estações (\bar{P}).	02044020; 02044021; 02044026;02044041;02044054
	Evaporação-Tanque (E).	02044021
3	Precipitação (P_i) ³ .	02044021; 02044020; 02044026;02044041;02044054
	Evaporação-Tanque (E).	02044021
	Vazão t-1 (Q_{-1}).	40810800
4	Precipitação média das estações. (\bar{P}).	02044021; 02044020; 02044026;02044041;02044054
	Evaporação-Tanque (E)	02044021
	Vazão t-1(Q_{-1}).	40810800

Os modelos de simulação/previsão foram gerados com o *software* GPTIPS (SEARSON, 2010), o qual tem sido empregado em estudos que visaram identificar as relações chuva-vazão (e,g Merh e Neurani (2018); Merh e Neurani (2017)). Por outro lado, a avaliação do modelo foi realizada com os critérios de eficiência descritos no item a seguir.

3 O subíndice i , é o indicativo da estação, por exemplo, um subíndice $i=1$ faz referência à estação com código "02044021".

O modelo MGGP foi configurado com uma população inicial de 200 indivíduos, um número máximo de 100 gerações, uma taxa de mutação, cruzamento e reprodução 5, 90 e 5% respectivamente, e um número máximo de 3 genes e uma altura máxima da árvore de 4. As funções matemáticas escolhidas para os nós foram: soma (+), diferença (-), divisão (/), produto (*) e a função trigonométrica Cosseno (Cos).

3.4 Critérios de eficiência

Com o propósito de conhecer a magnitude do erro e verificar a eficiência das simulações de vazões, foram empregados coeficientes de avaliação amplamente conhecidos na modelagem hidrológica, o coeficiente de Nash-Sutcliffe-NSE (Eq 2, Nash e Sutcliffe 1979) e a raiz do erro médio quadrático-RMSE (Eq. 3) e o coeficiente de Kling-Gupta-KGE (Eq. 4, Gupta *et, al* 2009) ,

Um NSE e KGE com valor de 1 indicam um ajuste perfeito, enquanto, que no caso do RMSE o valor de ajuste perfeito é 0.

$$NSE = 1 - \frac{\sum_{i=1}^n (X_i^{obs} - X_i^{est})^2}{\sum_{i=1}^n (X_i^{obs} - X_{média}^{obs})^2} \quad [2]$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i^{obs} - X_i^{est})^2}{n}} \quad [3]$$

$$KGE = 1 - \sqrt{(r - 1)^2 + \left(\frac{\sigma_{est}}{\sigma_{obs}} - 1\right)^2 + \left(\frac{\mu_{est}}{\mu_{obs}} - 1\right)^2} \quad [4]$$

Onde: X_i^{obs} = Vazão observada no instante de tempo i ; X_i^{est} = Vazão estimada para o instante de tempo i ; $X_{média}^{obs}$ = média das vazões observadas; n = número total de dados; σ_{est} =desvio padrão da data simulada; σ_{obs} =desvio padrão da data Observada; r =coeficiente de correlação entre a data observada e simulada.

4. RESULTADOS E DISCUSSÃO.

4.1 Treinamento e validação do modelo.

O treinamento e validação dos modelos de simulação foram realizados para cada uma das configurações descritas na tabela 2. Na etapa de treinamento foram empregados 11.181 registros, os quais, correspondem ao 73,7% dos dados disponíveis, por outro lado, a etapa de validação foi desenvolvida com 3.986 registros, que equivalem ao restante 26,3% dos dados .

A discrepância de percentagens nas etapas de treinamento e validação obedece à necessidade de garantir um adequado aprendizado do algoritmo na etapa de treinamento, pelo qual, é preciso empregar uma maior quantidade de dados.

