

XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

IMPACTO DO PREENCHIMENTO DE FALHAS NAS SÉRIES HISTÓRICAS DE VAZÃO NO CÁLCULO DAS VAZÕES DE REFERÊNCIA: ESTUDO DE CASO NA BACIA DO RIO DOCE

*Guilherme Barbosa Reis¹; Demetrius David da Silva¹; Michel Castro Moreira¹; Roberto Avelino
Cecílio²; Micael de Souza Fraga³ & Rafael Luís Silva Dias³*

Abstract: Historical streamflow series are essential for water resource management, especially for calculating reference flows such as $Q_{7,10}$, Q_{90} , Q_{95} , and Q_{mld} , used in the allocation, licensing, and protection of multiple water uses. However, these series often present gaps due to operational, technical, or logistical problems. This study investigated the impact of filling gaps in streamflow series on the accuracy of reference flows in the Doce River basin, southeastern Brazil. Using daily data from 11 fluvimetric stations with complete 30-year series (1994–2023), gaps of 5% to 50% were simulated, applying five imputation methods: moving average (MM), simple linear regression (RL), MissForest (MF), K-Nearest Neighbors (KNN), and Multiple Imputation by Chained Equations (MICE). The quality of the imputations was assessed by the metrics R^2 , PBIAS, and RMSE. The results demonstrated that the MICE algorithm performed better in recovering missing values. Furthermore, the comparative analysis of the calculation of reference flows using complete, faulty and filled series indicated that there was no statistical difference in the flow values obtained. This shows that for the historical series analyzed, the presence of gaps does not cause major losses in obtaining reference flows.

Resumo: As séries históricas de vazão são fundamentais para a gestão de recursos hídricos, especialmente no cálculo das vazões de referência como $Q_{7,10}$, Q_{90} , Q_{95} e Q_{mld} , utilizadas na alocação, licenciamento e controle dos usos múltiplos da água. No entanto, é comum que essas séries apresentem falhas devido a problemas operacionais, técnicos ou logísticos. Este estudo investigou o impacto do preenchimento de falhas em séries históricas de vazão sobre a acurácia das vazões de referência na bacia do rio Doce, sudeste do Brasil. Utilizando dados diários de 11 estações fluviométricas com séries completas de 30 anos (1994–2023), foram simuladas falhas de 5% a 50%, aplicando-se cinco métodos de imputação: média móvel (MM), regressão linear simples (RL), MissForest (MF), K-Nearest Neighbors (KNN) e Multiple Imputation by Chained Equations (MICE). A qualidade das imputações foi avaliada pelas métricas R^2 , PBIAS e RMSE. Os resultados demonstraram que o algoritmo MICE apresentou melhor desempenho na recuperação de valores ausentes. Ademais, a análise comparativa das vazões de referência estimadas utilizando séries completas, com as vazões estimadas a partir das séries com falhas e preenchidas indicou que não houve diferença estatística nos valores de vazões obtidos. Isso mostra que para as séries históricas analisadas, a presença de falhas não causa grandes prejuízos na obtenção de vazões de referência.

Palavras-Chave: Séries temporais hidrológicas; vazões de referência; imputação de dados.

1) Dep. de Eng. Agrícola, Universidade Federal de Viçosa, Viçosa, MG, 36.570-900; guilherme.b.reis@ufv.br, demetrius@ufv.br, michelcm@ufv.br.

2) Dep. de Ciências Florestais e da Madeira, Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES, 29.500-000; roberto.cecilio@ufes.br.

3) Instituto Mineiro de Gestão das Águas, Belo Horizonte, MG, 31.630-900; micael.fraga@meioambiente.mg.gov.br, rafael.luis@ufv.br.

1. INTRODUÇÃO

As séries históricas de vazão constituem a base para uma ampla gama de aplicações na hidrologia e na gestão dos recursos hídricos, incluindo o dimensionamento de estruturas hidráulicas, o planejamento do uso da água, a avaliação de disponibilidade hídrica e a definição de vazões de referência para fins ambientais e legais (Ibiapina et al., 2003; Tucci, 2009). A qualidade e a continuidade dessas séries são, portanto, essenciais para assegurar a confiabilidade das análises hidrológicas (Vieira et al., 2018). No entanto, é comum a ocorrência de dados faltantes nas séries históricas de vazão, em decorrência de falhas nos sensores, problemas de operação das estações hidrométricas ou dificuldades logísticas na coleta e transmissão dos dados ou erros obtidos ao anotar ou observar os dados (Sharma e Yuden, 2021).

