

# Previsão de Vazão com Séries Temporais Nebulosas para Bacias do Sistema Interligado Nacional.

Tiago da Rocha Alves

*Departamento de Energia*

*Universidade Federal de Juiz de Fora*

Juiz de Fora, Brasil

tiago.alves@engenharia.ufjf.br

Ivo Chaves da Silva Júnior

*Departamento de Energia*

*Universidade Federal de Juiz de Fora*

Juiz de Fora, Brasil

ivo.junior@ufjf.br

Leonardo M. Honório

*Departamento de Energia*

*Universidade Federal de Juiz de Fora*

Juiz de Fora, Brasil

leonardo.honorio@ufjf.br

**Abstract**—This study proposes a comparative analysis between the Soil Moisture Accounting Procedure (SMAP/ONS) and the fuzzy time series technique for water flow forecasting in Brazilian hydroelectric power generation systems. The reservoir crisis of 2021, caused by the worst drought since 1931, which affected the country's energy sector and increased energy tariffs, served as a warning of the importance of water resource planning and management and how it is essential for electricity generation in Brazil. The SMAP/ONS model, currently used by the Brazilian National Electric System Operator (ONS), calculates water flow based on evapotranspiration and precipitation. In contrast, the fuzzy time series technique is a machine learning-based approach that uses fuzzy logic to handle uncertain data. Results show that the fuzzy time series technique presented competitive performance in most assessed cases.

**Index Terms**—Aprendizagem de máquina, Sistema Interligado Nacional, Previsão de Vazão, Séries Temporais Nebulosas

## I. INTRODUÇÃO

A crise hídrica de 2021, causada pela pior seca no Brasil desde 1931, foi responsável pelo aumento de tarifas de energia, preocupações por parte do setor energético e insegurança por parte de vários setores da economia brasileira. O parque gerador brasileiro, caracterizado por um perfil hidrotérmico, tendo em sua composição aproximadamente 60% da produção advinda de fonte hidráulica, sofreu de maneira acentuada com os reservatórios alcançando níveis criticamente baixos e sem previsão de chuvas iminentes. O planejamento e gerenciamento de recursos hídricos aliado a uma boa capacidade de previsão de vazões, e por consequência de disponibilidade de recursos hídricos é um tema de extrema importância para o contexto de geração de energia elétrica no Brasil.

Dada esta importância, o presente trabalho visa analisar a comparação entre a técnica *Soil Moisture Accounting Procedure* (SMAP/ONS), utilizada atualmente pelo Operador Nacional do Sistema Elétrico (ONS) brasileiro na previsão para o problema de chuva vazão e a técnica de previsão de séries temporais *fuzzy*. O modelo SMAP, originalmente proposto por Lopes et al. (1982) é um modelo capaz de calcular a vazão em uma bacia hidrográfica com base na evapotranspiração e na precipitação ocorridas na região da bacia. Nos últimos anos, o ONS modificou e aprimorou o modelo, adicionando um reservatório e alterando algumas equações[1][2]. Na utilização atual, este modelo passa por um processo de calibração da

vazão observada que visa adequar o modelo ao estado mais recente da bacia antes de gerar previsões. Este processo de calibração é feito através da meta-heurística Bat Algorithm, a qual é responsável pela otimização dos pesos de chuva recentes para que haja uma boa previsão de um modelo bem calibrado. Possíveis melhorias para a metodologia do SMAP continuam sendo investigadas [3][4].

A metodologia de séries temporais *fuzzy*, é uma técnica de análise de séries temporais que utiliza da lógica *fuzzy* para auxiliar no tratamento de dados com grande incerteza associada. Como esta é uma técnica de aprendizado de máquina capaz de ajustar-se através de dados históricos para gerar previsões futuras, não necessita de um estudo hidrológico prévio e pode ser implementada para as bacias através do treinamento dos modelos com base nas séries históricas de vazão e precipitação. Nesta técnica, as informações relativas a cada vazão e precipitação observadas nas bacias são associadas à conjuntos *fuzzy* ao invés de valores únicos, o que auxilia o tratamento de dados imprecisos ou com incertezas associadas ao processo de obtenção. Alguns exemplos de implementações de séries temporais nebulosas nas áreas de recursos energéticos renováveis [5][6], engenharia [7][8], meteorologia [9] e mercado financeiro [10] são encontradas.

Para a análise das metodologias propostas neste trabalho, foram utilizados dados das séries históricas de vazão e precipitação via satélite para 3 bacias do Sistema Interligado Nacional (SIN). Para estas, foi implementada a técnica SMAP/ONS e feita a calibração do modelo conforme é feito no processo de previsão de vazões e geração de cenários do ONS para os períodos de teste com o horizonte de previsão utilizado para teste sendo de 14 dias após treinamento dos modelos. Foram também implementados modelos de séries temporais *fuzzy* para as mesmas 3 bacias e os resultados das previsões foram comparados. As séries temporais *fuzzy* apresentaram bons resultados, superando a capacidade de previsão do modelo SMAP/ONS como é utilizado atualmente em vários casos.