As equações 4, 5, 6 e 7 foram obtidas para cada uma das configurações apresentadas na Tabela 2.

$$Q(t) = 0.0088P_1 + 0.00122 P_2 + 0.0188P_3 - 0.00122P_5 - 0.01E + 0.00122P_2 P_4 - 0.000323 (P_5 - P_6)(P_2 + P_3 + P_4 - P_5) + 0.616 \quad [4]$$

$$Q(t) = 0.0324\bar{P} - 0.0324 \cos(\bar{P}) - 0.0324 \cos(E) + 0.00064 \bar{P} (\bar{P} + E + 7.472) - 0.0118 \bar{P} \cos(E) + 0.5798 \quad [5]$$

$$Q(t) = 0.0042 Q_{-1} + 0.0042P_3 + 0.0042P_4 + 0.00057P_2P_4 + \frac{0.178 (Q_{-1}^2 - 7.855)}{0.784Q_{-1} + 0.6627} + \frac{3.258 Q_{-1}P_2 P_3 E}{10^7} + 1.801 \quad [6]$$

$$Q(t) = 0.629 Q_{-1} + 0.00179\bar{P} + 0.0036 Q_{-1} (\bar{P} - 5.62Q_{-1} + E) + 0.000895(Q_{-1} + \bar{P})(\bar{P} + E) + 0.189 + \frac{0.000895 \bar{P}}{Q_{-1}} \quad [7]$$

Onde: $Q(t)$ = vazão no instante de tempo t (m^3/s), P_i = precipitação total registrada na estação i no instante de tempo t (mm/dia), \bar{P} = precipitação média diária das estações pluviométricas para o tempo t (mm/dia), E = evaporação de tanque (mm/dia) no tempo t e Q_{-1} = Vazão com atraso temporal de um dia (m^3/s).

Ao analisar os modelos obtidos, é possível perceber a impossibilidade de estabelecer relações físicas entre as variáveis preditoras e a predição, devido ao fato do MGGP buscar unicamente identificar e representar as relações lineares e não lineares, existentes entre as variáveis preditoras e a predição, sem ter em conta os processos físicos e hidrológicos subjacentes.

Uma vez obtidos os modelos chuva-vazão, procedeu-se calcular os critérios de eficiência descritos anteriormente, os resultados para as etapas de treinamento e validação são apresentados na Tabela 3.

Tabela 3 resultados dos critérios de eficiência dos modelos chuva-vazão.

Configuração	RMSE		NSE		KGE	
	treinamento	Validação	treinamento	Validação	treinamento	Validação
1	0,74	0,63	0,52	0,28	0,60	0,19
2	0,81	0,67	0,43	0,21	0,52	0,15
3	0,53	0,43	0,75	0,67	0,81	0,81
4	0,60	0,47	0,68	0,60	0,75	0,67

Tendo em conta que Knoben *et. al.* (2019) ressalta que ainda não existe um consenso generalizado entre o rendimento do modelo e os índices de avaliação empregados (*i.e* NSE, RMSE e KGE), no presente estudo foram adoptados os rendimentos descritos na Tabela 4.

Tabela 4 resultados dos critérios de eficiência dos modelos chuva-vazão.

	Confiável	bom	aceitável	pouco confiável
NSE	$0,90 \leq NSE \leq 1$	$0,60 \leq NSE < 0,90$	$0,60 < NSE \leq 0$	$NSE < 0$
RSM	$0 \leq RMSE \leq 0,3$	$0,3 < RMSE \leq 0,6$	$0,6 < RMSE \leq 1$	$RMSE > 1$
KGE	$0,90 \leq KGE \leq 1$	$0,41 \leq KGE < 0,90$	$0,41 < KGE \leq 0$	$KGE < 0$

De acordo com o exposto nas tabelas 3 e 4, é possível avaliar o rendimento dos modelos obtidos a partir dos resultados da etapa de validação. Os modelos obtidos a partir das configurações 1 e 2 podem ser classificadas com rendimento aceitável, enquanto que os modelos obtidos a partir das configurações 3 e 4 é possível atribuir um rendimento bom.

Ao analisar as diferentes configurações de preditores empregados, observa-se que aquelas que contemplam a vazão precedente como variável preditora fornecem modelos com maiores rendimentos. Apesar de apresentar as melhores métricas, o modelo 3 gerou muitas vazões negativas na etapa de validação. Assim sendo o melhor modelo passa a ser o 4, o qual também gerou valores negativos, mas somente em 8 dias. Porém é importante ressaltar que o período de 2014 a 2018 foi o mais seco da série histórica, o que provavelmente dificultou a validação.