A presença de lacunas nas séries históricas de vazões pode comprometer a confiabilidade de indicadores da disponibilidade hídrica em uma bacia hidrográfica (Giustarini et al., 2016; Tencaliec et al., 2015). Segundo Serrano (2020), a disponibilidade hídrica pode ser estimada por diferentes metodologias, sendo normalmente quantificada por meio de algumas vazões de referência, que são utilizadas na gestão de recursos hídricos. As vazões de referência mais utilizadas pelos órgãos gestores de recursos hídricos no Brasil são a vazão mínima com média de sete dias consecutivos e período de retorno de 10 anos ($Q_{7,10}$), as vazões associadas às permanências de 90 e 95% no tempo (Q_{90} e Q_{95}) (Lelis et al., 2020) e a vazão média de longa duração (Q_{mld}).

A fim de superar a presença de falhas nos dados de vazão, diversas abordagens têm sido propostas para o preenchimento de lacunas em séries hidrológicas, variando desde modelos lineares simples a técnicas determinísticas ou estocásticas complexas (Dembélé *et al.* 2019). Atualmente ganha destaque técnicas baseadas em aprendizado de máquina, como Random Forest, K-Nearest Neighbors (KNN) e redes neurais artificiais (Beguería *et al.*, 2019; Kim e Pachepsky, 2010; Stekhoven e Buhlmann, 2012). Estudos comparativos revelaram que os métodos podem superar uns aos outros dependendo do conjunto de dados utilizado (Campozano et al., 2014; Harvey et al., 2012).

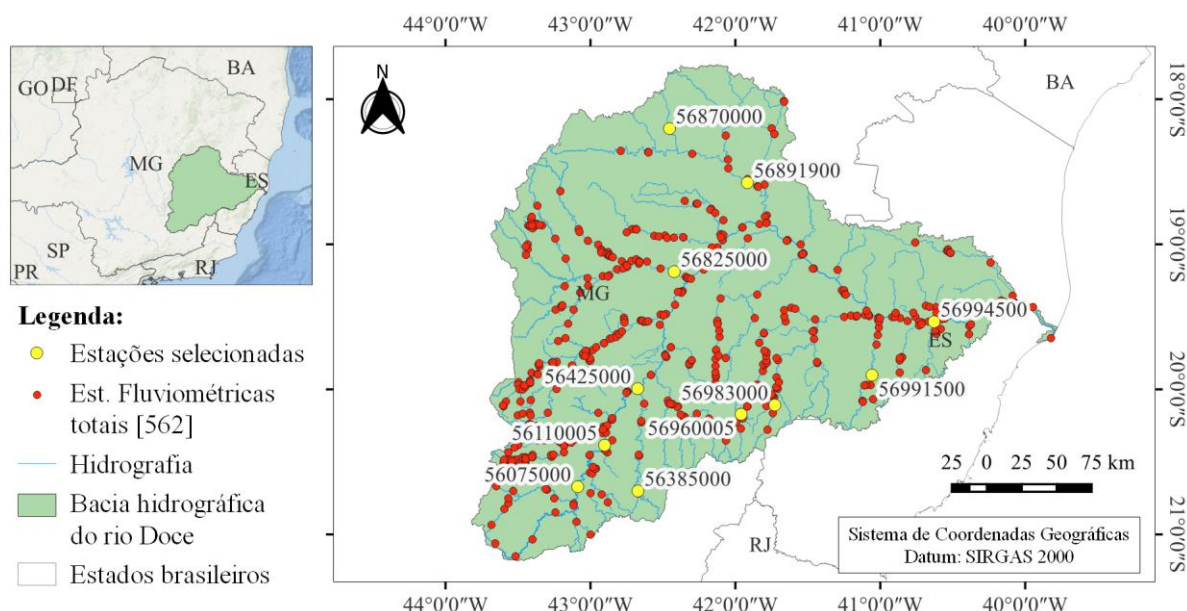
Contudo, embora muitos estudos se concentrem na acurácia da imputação dos dados em si, ainda são limitadas as investigações que avaliam o impacto da utilização de séries históricas com falhas e preenchidas sobre o cálculo da $Q_{7,10}$, Q_{90} , Q_{95} e Q_{mld} . Essa lacuna é particularmente relevante, considerando a importância desses valores na gestão integrada de recursos hídricos. Nesse contexto, o presente trabalho busca testar diferentes técnicas de preenchimento de dados faltantes para completar as séries históricas de vazão, avaliando o impacto do preenchimento de falhas das séries históricas no valor calculado das vazões de referência $Q_{7,10}$, Q_{90} , Q_{95} e Q_{mld} .

2. MATERIAL E MÉTODOS

2.1. Área de estudo

A área de estudo foi a bacia hidrográfica do rio Doce (Figura 1), localizada na região sudeste do Brasil, com extensão de aproximadamente 82.427 km² (ANA, 2018). Os climas predominantes na bacia, de acordo com a classificação de Köppen, são o tropical de monções com inverno seco (Aw); o subtropical úmido com inverno seco e verão quente (Cwa); e o subtropical úmido com inverno seco e verão ameno (Cwb) (Alvares et al., 2013). A precipitação média anual é de cerca de 1.200 mm (Lima et al., 2019), e o ano hidrológico é dividido em duas estações: seca, com 150 a 250 mm de chuva (abril a setembro) e chuvosa, com 800 a 1.300 mm (outubro a março) (ECOPLAN-LUME, 2010).