Como um produto gerado através deste trabalho de pesquisa, está sendo desenvolvida também uma pequena aplicação com interface gráfica que permite ao usuário escolher dentre as técnicas utilizadas neste estudo e bacias para gerar previsões atualizadas com os dados mais recentes das bacias do SIN

disponibilizados pelo ONS através do sistema SINTEGRE. O restante deste trabalho está dividido da seguinte forma, as seções II e III apresentam brevemente uma revisão sobre as técnicas utilizadas, a seção IV apresenta as simulações computacionais elaboradas e os resultados obtidos para os casos de estudo propostos e a seção V discorre brevemente sobre as conclusões obtidas neste estudo e propostas de trabalhos futuros.

## II. THE SMAP MODEL (SOIL MOISTURE ACCOUNTING PROCEDURE)

O modelo SMAP é um modelo determinístico de simulação hidrológica de transformação chuva-vazão, o qual procura simular o ciclo da água em uma bacia hidrográfica. O SMAP foi desenvolvido na década de 80 por Lopes et al. [11].

Os dados de entrada do modelo SMAP são os totais diários de precipitação, observados na etapa de calibração e aquecimento do modelo e previstos para etapas de previsão de vazão. Os totais diários de evapotranspiração potencial ( $Ep_{(t)}$ ) e as vazões médias diárias observadas ( $Q_{obs_{(t)}}$ ) são calculados a partir de equações do modelo. Com os valores diários de precipitação observados em postos pluviométricos, o modelo calcula o total diário de precipitação média da bacia ( $Pb_{(t)}$ ) ponderando a precipitação observada de cada estação pelos coeficientes ( $ke$ ), de acordo com as equações (1) e (2):

$$Pb_{(t)} = P1_{(t)} \times ke_1 + P2_{(t)} \times ke_2 + P3_{(t)} \times ke_3 + \dots + Pn_{(t)} \times ke_n \quad (1)$$

$$ke_1 + ke_2 + ke_3 + \dots + ke_n = 1 \quad (2)$$

Onde:

**Pb<sub>(t)</sub>**: precipitação média observada na bacia, no instante de tempo  $t$  (mm/dia);

**P1<sub>(t)</sub>; P2<sub>(t)</sub>; ...; Pn<sub>(t)</sub>**: precipitação observada nos postos pluviométricos considerados na bacia;

**ke<sub>1</sub>; ke<sub>2</sub>; ...; ke<sub>n</sub>**: coeficientes de representação espacial de cada posto pluviométrico.

Após essa fase, o modelo calcula a precipitação considerada como representativa do dia  $t$  ( $Pd_{(t)}$ ), sendo esta composta por uma ponderação de precipitações médias observadas de diferentes tempos e representada pela equação (3):

$$Pd_{(t)} = Pb_{(t-n)} \times kt_{(-n)} + Pb_{(t-n+1)} \times kt_{(-n+1)} + \dots + Pb_{(t)} \times kt_{(0)} + Pb_{(t+1)} \times kt_{(+1)} + Pb_{(t+2)} \times kt_{(+2)} \quad (3)$$

Onde:

**Pd<sub>(t)</sub>**: precipitação representativa do instante de tempo  $t$  (mm/dia);

**kt<sub>(-n)</sub>; kt<sub>(-n+1)</sub>; kt<sub>(0)</sub>; kt<sub>(+1)</sub>; kt<sub>(+2)</sub>**: coeficientes de representação temporal.

O valor de  $Pd_{(t)}$  é multiplicado pelo fator  $Pcof$ , que tem a função de ajustar o volume de precipitação na bacia para garantir o equilíbrio hídrico desta, vide equação (4).

$$P_{(t)} = Pd_{(t)} \times Pcof \quad (4)$$

Onde:

**P<sub>(t)</sub>**: precipitação média na bacia no instante de tempo  $t$  considerado pelo modelo (mm/dia);

**Pcof**: coeficiente de ajuste de precipitação.

O modelo SMAP/ONS diário pode ser representado por quatro reservatórios[1], sendo as variáveis de estado de cada um dos reservatórios atualizadas a cada instante de tempo, de acordo com as equações (5), (6), (7) e (8).

$$Rsolo_{(t)} = \text{Mín} \left\{ Rsolo_{(t-1)} + P_{(t)} - Es_{(t)} - Er_{(t)} - Rec_{(t)}, Str \right\} \quad (5)$$

$$Rsub_{(t)} = Rsub_{(t-1)} + Rec_{(t)} - Eb_{(t)} \quad (6)$$

$$Rsup_{(t)} = Rsup_{(t-1)} + Es_{(t)} - Marg_{(t)} - Ed_{(t)} - Ed3_{(t)} + Máx \left\{ 0, [(Rsolo_{(t-1)} + P_{(t)}) - Es_{(t)} - Er_{(t)} - Rec_{(t)} - Str] \right\} \quad (7)$$

$$Rsup2_{(t)} = Rsup2_{(t-1)} + Marg_{(t)} - Ed2_{(t)} - Emarg_{(t)} \quad (8)$$

Onde:

**Rsolo<sub>(t)</sub>**: reservatório do solo no instante de tempo  $t$  (mm);

**Rsub<sub>(t)</sub>**: reservatório subterrâneo no instante de tempo  $t$  (mm);

**Rsup<sub>(t)</sub>**: reservatório da superfície no instante de tempo  $t$  (mm);

**Rsup2<sub>(t)</sub>**: reservatório da superfície/planície no instante de tempo  $t$  (mm);

**P<sub>(t)</sub>**: precipitação média na bacia, a ser considerada pelo modelo no instante de tempo  $t$  (mm);

**Es<sub>(t)</sub>**: escoamento para o reservatório de superfície no instante de tempo  $t$  (mm);

**Er<sub>(t)</sub>**: evapotranspiração real do solo no instante de tempo  $t$  (mm);

**Rec<sub>(t)</sub>**: recarga subterrânea no instante de tempo  $t$  (mm);

**Eb<sub>(t)</sub>**: escoamento básico, proveniente do reservatório subterrâneo, no instante de tempo  $t$  (mm);

**Marg<sub>(t)</sub>**: extravasamento pelas margens no instante de tempo  $t$  (mm);

**Emarg**: evaporação da planície de inundação (mm);

**Ed<sub>(t)</sub>**: escoamento superficial, proveniente do reservatório da superfície, no instante de tempo  $t$  (mm), para vazões de pequeno e médio porte;

**Ed2<sub>(t)</sub>**: escoamento superficial, proveniente do reservatório da superfície/planície, no instante de tempo  $t$  (mm);

**Ed3<sub>(t)</sub>**: escoamento superficial, proveniente do reservatório da superfície, no instante de tempo  $t$  (mm), para vazões de grande porte;

**Str**: capacidade de saturação do solo (mm);

**t**: instante de tempo (no atual estudo: diário).

Com base nos valores de escoamento dos reservatórios ( $R_{solo}$ ), ( $R_{sub}$ ), ( $R_{sup}$ ), ( $R_{sup2}$ ) e na área de drenagem da bacia em estudo é possível determinar a vazão total no instante de tempo  $t$  através da equação (9). A divisão pelo fator 86,4 tem por objetivo a mudança da unidade de tempo.

$$Q_{calc(t)} = \frac{(Ed_{(t)} + Ed2_{(t)} + Ed3_{(t)} + Eb_{(t)}) \times Ad}{86,4} \quad (9)$$

Onde:

**Qcalc(t)**: vazão total calculada pelo modelo no instante de tempo  $t$  ( $m^3/s$ );

**Ad**: área de drenagem da bacia considerada ( $km^2$ ).

A otimização do SMAP consiste no ajuste dos parâmetros do modelo, sendo estes: (a) coeficientes de pluviosidade espacial; (b) escoamento subterrâneo inicial; (c) escoamento de superfície inicial. O objetivo é produzir uma resposta de vazão calculada o mais próxima possível da vazão observada no período de assimilação. O período de assimilação considerado nesse trabalho como 30 dias, tem como intuito calibrar o modelo hidrográfico nos dias que antecedem a previsão. Para este artigo, foi utilizada a metodologia de otimização bioinspirada Bat Algorithm (BA)-2010, que é a técnica atualmente utilizada pelo ONS na otimização do modelo SMAP. A metodologia SMAP/ONS associada a otimização via BA neste trabalho foi implementada em python.

#### A. Bat Algorithm - BA

O “Bat Algorithm”, proposto por Yang [12], é inspirado no processo de ecolocalização dos morcegos, no qual os morcegos emitem pulsos de alta frequência para encontrar e diferenciar obstáculos de diferentes tamanhos e, assim, capturar suas presas. Sendo assim, foi desenvolvida uma analogia matemática a este comportamento para resolução de problemas de otimização. O controle da exploração (busca global) e intensificação (busca local) é feito através dos parâmetros amplitude ( $A$ ) e frequência ( $r$ ), respectivamente, onde ambos são alterados no decorrer do processo iterativo.

O pseudocódigo da metodologia proposta por Yang é exibido no algoritmo (1).

### III. FUZZY TIME SERIES

*Fuzzy Time Series* (FTS), assim como modelos baseados em lógica *fuzzy* são capazes de modelar de maneira robusta as incertezas, sendo capazes de desenvolver sistemas de inferência bastante assertivos. Em modelos FTS, séries temporais convencionais  $Y$ , compostas de observações reais  $Y_t$  são transformadas e passam a ser representadas por conjuntos *fuzzy*. O universo de discurso é obtido através da amplitude dos valores observados na série temporal convencional. Para a série temporal convencional  $Y$ , por exemplo, a faixa de valores observados será transformada em um universo de discurso  $\mathcal{U} = u_1, u_2, \dots, u_k$  no qual  $u_k$  representa os intervalos das partições dentro desse universo. Após a divisão do universo de discurso em subintervalos  $u_k$ , é feita então uma associação

---

#### Algorithm 1: Pseudocódigo Bat Algorithm (BA).

---

```

1 Inicializar os parâmetros:  $n, \alpha, \lambda$ 
2 Inicialização das soluções:  $X_i (i = 1, 2, 3, \dots, n)$ 
3 Avaliação das soluções:  $f(X_i)$ 
4 Atualização da melhor solução:  $X_*^t$ 
5 while não atingir o critério de parada, do
6   for  $i$  de 1 a  $n$  do
7      $fr_i = fr_{min} + (fr_{max} - fr_{min})\beta$ ,  $\beta \in [0, 1]$ 
8      $V_i^{t+1} = V_i^t + (X_i^t - X_*^t)fr_i$ 
9      $X_i^{t+1} = V_i^{t+1} + X_i^t$ 
10    if  $r_i > rand$ ,  $rand \in [0, 1]$ , then
11       $X_i^{t+1} = X_*^t + \varepsilon \cdot média(A_i^t)$ ,  $\varepsilon \in [-1, 1]$ 
12    end if
13    Verificar os limites de busca ( $X_i^{t+1}$ )
14    Avaliar a solução  $f(X_i^{t+1})$ 
15    if  $rand < A_i^t$  &  $f(X_i^{t+1}) \leq f(X_i^t)$ ,  $rand \in [0, 1]$ , then
16       $r_i^{t+1} = 1 - exp(-\lambda t)$ 
17       $A_i^{t+1} = \alpha A_i^t$ 
18    end if
19    Atualizar a melhor solução  $X_*^t$ 
20  end for
21 end while