Na figura 2 são apresentados os resultados obtidos na etapa de validação das configurações 3 e 4.

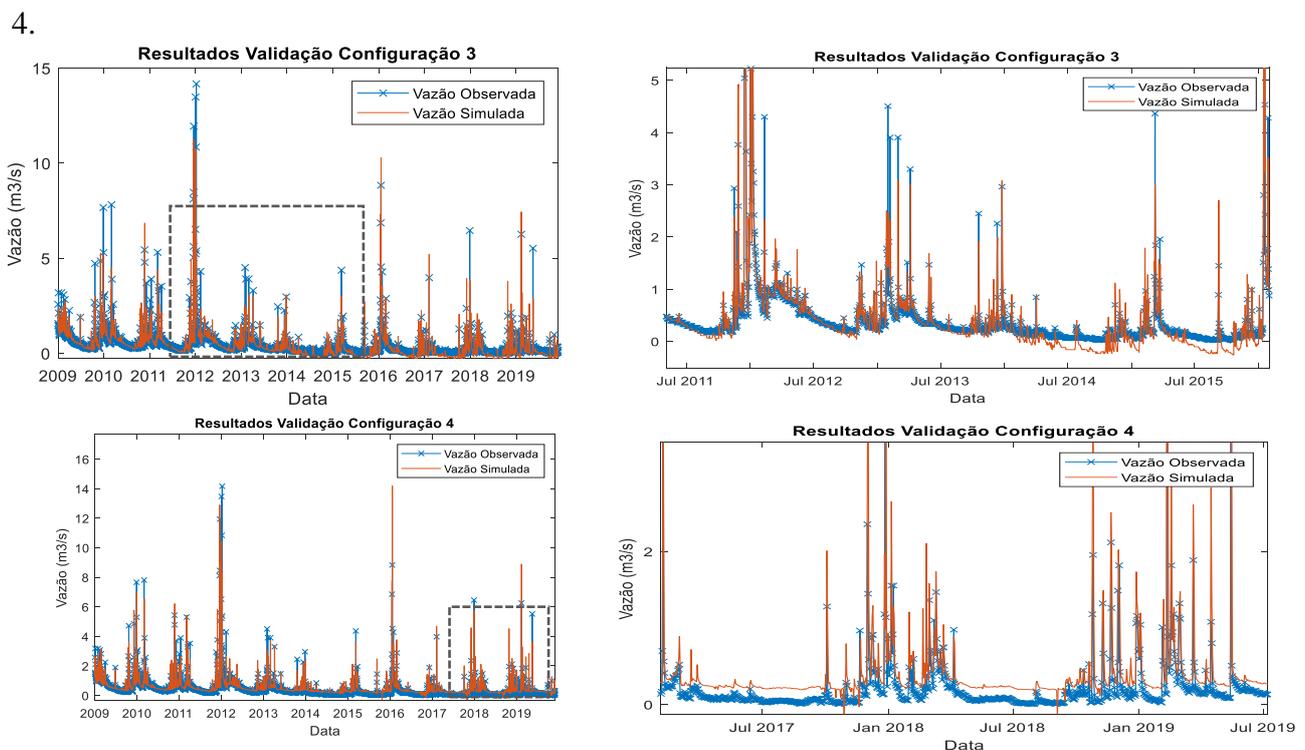


Figura 2 – vazões simuladas e observadas etapa de validação configurações 3 e 4.

5. CONCLUSÕES

Apesar de não considerar as relações conhecidas dos processos físicos e hidrológicos, a técnica de programação genética, MGGP, mostrou-se eficiente na previsão de vazões devido a sua capacidade de identificar e representar as relações lineares e não lineares existentes entre as variáveis preditoras e a prevista.

No presente estudo foram avaliados quatro modelos de previsão de vazões no rib. Serra Azul em Fazenda Pasto Grande, que utilizaram como variáveis preditoras dados pluviométricos, de evaporação do Tanque Classe-A e de vazões. a partir de quatro configurações de: registros pluviométricos, fluviométricos e de evaporação de Tanque. A avaliação da etapa de validação indicou que o melhor modelo utiliza como variáveis preditoras a precipitação média de 5 estações pluviométricas, os registros de 1 estação evaporimétrica e os dados de vazão de Faz. Pasto Grande defasados de um dia.