Figura 1 - Mapa de localização e estações fluviométricas da bacia hidrográfica do rio Doce.



2.2. Dados de vazão

O inventário de estações fluviométricas da Agência Nacional de Águas e Saneamento Básico (ANA), disponível nos metadados da agência (ANA, 2023), aponta 562 estações para a bacia do rio Doce (Figura 1), porém nem todas possuem dados disponíveis. Foi feito o download automático das séries históricas de vazões das estações presentes na bacia utilizando uma rotina em *Python* capaz de acessar e baixar os dados disponíveis no *Hidroweb* (<https://www.snirh.gov.br/hidroweb>) e organizá-los em um *Dataframe*.

Para a realização do estudo foi adotado um período base de 30 anos de dados diários de vazão, de outubro de 1994 a setembro de 2023, considerando o ano hidrológico na bacia que é de outubro a setembro (CPRM, 2014; IGAM, 2015; Marques, 2010). Utilizaram-se os dados brutos e consistidos para representar a realidade hidrológica atual da bacia, assim como feito por Ferreira *et al.* (2021). Foram utilizadas no estudo apenas as estações que não apresentaram falhas no período adotado, resultando em 11 estações (Tabela 1).

Tabela 1 - Lista das estações selecionadas para o estudo.

Código	Latitude (°)	Longitude (°)	Rio	Área de drenagem (km ²)
56075000	-20,67	-43,09	Rio Piranga	4260
56110005	-20,38	-42,90	Rio Piranga	6230
56385000	-20,70	-42,67	Rio Casca	523
56425000	-19,99	-42,67	Rio Doce	10100
56825000	-19,19	-42,42	Rio Santo Antônio	10200
56870000	-18,20	-42,45	Rio São Félix	622
56891900	-18,57	-41,92	Rio Suaçuí Grande	9770
56960005	-20,17	-41,96	Rio Manhuaçu	1070
56983000	-20,11	-41,73	Rio José Pedro	384
56991500	-19,90	-41,06	Rio Guandú	1330
56994500	-19,53	-40,63	Rio Doce	76400

2.3. Avaliação dos métodos de preenchimento de falhas

2.3.1. Geração de dados faltantes nas séries históricas de vazão

Nas séries históricas das 11 estações fluviométricas adotadas, as quais não apresentaram falhas no período adotado, foram gerados aleatoriamente dados faltantes, com percentuais de falhas de 5%, 10%, 20%, 30%, 40% e 50% em cada estação. Esse procedimento permitiu avaliar o desempenho das técnicas de imputação de dados em função da variação na quantidade de falhas presentes nas séries.

2.3.2. Métodos de preenchimento de falhas utilizados

Para fins de comparação foram utilizados cinco métodos de preenchimento de falhas: a Média Móvel (MM); a Regressão Linear Simples (RL); o algoritmo MissForest (MF); o algoritmo K-Nearest Neighbors (KNN); e o algoritmo Multiple Imputation by Chained Equations (MICE).

O método da Média Móvel (MM) foi aplicado semelhante ao que foi feito no estudo de Ventura *et al.* (2016). A MM realiza a média aritmética de uma série de valores anteriores à falha. Neste trabalho utilizou-se uma janela de sete dias, o que significa que para preencher uma determinada falha foram utilizados os últimos sete valores de vazão da própria série histórica para realização da média. Nos casos em que houver falhas dentro da janela de sete dias, a média é feita com os valores disponíveis. É importante ressaltar que a média móvel se torna inviável para preenchimento de séries com elevado número de falhas consecutivas, pois pode ocorrer de não haver nenhum valor disponível dentro da janela adotada para realizar a média e, consequentemente o preenchimento do dado faltante.

A Regressão Linear Simples (RL) é um método comumente utilizado (Alley; Burns, 1983; Beyad; Maeder, 2013; Mfwango *et al.*, 2018) para preenchimento de dados hidrometeorológicos e consiste em correlacionar a estação que se deseja realizar o preenchimento de falhas com as demais estações de apoio disponíveis, gerando um ranking de estações mais correlacionadas. A estação de apoio que resultou no maior coeficiente de correlação (r) com a estação alvo foi utilizada para ajustar uma equação de regressão linear. Dessa forma o valor faltante foi determinado aplicando-se a equação de regressão ajustada, utilizando como variável independente o valor de vazão da estação de apoio na mesma data de ocorrência da falha. Quando a estação de apoio apresentou falhas na mesma data da estação alvo, utilizou-se a próxima estação de apoio com maior correlação para ajuste da equação.