```

---

desses intervalos com conjuntos *fuzzy*  $A_k$  através de uma função de pertinência  $\mu_f$  definida na equação 10.

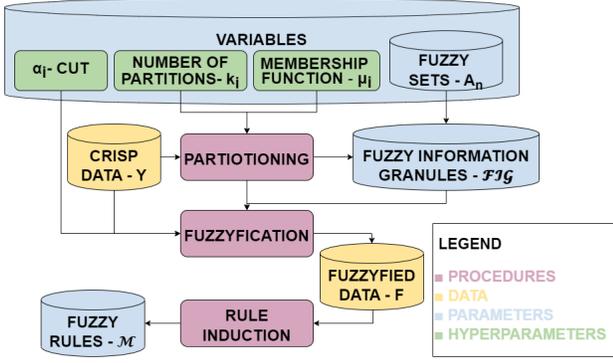
$$\mu_{f_{a_k}} : u_k \mapsto [0, 1] \quad (10)$$

Então, a série temporal *fuzzy*, composta pelas observações *fuzzyficadas*  $F_t$ , na qual  $F_t$  é composta por  $\mu_{f_{A_k}}(t)$  é considerada uma série temporal *fuzzy* em  $Y_t$ . Para os modelos deste trabalho, foram utilizadas funções de pertinência triangulares para  $\mu_{f_{A_k}}$ . A abordagem utilizada neste trabalho é baseada na abordagem de *Fuzzy Information Granular Fuzzy Time Series* proposta em [13]. Para a implementação dos modelos FTS foi utilizada a biblioteca pyFTS [14] através linguagem de programação python.

#### A. Fuzzy Information Granular Fuzzy Time Series - FIG-FTS

Fuzzy Information Granular Fuzzy Time Series (FIG-FTS) é um modelo de séries temporais nebulosas multivariável, com capacidade de tratamento de múltiplas entradas e múltiplas saídas. O modelo funciona como um *wrapper* que transforma as entradas multivariáveis da série temporal original em uma série temporal *fuzzyficada* univariável.

Dada uma série temporal nebulosa  $Y$   $n$ -variável, sendo as variáveis  $y_i$ , uma amostra temporal  $y_i(t)$  pode ser representada por  $Y_t = y_1(t), y_2(t), \dots, y_n(t)$ . Através do processo de *fuzzyficação*, são criadas variáveis linguísticas  $\mathcal{V}_i$  as quais possuem seus estados descritos pelos conjuntos *fuzzy*  $A_k$ . A série temporal nebulosa resultante do processo de *fuzificação*  $F$  possui pontos de dados  $f(t) \in F$  os quais representam uma sequência de grânulos de informação *fuzzyficada*  $\mathcal{G}_i$ .


 Fig. 1. Procedimento de Treinamento e Componentes *FIG-FTS* [15]

A Figura 1 exemplifica o processo de treinamento do modelo e seus componentes, assim como os parâmetros e hiperparâmetros associados. No procedimento de treinamento são feitos os passos de particionamento do universo de discurso das *features*, *fuzzyficação* das observações e indução de regras para criar um modelo de regras *fuzzy*  $\mathcal{M}$ . O particionamento de cada variável na etapa de treinamento é feito de maneira separada, sendo possível definir um número de partições, uma função de pertinência e um parâmetro  $\alpha$  diferente para cada *feature*. O parâmetro  $\alpha$  representa o limiar inferior de pertinência considerado no processo de *fuzzyficação*. A variável linguística global representada por *FIG* é a união de todos os grânulos de informação nebulosa  $\mathcal{G}_j$  os quais são por sua vez, a combinação de um conjunto *fuzzy* para cada variável de modo que  $\mathcal{G}_i = \{A_k^{V_i}\}, \forall V_i \in \mathcal{V}$  e a função de pertinência é dada pela relação  $\mu_f \mathcal{G}_i = \cap \mu_f A_k^{V_i}$  sendo  $\cap$  a T-norma mínima. Através da utilização dos grânulos *FIG*, a série temporal multivariável é transformada em uma série univariável na qual os grânulos são a única *feature* do modelo. Através desse processo, a observação temporal  $y(t)$  passa a ser representada por conjunto de grânulos  $\mathcal{G}$  de *FIG*.