AGRADECIMENTOS,

Os autores agradecem ao programa de Pós-Graduação em Saneamento, Meio Ambiente e Recursos Hídricos da UFMG e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio à realização desta pesquisa.

6. REFERÊNCIAS,

BARTOLETTI, N. et al. *"Data-driven rainfall/runoff modelling based on a neuro-fuzzy inference system"*. Environmental Modelling & Software 2018-2019(1-106), pp. 35–47.

DORADO, J. et al. *"Prediction and modeling of the rainfall-runoff transformation of a typical urban basin using ann and gp"*. Applied Artificial Intelligence, 2010-2011(17-4), pp. 329–343.

GUPTA, H. V. et al. *"Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling"*. Journal of Hydrology, 2009-2010(377-1), pp. 80–91.

HEŘMANOVSKÝ, M. et al. *"Regionalization of runoff models derived by genetic programming"*. Journal of Hydrology, 2017-2018(547-1), pp. 544–556.

HINCHLIFFE, M. et al. *"Modelling Chemical Process Systems Using a Multi-Gene Genetic Programming Algorithm"*. In: Late Breaking Papers at the Genetic Programming. Stanford University, CA, USA: Stanford Bookstore, 1996-1997(1-1) pp. 56–65.

KISI, O.; SHIRI, J.; TOMBUL, M. *"Modeling rainfall-runoff process using soft computing techniques"*. Computers & Geosciences, 2013-2014 (51-1), pp. 108–117.

KNOBEN, W. J. M.; FREER, J. E.; WOODS, R. A. "Technical note: Inherent benchmark or not? Comparing Nash–Sutcliffe and Kling–Gupta efficiency scores". *Hydrology and Earth System Sciences*, 2019-2020 (23-10), pp. 4323–4331.

KOZA, J. R.(1992) "*Genetic Programming II: Automatic Discovery of Reusable Programs.*" 1. ed. MIT Press. pp 768.

LEE, K. T.; HUNG, W.-C.; MENG, C.-C. "Deterministic Insight into ANN Model Performance for Storm Runoff Simulation." *Water Resources Management*, 2008-2009 (22-1) pp. 67–82.

MEHR, D. A. et al. "Genetic programming in water resources engineering: A state-of-the-art review". *Journal of Hydrology*, 2018-2019 (566-1), pp. 643–667.

MEHR, D. A.; NOURANI, V. "A Pareto-optimal moving average-multigene genetic programming model for rainfall-runoff modelling". *Environmental Modelling & Software*, 2017-2018 (92-1), pp. 239–251.

MEHR, D. A.; NOURANI, V. "Season Algorithm-Multigene Genetic Programming: A New Approach for Rainfall-Runoff Modelling." *Water Resources Management*, 2018-2019 (32-8), pp. 2665–2679.

MORÁN, W. C. (1989) *Hidrologia para estudiantes de ingeniería civil*. PONTIFICIA UNIVERSIDAD CATOLICA DEL PERÚ. p. 236.

NASH, J. E.; SUTCLIFFE, J. V. "River flow forecasting through conceptual models part I — A discussion of principles" - ScienceDirect. Disponível em: <[https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)>. Acesso em: 25 jul. 2020.

SAVIC, D. A.; WALTERS, G. A.; DAVIDSON, J. W. "A Genetic Programming Approach to Rainfall-Runoff Modelling." *Water Resources Management* 1999-2000(13-1), pp. 219–231.

SEARSON, D.(2010) Genetic programming & symbolic regression for MATLAB.User guide.

SUNGWON, K. "Nonlinear Hydrologic Modeling Using the Stochastic and Neural Networks Approach." *Disaster Advances*, (2011-2012) pp. 53–63.

TAN, Q.-F. et al. "An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach." *Journal of Hydrology*, 2018-2019 (567-1), pp. 767–780.

VARGAS, L. A.; OBREGÓN, N. N.(2011) "*La programación Genética en la Modelación Hidrológica de Cuencas. Aplicaciones en el estudio del Proceso Lluvia-Escorrentia*. Saarbrücken, Alemania: Editorial Académica Española., p. 180.