O MissForest (MF) é um algoritmo de aprendizado de máquina não paramétrico desenvolvido por Stekhoven e Bühlmann (2012). O MF utiliza o algoritmo Random Forest para treinar iterativamente um modelo que considera o conjunto de estações fluviométricas como variáveis e realiza a predição dos valores faltantes. Para cada estação com falhas, o algoritmo construiu uma floresta aleatória usando as outras estações como variáveis preditoras. A floresta aleatória foi ajustada apenas com os valores observados (não faltantes). Após o treinamento das árvores de regressão os valores faltantes da estação em questão foram preenchidos com as previsões geradas pelo modelo.

O KNN é um dos métodos mais utilizados para preenchimento de falhas em séries de dados hidrometeorológicos (Beguería *et al.*, 2019; Lepot *et al.*, 2017). Este método utiliza as estações vizinhas mais próximas para preencher lacunas na estação com dados faltantes e imputa valores faltantes usando a média ponderada das estações vizinhas (Martins *et al.*, 2023). Neste estudo o número de vizinhos adotados foi $K=5$, conforme feito por Martins *et al.* (2023), e a medida para identificar as estações vizinhas foi a distância euclidiana. Dessa forma, considerando os valores das séries históricas das estações para a mesma data calculou-se a distância entre os dados da estação com falha e das demais estações. As cinco estações que apresentaram menor distância foram selecionadas para realizar o preenchimento. Os valores conhecidos de vazão dos K-vizinhos mais próximos na

mesma data da ocorrência da falha foram utilizados para preencher o valor ausente a partir da média ponderada pela distância, em que o maior peso é atribuído à estação mais próxima.

O MICE (Van Buuren, 1999) é uma abordagem prática para lidar com dados ausentes. O método demonstrou funcionar bem em diversas aplicações hidrológicas e teve melhor desempenho do que outros métodos (Ekeu-wei *et al.*, 2018; Little, 1992; Sidibe *et al.*, 2018). Para realizar a imputação utilizando o método MICE, o algoritmo executou as seguintes etapas, conforme descrito por Azur *et al.* (2011): inicialmente, definiu-se o número de iterações (K). Em seguida, para cada estação, substituíram-se os valores ausentes por uma estimativa inicial, como a média dos valores não ausentes dessa coluna, o que resultou em um conjunto de dados sem falhas temporariamente. Posteriormente, para preencher os dados da primeira estação, o valor imputado foi novamente marcado como ausente, e um modelo de regressão foi construído para prever os dados da estação em questão utilizando as demais como preditoras, considerando apenas as linhas onde a estação a ser preenchida não possuía dados ausente. Esse modelo foi então utilizado para prever os valores ausentes da primeira estação. O mesmo processo foi repetido para as outras estações, completando uma iteração de previsões. Esse procedimento foi repetido para K iterações, com os valores previstos em cada iteração sendo progressivamente aprimorados. Ao final da K-ésima iteração, a última previsão para cada estação foi mantida como valor preenchido.

2.3.3. Métricas de avaliação

Para a avaliação do desempenho das técnicas de preenchimento adotadas, foram consideradas as seguintes métricas estatísticas: Coeficiente de determinação (R^2); Viés percentual (PBIAS); e Raiz quadrada do erro médio (RMSE). A classificação qualitativa dos modelos foi realizada com base nas faixas dos valores dos indicadores estatísticos, conforme indicado por Moriasi *et al.* (2015) e apresentadas na Tabela 2.

Tabela 2 - Classificação qualitativa dos indicadores estatísticos.

Indicador	Critérios de avaliação de desempenho			
	Muito bom	Bom	Satisfatório	Insatisfatório
R^2	$> 0,85$	$0,75 < R^2 \leq 0,85$	$0,60 < R^2 \leq 0,75$	$R^2 \leq 0,60$
PBIAS (%)	$< \pm 5$	$\pm 5 < \text{PBIAS} \leq \pm 10$	$\pm 10 < \text{PBIAS} \leq \pm 15$	$\text{PBIAS} \geq \pm 15$

Fonte: Adaptado de Moriasi *et al.* (2015).

O RMSE foi considerado satisfatório quando o seu valor foi abaixo da metade do desvio padrão dos dados observados, conforme utilizado por Singh *et al.* (2005).

2.4. Avaliação do impacto do preenchimento no valor das vazões de referência

2.4.1. Simulação de falhas

Para este trabalho, consideraram-se as vazões de referência a vazão mínima da média de sete dias consecutivos e período de retorno de dez anos ($Q_{7,10}$), as vazões com 90 e 95% de permanência (Q_{90} e Q_{95} , respectivamente) e a vazão média de longa duração (Q_{mld}), uma vez que estas são as mais utilizadas pelos órgãos gestores de recursos hídricos no Brasil (Lelis *et al.*, 2020).

Para avaliar a qualidade e, até mesmo a necessidade, do preenchimento de falhas nas séries históricas de vazões diárias para determinação das vazões de referências $Q_{7,10}$, Q_{90} , Q_{95} e Q_{mld} , foi

feito o cálculo das vazões para: as séries completas de dados; as séries com exclusão de dados faltantes; e as séries contendo valores preenchidos pelo método que apresentou melhor desempenho na etapa anterior. Na sequência foi verificado se os valores obtidos de vazões de referência diferem estatisticamente entre si.