O processo de previsão tem como objetivo gerar uma estimativa  $\hat{y}(t+1)$  para cada variável de entrada dado um conjunto de entrada  $Y$ , através do uso da variável linguística *FIG* e o conjunto de regras  $q$  do modelo  $\mathcal{M}$ . Para isso, este processo é composto de três etapas principais sendo estas a *fuzzyficação*, o pareamento das regras e a *defuzzyficação*. Na etapa de *fuzzyficação* é feita conversão dos valores do conjunto de entrada  $Y$  para valores *fuzzyficados*. Com pontos de dados *fuzzy*, é executada a etapa de pareamento de regras para encontrar  $k$  regras correspondentes. Esse processo é feito através do cálculo da distancia entre os valores de entrada *fuzzyficados* e os pontos centrais  $mp_{\mathcal{M}}$ . O ultimo passo do processo de previsão é a etapa de *defuzzyficação* dos valores obtidos após a identificação das  $k$  regras correspondentes através da média ponderada dos pontos centrais pela pertinência de de cada regra selecionada como na equação 11.

$$\hat{y}(t+1) = \frac{\sum_q^k \mu_f q \cdot mp_q}{\sum_q^k \mu_f q} \quad (11)$$

## IV. RESULTADOS

As Bacias hidrográficas utilizadas para a avaliação das metodologias foram as bacias de Corumbá I, Emborcação e Nova Ponte. Os dados de precipitação via satélite e vazão foram obtidos através do portal SINTEGRE - ONS e são referentes ao período de 31/08/2019 até 07/11/2021. A base de dados foi dividida em dois períodos, um período de dois anos para treinamento do modelo FTS e 70 dias divididos em 5 janelas de previsão para os testes de 14 dias cada. A metodologia de comparação foi feita através da metodologia de janela deslizante conforme descrito na figura 2. Nos períodos de teste, foram utilizados os 30 dias prévios de cada janela para a assimilação do modelo SMAP/ONS através do *Bat Algorithm* e os parâmetros utilizados foram obtidos através do SINTEGRE.

As bacias utilizadas já foram alvo de estudos anteriores com relação a capacidade do SMAP/ONS associado ao BA [3].

Todos os gráficos apresentados nesta seção estão disponíveis em maior resolução e com interface iterativa em [tiagoalvesuffj.github.io](https://tiagoalvesuffj.github.io).

A métrica de avaliação utilizada para ambas as abordagens do problema de previsão de vazão é o erro absoluto percentual médio MAPE (Mean Absolute Percentage Error), vide equação (12).

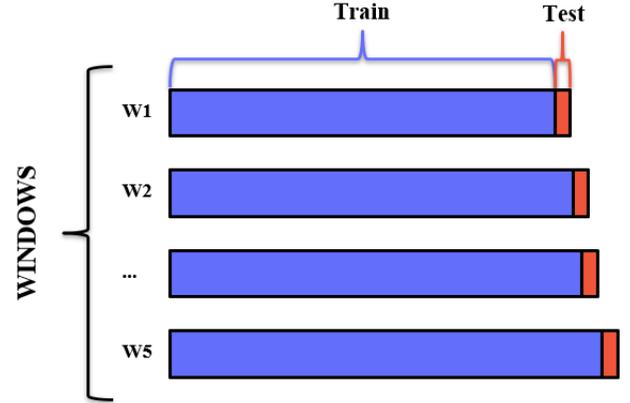


Fig. 2. Metodologia de Janela Deslizante.

$$MAPE(\%) = \frac{\sum_{i=1}^N \left| \frac{Q_{calc} - Q_{obs}}{Q_{obs}} \right|}{N} \times 100 \quad (12)$$

### A. Corumbá I

A usina hidroelétrica de Corumbá I (UHE) começou a ser construída em 1982 e iniciou sua operação em 1994. A UHE Corumbá I conta com 375 MW de potência instalada distribuída pelas suas 3 unidades geradoras. A Usina foi construída no rio Corumbá, a cerca de 30 km da cidade de Caldas Novas, GO. A barragem da UHE Corumbá I possui cerca de 540 m de comprimento de crista e 90 m de altura máxima. Seu reservatório possui cerca de 65 km<sup>2</sup> de área inundada e

TABELA I  
HIPERPARÂMETROS UTILIZADOS PARA AS METODOLOGIAS

Algorithm	Parameter	Value
BA	A	0.5
	r	0.1
	$fr_{min}$	0
	$fr_{max}$	2
	$\lambda$	0.9
	$\alpha$	0.9
FIG-FTS	$\alpha$ -cut	0.0
	$\mu_f$	Triangular
	k - Vazão	800
	k - all	50

capacidade máxima de acumulação aproximadamente de 1,03 km<sup>3</sup>.

O gráfico da Figura 3 apresenta a comparação do valor de MAPE para as cinco janelas de previsão estudadas para a bacia de Corumbá I. Em quatro dos cinco períodos avaliados, a metodologia de séries temporais nebulosas obteve um desempenho melhor, com percentuais de erro com diferenças significantes nos períodos 1, 2 e 3. Para o período 0 e o período 5 as diferenças entre os valores de erro foram menores que 1%, com o método FTS obtendo melhores resultados no primeiro período e SMAP/ONS obtendo melhor resultado no ultimo. Com relação a média de todo o período de teste, o modelo FTS obteve melhor desempenho geral com média de 16,46% quando comparado à média do SMAP/ONS de 22,23%.