Primeiramente foram calculadas as vazões de referência para as séries com os dados completos. Na sequência, para cada estação, foram geradas lacunas nos dados em um percentual de 10% distribuídos aleatoriamente nos meses do período seco (abril a setembro), pois as vazões neste período são as que, de fato, influenciam no cálculo das vazões mínimas. Foram feitas 4 simulações distintas, S1, S2, S3 e S4, correspondendo a geração dos 10% de falhas no período seco em 5, 10, 15 e 20 anos de dados, respectivamente. Os anos com dados faltantes foram excluídos e os valores das vazões de referência foram recalculados. Por último, as falhas geradas na etapa anterior foram preenchidas pelo método de melhor desempenho e, para a série completa com os dados preenchidos, as vazões de referência foram novamente determinadas.

2.4.2. Verificação estatística dos valores obtidos

Para cada uma das simulações (S1, S2, S3 e S4) foram estimados os valores das vazões de referência na condição de dados completos, dados com exclusão de anos faltantes e dados com preenchimento das falhas. Foi feita uma comparação estatística entre as vazões de referência obtida com os dados completos e as vazões determinadas nas outras duas condições para verificar se estes diferem estatisticamente.

Primeiramente a distribuição dos dados de vazões de referência foi avaliada utilizando-se o teste de Shapiro-Wilk (Shapiro; Wilk, 1965) que, para todos os casos, apontou que os dados não seguem uma distribuição normal. Com isso, utilizou-se o teste não paramétrico de Man-Whitney (Mann; Whitney, 1947) para comparação estatística dos valores. Para a realização dos testes foi adotado um nível de significância (α) de 5% (0,05), conforme feito por Kiely (1999). A interpretação dos testes é feita com base no valor de probabilidade (p-value) que, se for menor que α (p-value < 0,05) rejeita-se a hipótese nula (H_0) de que os dados seguem uma distribuição normal, no caso do teste de Shapiro-Wilk, e de que não há diferença significativa entre as amostras, no caso do teste de Mann-Whitney.

3. RESULTADOS E DISCUSSÃO

3.1. Análise dos métodos de preenchimento de falhas

A Figura 2-a apresenta os valores do coeficiente de determinação (R^2) obtidos para cada método de preenchimento de falhas adotado variando o percentual de dados faltantes. Observa-se que todos os métodos, avaliando o valor de R^2 , tiveram desempenhos classificados como Bom ou Muito bom, com R^2 acima de 0,75 e na maioria dos casos acima de 0,85.

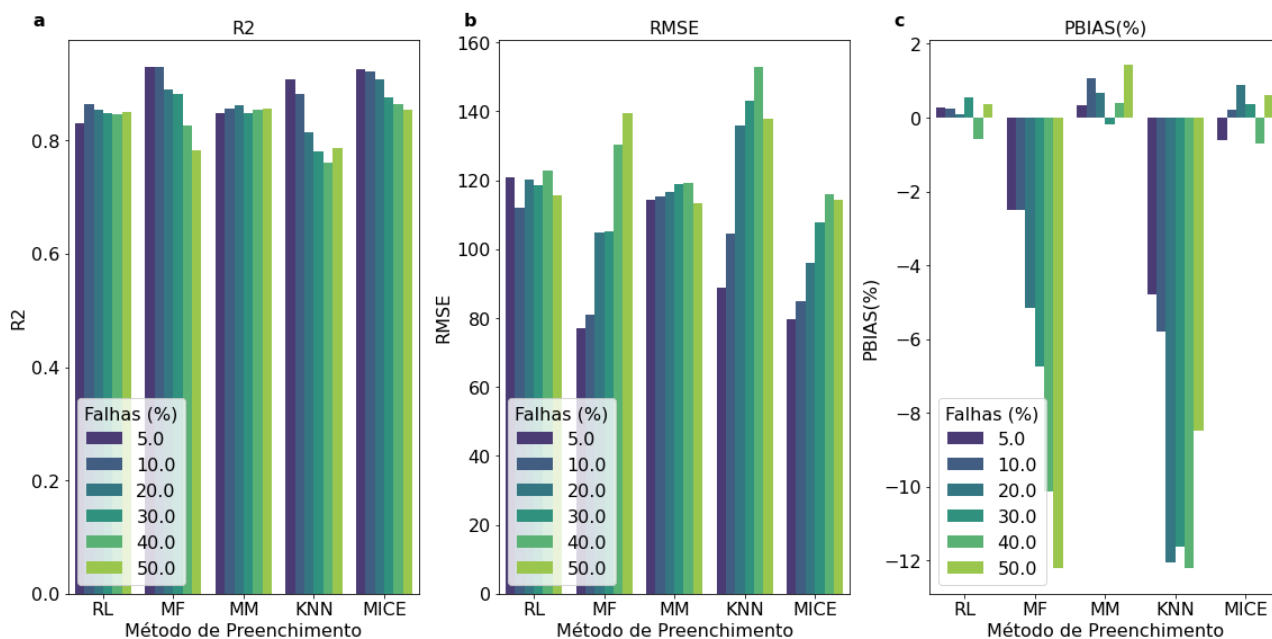
Os métodos Média Móvel (MM) e Regressão Linear Simples (RL), avaliando o valor de R^2 , não apresentaram grande variação no desempenho à medida que o percentual de falhas aumentou. Por outro lado, os métodos de aprendizado de máquina, MissForest (MF) e K-Nearest Neighbors (KNN), apesar de apresentarem desempenho superior aos anteriores para baixos percentuais de falhas, decaíram à medida que o número de falhas aumentou. Possivelmente isso ocorre, pois estes modelos precisam de uma quantidade elevada de dados para realizar a etapa do treinamento e aprender o comportamento da variável. Um número de amostras de treinamento pequeno pode prejudicar a capacidade de tomada de decisão dos algoritmos de aprendizado de máquina (Millard;

Richardson, 2015). O algoritmo Multiple Imputation by Chained Equations (MICE) apresentou maiores valores de R^2 em praticamente todos os percentuais de falhas, apresentando um decaimento menor no desempenho com o aumento de dados faltantes.

A Figura 2-b apresenta os valores da Raiz quadrada do erro médio (RMSE). Semelhante ao que foi observado para o R^2 , os métodos MM e RL, avaliando o valor do RMSE, não apresentaram grande variação no desempenho à medida que o percentual de falhas aumentou, no entanto, apresentaram erros maiores que os demais métodos principalmente para percentuais de falhas mais baixos. Para percentuais de falhas acima de 20 e 30%, o KNN e o MF, respectivamente, apresentaram maiores valores de RMSE do que a RL e a MM. Até 10% de falhas, o MF apresentou RMSE menor que o MICE, embora tenham sido valores muito próximos. A partir de 10% de dados faltantes, o MICE teve erros aumentando progressivamente, no entanto, em valores absolutos menores que os demais métodos para o mesmo percentual de falhas.

Na Figura 2-c é apresentada a tendência dos métodos de preenchimento de sub ou superestimar os dados. O MF e o KNN subestimaram os dados em todas as situações, chegando a apresentar valores acima de 12%, que ainda assim são classificados como satisfatório para este índice. Os demais métodos tiveram, em todas as situações, considerando a métrica PBIAS, desempenho classificado como muito bom.

Figura 2 - Indicadores estatísticos por método de preenchimento e diferentes percentuais de falhas: a) Coeficiente de determinação (R^2); b) Raiz quadrada do erro médio (RMSE); e c) Viés percentual (PBIAS).



RL - Regressão Linear Simples; MF - algoritmo MissForest; MM - Média Móvel; KNN - algoritmo K-Nearest Neighbors; e MICE - Multiple Imputation by Chained Equations.

Com base nas métricas analisadas, pode-se perceber que o método MICE apresentou melhor desempenho e maior estabilidade para realizar o preenchimento de falhas nas estações consideradas, resultado que corrobora com os obtidos por Sidibe *et al.* (2018). Segundo o mesmo autor, apesar do MICE muitas vezes fornecer estimativas melhores do que o MF, este último pode ser mais apropriado no contexto de mudanças de regimes hidrológicos, devido à sua capacidade de capturar relações não lineares complexas.

3.2. Análise do impacto do preenchimento no valor das vazões de referência

Na Tabela 3 são apresentados os resultados do teste de Mann-Whitney, sendo possível verificar que para todas as comparações feitas em todas as simulações o p-value apresentou valor maior do que o nível de significância (0,05), indicando que não foi observada diferença estatística entre os valores de vazões de referência calculados para as séries históricas com dados completos em comparação com as vazões obtidas para as séries com dados descartados e preenchidos.

Tabela 3 - Resultados do teste de Mann-Whitney.

Vazão	Comparação	S1		S2		S3		S4	
		MW	p-value	MW	p-value	MW	p-value	MW	p-value
Q _{7,10}	C vs F	58.0	0.896	59.0	0.948	57.0	0.844	54.0	0.694
Q _{7,10}	C vs P	59.5	0.974	61.0	1.000	60.0	1.000	61.0	1.000
Q ₉₀	C vs F	67.0	0.694	67.0	0.694	63.0	0.896	66.0	0.743
Q ₉₀	C vs P	60.0	1.000	60.0	1.000	59.5	0.974	60.0	1.000
Q ₉₅	C vs F	68.0	0.646	63.0	0.896	61.0	1.000	62.5	0.922
Q ₉₅	C vs P	59.5	0.974	58.5	0.921	57.0	0.844	57.0	0.844
Q _{mld}	C vs F	66.0	0.743	66.0	0.743	66.0	0.743	63.0	0.896
Q _{mld}	C vs P	61.0	1.000	59.0	0.948	60.0	1.000	61.0	1.000

C - Série com dados completos; F - Série com remoção dos anos com falhas (que foram geradas); P - Série com dados faltantes preenchidos; MW - Estatística do teste de Mann-Whitney; S1 - Simulação com geração de falhas em 5 anos de dados; S2 - Simulação com geração de falhas em 10 anos de dados; S3 - Simulação com geração de falhas em 15 anos de dados; e S4 - Simulação com geração de falhas em 20 anos de dados.