No Hidrograma apresentado na figura 4 são apresentados os valores de vazão observada, precipitação, vazão prevista pelo modelo SMAP/ONS e vazão prevista pelo modelo *FIG-FTS* para a bacia de Corumbá I. É possível observar que para os casos em que há grande variação da vazão no período de previsão ambos os modelos tendem a obter valores da métrica de erro mais altos. É notável também que, o modelo SMAP/ONS apresenta uma maior sensibilidade para eventos de precipitação mais elevados ocasionando aumentos significativos nas vazões previstas nos dias subsequentes.

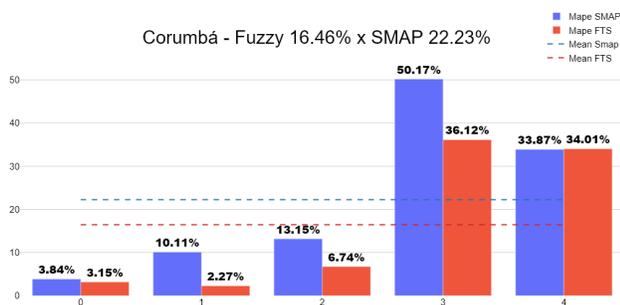


Fig. 3. Comparação de erro MAPE para as 5 Janelas de previsão - Corumbá I

### B. Emborcação

A usina hidrelétrica (UHE) de Emborcação, começou a ser construída em 1977 e iniciou sua operação em 1982. A

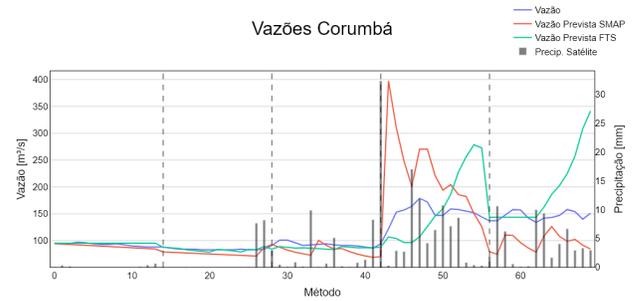


Fig. 4. Hidrograma com Vazão Efetuada e Previsões das Metodologias - Corumbá I

usina iniciou sua operação contando com 2 unidades geradoras de 298 MW de potência unitária e em 1983, passou a ter mais 2 unidades geradoras de mesma potência. Construída em Araguari, MG, no Rio Paranaíba, possui 1.192 MW potência instalada disponibilizada nas suas 4 unidades geradoras. A barragem da UHE Emborcação se estende por 1.502 m de comprimento de crista e possui 158 m de altura máxima. Seu reservatório possui cerca de 477 km<sup>2</sup> de área inundada e capacidade máxima de acumulação de aproximadamente de 17,72 km<sup>3</sup>.

O gráfico da Figura 5 apresenta a comparação do valor de MAPE para as cinco janelas de previsão estudadas para a bacia de Emborcação. Para esta bacia, o método FTS obteve melhor desempenho em todas as 5 janelas de previsão estudadas, com grande discrepância nos valores de erro MAPE para 4 dos cinco períodos. Para a janela de previsão número 2, a qual as metodologias tiveram a métrica de erro mais próxima ainda há uma diferença absoluta de mais de 1%. Com relação aos valores de erro médio entre todo o período, o caso da bacia de Emborcação foi o que teve a maior diferença com a média da metodologia FTS de 12,02% e a média do SMAP/ONS de 40,96%.

No Hidrograma da Figura 6 são apresentados os valores de vazão observada, precipitação, vazão prevista pelo modelo SMAP/ONS e vazão prevista pelo modelo *FIG-FTS* para a bacia de Emborcação. Assim como nas outras bacias, é possível observar que para os casos em que há grande variação da vazão no período de previsão ambos os modelos tendem a obter valores da métrica de erro mais altos. Novamente, é possível observar que o modelo SMAP/ONS apresenta uma maior sensibilidade para eventos de precipitação mais elevados ocasionando aumentos significativos nas vazões previstas nos dias subsequentes.

### C. Nova Ponte

A usina hidroelétrica de Nova Ponte (UHE) começou a ser construída em 1987 e iniciou sua operação em 1994. Esta conta com 510 MW de potência instalada distribuída pelas suas 3 unidades geradoras. Construída no rio Araguari no município de Nova Ponte. A barragem da UHE Nova Ponte possui cerca de 1.620 m de comprimento de crista e 142 m de altura máxima. Seu reservatório possui cerca de 443