Em termos práticos, os resultados indicam que a presença de dados faltantes não compromete significativamente o cálculo das vazões de referência, que possuem um componente estatístico em sua determinação. Foi possível obter estimativas de vazões comparáveis às obtidas a partir de séries completas, mesmo quando a série histórica apresentava falhas em 20 dos 30 anos analisados, ou seja, com apenas 33% dos dados disponíveis.

4. CONCLUSÕES

O algoritmo Multiple Imputation by Chained Equations (MICE) apresentou melhor desempenho e maior estabilidade para realizar o preenchimento de falhas nas séries históricas de vazões diárias das estações fluviométricas consideradas.

Para as estações consideradas no estudo, os valores de vazões de referência calculados para as séries históricas com dados completos em comparação com as vazões obtidas para as séries com dados descartados e preenchidos não diferem estatisticamente, indicando que a presença de dados faltantes não compromete significativamente o cálculo das vazões de referência. No entanto é preciso, em trabalhos futuros, expandir a análise para outras regiões com climas e comportamento hidrológico distintos, variando também o percentual de falhas adotados.

REFERÊNCIAS

- ALLEY, W. M.; BURNS, A. W. Mixed-Station Extension of Monthly Streamflow Records. *Journal of Hydraulic Engineering*, v. 109, n. 10, pp. 1272–1284, out. 1983.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, v. 22, n. 6, pp. 711–728, 2013.
- ANA. Base Hidrográfica Ottocodificada da Bacia do Rio Doce 1:50.000/1:100.000. Brasília Agência Nacional de Águas, 17 jul. 2018.

- ANA. Rede Hidrometeorológica Nacional. Brasília. Agência Nacional de Águas, 25 abr. 2023.
- AZUR, M. J. et al. Multiple imputation by chained equations: what is it and how does it work? *International Journal of Methods in Psychiatric Research*, v. 20, n. 1, pp. 40–49, 24 mar. 2011.
- BEGUERÍA, S. et al. Gap Filling of Monthly Temperature Data and Its Effect on Climatic Variability and Trends. *Journal of Climate*, v. 32, n. 22, pp. 7797–7821, 15 nov. 2019.
- BEYAD, Y.; MAEDER, M. Multivariate linear regression with missing values. *Analytica Chimica Acta*, v. 796, pp. 38–41, set. 2013.
- CAMPOZANO, L. et al. Evaluation of infilling methods for time series of daily precipitation and temperature: The case of the Ecuadorian Andes. 2014.
- CPRM. Relatório 6 - Acompanhamento da estiagem na região sudeste do Brasil. Belo Horizonte. 2014.
- DEMBÉLÉ, M. et al. Gap-filling of daily streamflow time series using Direct Sampling in various hydroclimatic settings. *Journal of Hydrology*, v. 569, pp. 573–586, 2019.
- ECOPLAN-LUME. Plano de ação de recursos hídricos da unidade de planejamento e gestão dos recursos hídricos Piranga. 2010.
- EKEU-WEI, I. T.; BLACKBURN, G. A.; PEDRUCO, P. Infilling Missing Data in Hydrology: Solutions Using Satellite Radar Altimetry and Multiple Imputation for Data-Sparse Regions. *Water*, v. 10, n. 10, pp. 1483, 20 out. 2018.
- FERREIRA, R. G. et al. Machine learning models for streamflow regionalization in a tropical watershed. *Journal of Environmental Management*, v. 280, n. August 2020, 2021.
- GIUSTARINI, L. et al. A user-driven case-based reasoning tool for infilling missing values in daily mean river flow records. *Environmental modelling & software*, v. 82, pp. 308–320, 2016.
- HARVEY, C. L.; DIXON, H.; HANNAFORD, J. An appraisal of the performance of data-infilling methods for application to daily mean river flow records in the UK. *Hydrology Research*, v. 43, n. 5, p. 618–636, 2012.
- IBIAPINA, A. V., et al. 2003 Evolução da hidrometria no Brasil. Disponível em: <http://www.mma.gov.br/port/srh/acervo/publica/doc/oestado/texto/121-138.html>.
- IGAM. Relatório Hidrometeorológico: Período Chuvoso 2014/2015. Belo Horizonte, 2015.
- KIELY, G. Climate change in Ireland from precipitation and streamflow observations. *Advances in Water Resources*, v. 23, n. 2, pp. 141–151, out. 1999.
- KIM, J.; PACHEPSKY, Y. A. Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. *Journal of hydrology*, v. 394, n. 3–4, pp. 305–314, 2010.
- LELIS, L. C. DA S. et al. Assessment of hydrological regionalization methodologies for the upper Jaguari River basin. *Journal of South American Earth Sciences*, v. 97, pp. 102402, jan. 2020.
- LEPOT, M.; AUBIN, J.-B.; CLEMENS, F. Interpolation in Time Series: An Introductory Overview of Existing Methods, Their Performance Criteria and Uncertainty Assessment. *Water*, v. 9, n. 10, pp. 796, 17 out. 2017.
- LIMA, R. P. C. et al. Development of an annual drought classification system based on drought severity indexes. *Anais da Academia Brasileira de Ciências*, v. 91, n. 1, 8 abr. 2019.
- LITTLE, R. J. A. Regression with Missing X's: A Review. *Journal of the American Statistical Association*, v. 87, n. 420, pp. 1227–1237, dez. 1992.
- MARTINS, L. L. et al. Gap-filling of daily precipitation and streamflow time series: a method comparison at random and sequential gaps. *Hydrological Sciences Journal*, v. 68, n. 1, pp. 148–160, 2 jan. 2023.
- MANN, H. B.; WHITNEY, D. R. On a Test of Whether one of Two Random Variables is Stochastically Larger than the Other. *The Annals of Mathematical Statistics*, v. 18, n. 1, pp. 50–60, mar. 1947.