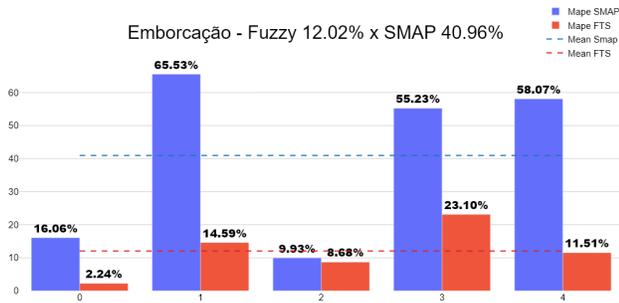


Fig. 5. Comparação de erro MAPE para as 5 Janelas de previsão - Emborcação

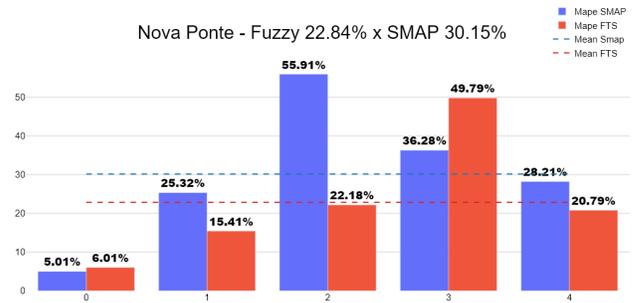


Fig. 7. Comparação de erro MAPE para as 5 Janelas de previsão - Nova Ponte



Fig. 6. Hidrograma com Vazão Efetuada e Previsões das Metodologias - Emborcação

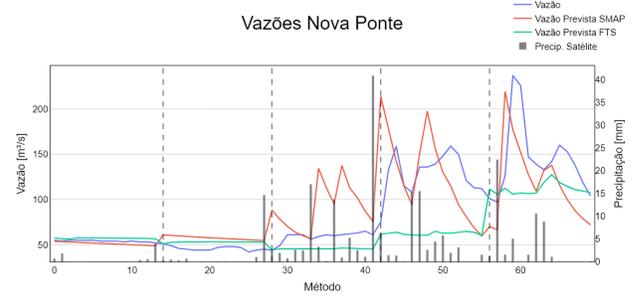


Fig. 8. Hidrograma com Vazão Efetuada e Previsões das Metodologias - Nova Ponte

km<sup>2</sup> de área inundada e capacidade máxima de acumulação aproximadamente de 12,79 km<sup>3</sup>.

O gráfico da Figura 7 apresenta a comparação do valor de MAPE para as cinco janelas de previsão estudadas para a bacia de Nova Ponte. No caso de estudo de Nova Ponte, o método FTS obteve melhor desempenho em 3 das 5 janelas de previsão estudadas. Na janela de previsão 3, a metodologia SMAP/ONS obteve uma métrica de erro com diferença absoluta para a métrica do FTS de mais de 10% sendo essa a maior discrepância em que o SMAP/ONS desempenhou melhor. Nova Ponte também foi a bacia em que o método FTS obteve o pior desempenho dos 3 casos estudados com média de erro de 22,84% em todo o período de teste. O SMAP/ONS obteve métrica média de erro de 30,15% em todo o período.

No Hidrograma presente na Figura 8 são apresentados os valores de vazão observada, precipitação, vazão prevista pelo modelo SMAP/ONS e vazão prevista pelo modelo *FIG*-FTS para a bacia de Nova Ponte. Assim como observado para Corumbá I e Emborcação, em Nova Ponte também há aumento nos valores de MAPE para ambos os modelos nos casos em que há grande variação da vazão no período de previsão. Nova Ponte foi o caso em que houve a maior sensibilidade com relação a eventos de grande precipitação resultando em grande variação nas vazões previstas pelo modelo SMAP/ONS

#### D. Análise conjunta das 3 Bacias

Para uma análise mais abrangente, os casos das 3 bacias foram analisados também de forma conjunta para que fossem abstraídas características das bacias e que os modelos fossem

comparados de maneira mais generalizada para o problema de previsão de vazão.

A Figura 9 apresenta a comparação em gráficos de barras das médias da métrica de erro MAPE para as bacias de Corumbá I, Emborcação e Nova Ponte, assim como a média geral dos métodos SMAP/ONS e *FIG*-FTS em linhas tracejadas. É possível notar que a metodologia *FIG*-FTS obteve menores valores de MAPE médios para as 3 Bacias avaliadas neste trabalho e a diferença absoluta entre as médias foi de aproximadamente 14%. A maior diferença entre médias das metodologias ocorreu para o caso de estudo da Bacia de Emborcação em qual o *FIG*-FTS apresentou o melhor desempenho dentre os três casos e o SMAP/ONS apresentou o pior desempenho. É também notável que o caso de maior erro da metodologia *FIG*-FTS apresentou valor com diferença absoluta de menos de 1% para o caso de menor métrica de erro do SMAP/ONS.

O gráfico de boxplot da Figura 10 apresenta uma visualização da distribuição dos valores de MAPE para as duas metodologias estudadas. Neste, é possível notar que os valores de MAPE para *FIG*-FTS possuem menor dispersão que os valores do SMAP/ONS além de uma mediana mais baixa. Ao comparar os valores de máxima métrica de erro MAPE para ambas as metodologias o *FIG*-FTS apresenta melhor desempenho tendo no pior caso um erro MAPE de 36,12% enquanto o SMAP/ONS obteve erro MAPE de 65,53% para seu pior caso. Para os valores de maior acerto das metodologias o *FIG*-FTS também obtém a métrica mais baixa de 2,24% quando comparada à 3,84% do SMAP/ONS.