- MARQUES, F. A. Sistema de controle dinâmico para a gestão dos usos múltiplos da água. Tese de doutorado - Viçosa: Universidade Federal de Viçosa - UFV, 17 jul. 2010.
- MFWANGO, L. H.; SALIM, C. J.; KAZUMBA, S. Estimation of Missing River Flow Data for Hydrologic Analysis: The Case of Great Ruaha River Catchment. *Hydrology: Current Research*, v. 09, n. 02, 2018.
- MILLARD, K.; RICHARDSON, M. On the Importance of Training Data Sample Selection in Random Forest Image Classification: A Case Study in Peatland Ecosystem Mapping. *Remote Sensing*, v. 7, n. 7, pp. 8489–8515, 6 jul. 2015.
- MORIASI, D. N. et al. Hydrologic and water quality models: Performance measures and evaluation criteria. *Transactions of the ASABE*, v. 58, n. 6, pp. 1763–1785, 2015.
- SERRANO, L. O. et al. Low-Flow Seasonality and Effects on Water Availability throughout the River Network. *Water Resources Management*, v. 34, n. 4, pp. 1289–1304, 31 mar. 2020.
- SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). *Biometrika*, v. 52, n. 3–4, pp. 591–611, 1 dez. 1965.
- SHARMA, V.; YUDEN, K. Imputing missing data in hydrology using machine learning models. *Int. J. Eng. Res. Technol.*, v. 10, n. 2021, pp. 78-82, 2021.
- SIDIBE, M. et al. Trend and variability in a new, reconstructed streamflow dataset for West and Central Africa, and climatic interactions, 1950–2005. *Journal of Hydrology*, v. 561, pp. 478–493, jun. 2018.
- SINGH, J.; KNAPP, H. V.; DEMISSIE, M. Hydrological modeling of the Iroquois River watershed using HSPF and SWAT. *Journal of the American Water Resources Association*, v. 41, n. 2, pp. 343–360, 2005.
- STEKHOVEN, D. J.; BÜHLMANN, P. MissForest - non-parametric missing value imputation for mixed-type data. *Bioinformatics*, v. 28, n. 1, pp. 112–118, 1 jan. 2012.
- TENCALIEC, Patricia et al. Reconstruction of missing daily streamflow data using dynamic regression models. *Water Resources Research*, v. 51, n. 12, pp. 9447-9463, 2015.
- TUCCI, C.E.M. Escoamento Superficial. In: TUCCI, C.E.M. *Hidrologia: Ciência e Aplicação*. Porto Alegre: UFRGS/ABRH. 4ª Ed. Cap. 11, pp.391-441. 2009.
- VAN BUUREN, S. Flexible multivariate imputation by MICE. *TNO Prevention and Health*, 1999.
- VENTURA, T. M. et al. Análise da aplicabilidade de métodos estatísticos para preenchimento de falhas em dados meteorológicos. *Revista Brasileira de Climatologia*, v. 19, 17 out. 2016.
- VIEIRA, S. A. et al. Metodologia de imputação de dados hidrometeorológicos para análise de séries históricas para avaliação de impactos das mudanças climáticas–Bacia do Rio dos Sinos, RS, Brasil. *Revista Brasileira de Climatologia*, v. 23, 2018.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio concedido a este trabalho. Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001.