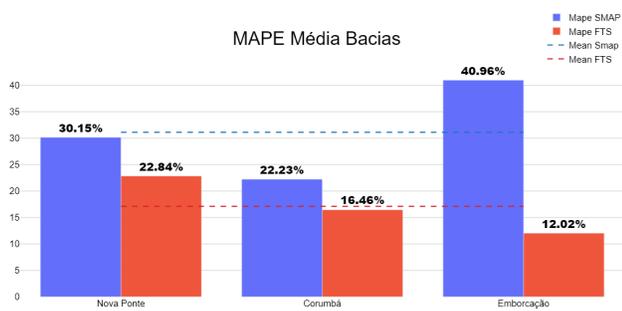


Fig. 9. Médias de erro das Metodologias entre as Bacias Estudadas

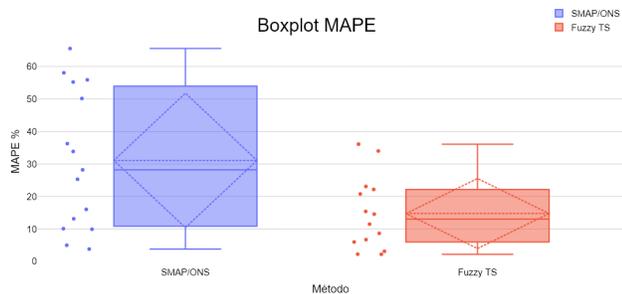


Fig. 10. Boxplot comparativo de erro entre SMAP/ONS e FTS

## V. CONCLUSÃO

A partir dos dados apresentados no presente estudo é possível concluir que a abordagem baseada em séries temporais nebulosas proposta por este trabalho apresentou resultados competitivos, sendo capaz de obter valores de MAPE consideravelmente melhores que a metodologia atualmente empregada pelo ONS na previsão de vazões das bacias de Corumbá I, Emborcação e Nova Ponte, para previsões em janelas de 14 dias. Como continuação do trabalho elaborado, faz-se necessário, no entanto, um aprofundamento no estudo de modo a verificar a comparação das metodologias em mais bacias do SIN e em mais períodos de previsão. Também é possível buscar melhorias nos hiperparâmetros da metodologia FTS através de uma busca em grade. Outras possíveis abordagens seriam as de inclusão de novas variáveis como a temperatura média na região da bacia ou alguma métrica de evaporação superficial como entrada do modelo FTS.

## AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, ao INERGE, FAPEMIG, CAPES e CNPq pelo suporte financeiro para desenvolvimento deste estudo.

## REFERENCES

[1] ONS, *Programa Computacional SMAP - Manual de metodologia*. Operador Nacional do Sistema Elétrico, 2022. Versão 4.0.0.

[2] ONS, *Programa Computacional SMAP - Manual do usuário*. Operador Nacional do Sistema Elétrico, 2022. Versão 4.0.0.

[3] L. A. Campos, “Aplicação de técnicas meta-heurísticas na calibração do modelo smap/ons,” *Faculdade de Engenharia, Universidade Federal de Juiz De Fora*, 2021.

[4] G. M. Maciel, V. A. Cabral, A. L. M. Marcato, I. C. S. Júnior, and L. D. M. Honorio, “Daily water flow forecasting via coupling between smap and deep learning,” *IEEE Access*, vol. 8, pp. 204660–204675, 2020.

[5] C. A. Severiano, P. C. d. L. e Silva, M. W. Cohen, and F. G. Guimarães, “Evolving fuzzy time series for spatio-temporal forecasting in renewable energy systems,” *Renewable Energy*, vol. 171, pp. 764–783, 2021.

[6] C. A. Severiano, P. C. Silva, H. J. Sadaei, and F. G. Guimarães, “Very short-term solar forecasting using fuzzy time series,” in *2017 IEEE international conference on fuzzy systems (FUZZ-IEEE)*, pp. 1–6, IEEE, 2017.

[7] H. J. Sadaei, F. G. Guimaraes, C. J. da Silva, M. H. Lee, and T. Eslami, “Short-term load forecasting method based on fuzzy time series, seasonality and long memory process,” *International Journal of Approximate Reasoning*, vol. 83, pp. 196–217, 2017.

[8] D. Leite, P. Costa, and F. Gomide, “Evolving granular neural networks from fuzzy data streams,” *Neural Networks*, vol. 38, pp. 1–16, 2013.

[9] D. Leite, *Evolving granular systems*. PhD thesis, 2012.

[10] F. M. Talarposhti, H. J. Sadaei, R. Enayatifar, F. G. Guimarães, M. Mahmud, and T. Eslami, “Stock market forecasting by using a hybrid model of exponential fuzzy time series,” *International Journal of Approximate Reasoning*, vol. 70, pp. 79–98, 2016.

[11] J. E. G. Lopes, B. P. F. Braga, and J. G. L. Conejo, “A simplified hydrologic model,” *Water Resources Publication, Littleton, Colorado, USA*, pp. 167–176, 1982.

[12] X. Yang, “A new metaheuristic bat-inspired algorithm,” *Nature Inspired Cooperative Strategies for Optimization (NISCO 2010) (Eds. J. R. Gonzales et al.)*, *Studies in Computational Intelligence, Springer Berlin*, 284, Springer, 65-74, 2010. Acessado: 2019-04-11.

[13] P. C. de Lima e Silva, C. A. Severiano Jr, M. A. Alves, M. W. Cohen, and F. G. Guimarães, “A new granular approach for multivariate forecasting,” in *Computational Neuroscience: Second Latin American Workshop, LAWCN 2019, São João Del-Rei, Brazil, September 18–20, 2019, Proceedings*, pp. 41–58, Springer, 2019.

[14] P. C. Silva, P. Lucas, H. Sadaei, and F. Guimarães, “pyfts: Fuzzy time series for python,” *Belo Horizonte*, 2018.

[15] P. C. de Lima et al., *Scalable models for probabilistic forecasting with fuzzy time series*. PhD thesis, Universidade Federal de Minas Gerais, 2019.