

PREVISÃO DE VAZÕES PARA BACIAS DO SISTEMA INTERLIGADO BRASILEIRO UTILIZANDO MODELO GAUSSIANO MULTIVARIÁVEL EVOLUTIVO APRIMORADO

Marcos V. G. Rocha

Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n - Campus Universitário, Juiz de Fora, MG
marcosv.jf@gmail.com

Tiago R. Alves

Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n - Campus Universitário, Juiz de Fora, MG
tralvescontato@gmail.com

Ivo C. S. Junior

Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora
Rua José Lourenço Kelmer, s/n - Campus Universitário, Juiz de Fora, MG
ivo.junior@ufjf.br

RESUMO

Neste trabalho, é apresentado um novo modelo de previsão aplicado ao contexto de previsão de vazão em bacias hidrográficas brasileiras, denominado *Novel Set-Membership evolving Multivariable Gaussian* (NSM-eMG). O modelo ajusta a taxa de aprendizado em função do erro durante o processo de aprendizagem, buscando melhorar o desempenho e aumentar a adaptabilidade. Para validar sua eficácia, foram conduzidos testes experimentais com dados reais de duas bacias hidrográficas relevantes para a operação hidrelétrica brasileira (Furnas e Itaipu). A avaliação considerou métricas de erro e o número de regras nos modelos evolutivos. Os resultados foram comparados com o modelo de referência utilizado pelo Operador Nacional do Sistema Elétrico (ONS), o *Soil Moisture Accounting Procedure* (SMAP). O modelo proposto obteve desempenho superior em todos os cenários avaliados, com redução significativa de erro (~70%) e viés. Esses resultados sugerem que a abordagem é flexível e promissora para a previsão de vazão em bacias hidrográficas.

PALAVRAS CHAVE. Previsão de vazão. Modelos evolutivos. Mecanismo adaptativo.

Tópicos: Inteligência computacional aplicada. Gestão de recursos hídricos.

ABSTRACT

This work presents a new forecasting model applied to streamflow prediction in Brazilian watersheds, called *Novel Set-Membership evolving Multivariable Gaussian* (NSM-eMG). The model adjusts the learning rate based on error during the training process, aiming to improve performance and increase adaptability. To validate its effectiveness, experimental tests were conducted using real data from two watersheds relevant to Brazil's hydroelectric operations (Furnas and Itaipu). The evaluation considered error metrics and the number of rules in the evolving models.

Results were compared with the reference model used by the National Electric System Operator (ONS), the Soil Moisture Accounting Procedure (SMAP). The proposed model outperformed SMAP in all scenarios, with significant reductions in both error ($\sim 70\%$) and bias. These results suggest that the proposed approach is flexible and promising for streamflow forecasting in watersheds.

KEYWORDS. Streamflow forecasting. evolving models. Adaptive mechanism.

Topics: Applied computational intelligence. Water resources management.

1. Introdução

A previsão de vazões afluentes desempenha um papel estratégico em diversas áreas, como o gerenciamento de enchentes, a alocação de recursos hídricos, a proteção ambiental e, especialmente no contexto brasileiro, o planejamento energético. Em países como o Brasil, onde a geração hidrelétrica é predominante, lidar adequadamente com a incerteza da vazão futura é essencial para garantir a segurança e a eficiência do sistema elétrico [Treistman et al., 2023].

Com a crescente integração de fontes renováveis à matriz elétrica, surgem novos desafios para o setor, entre eles o aprimoramento de modelos de geração de cenários sintéticos de vazão. Esses cenários são fundamentais não apenas para a previsão da disponibilidade hídrica, mas também para embasar decisões estratégicas de médio e longo prazo [Treistman et al., 2023].

Além disso, o aumento da demanda por água e os efeitos das mudanças climáticas intensificam a necessidade de um planejamento e gestão mais eficientes dos recursos hídricos, especialmente em grandes bacias hidrográficas. Aspectos como abastecimento, geração de energia e preservação ambiental dependem diretamente de previsões confiáveis de vazão [Wang et al., 2023].

No entanto, prever o comportamento da vazão não é trivial. Fatores como distribuições caóticas, padrões sazonais e interações complexas entre os elementos da bacia tornam a tarefa desafiadora [Khozani et al., 2024]. Diante desse cenário, o desenvolvimento de modelos preditivos robustos e adaptativos torna-se fundamental para garantir a sustentabilidade hídrica e energética do país.

Nesse sentido, as técnicas de inteligência computacional têm desempenhado um papel proeminente na abordagem desses desafios. Algoritmos de aprendizado de máquina, redes neurais artificiais, sistemas fuzzy e outras abordagens baseadas em inteligência computacional têm se demonstrado eficazes na previsão de séries temporais, o que pode ser aproveitado na previsão de geração de energia hidrelétrica. Tais técnicas possuem a capacidade de lidar com relações não-lineares, modelar dados imprecisos e se adaptar a mudanças, o que é valioso neste contexto.

O modelo chuva-vazão *Soil Moisture Accounting Procedure* (SMAP) é uma das ferramentas utilizadas pelo Operador Nacional do Sistema Elétrico (ONS) para gerar previsões de vazão em bacias hidrográficas brasileiras. Trata-se de um modelo determinístico e centralizado, que influencia diretamente o planejamento da operação do sistema elétrico e a dinâmica do mercado de energia brasileiro [Maciel et al., 2020].

Este artigo explora a importância da previsão de vazão e destaca a relevância do uso de modelos evolutivos aprimorados na superação das limitações dos modelos determinísticos tradicionais. Este trabalho propõe a aplicação de um mecanismo adaptativo *Novel Set-Membership evolving* (NSM) ao modelo *evolving Multivariable Gaussian* (eMG) para criar um novo modelo, denominado *Novel Set-Membership evolving Multivariable Gaussian* (NSM-eMG), com foco na previsão de vazão. Esse novo modelo apresenta a característica de limitar o aumento do erro durante o processo de aprendizagem do modelo evolutivo, visando melhorar sua precisão, bem como

aumentar sua adaptabilidade ao mesmo tempo em que mantém a robustez em comparação com o modelo original.

As principais contribuições deste trabalho estão descritas a seguir:

- É introduzido um modelo inédito, chamado NSM-eMG, que utiliza uma modificação do conceito *Set-Membership* (SM) proposto em [Rocha et al., 2021] para ajustar a taxa de aprendizado do modelo eMG.
- Foram utilizados dados reais de duas bacias hidrográficas relevantes na operação hidrelétrica brasileira (Furnas e Itaipu), para avaliar os resultados em termos de métricas de erro e do número de regras dos modelos evolutivos.
- Os resultados são comparados com os obtidos através de outros modelos sugeridos na literatura: o modelo original *evolving Multivariable Gaussian* (eMG) [Lemos et al., 2010], o modelo *Fuzzy Information Granular Fuzzy Time Series* (FIG-FTS) [Alves et al., 2023] e o modelo referência *Soil Moisture Accounting Procedure* (SMAP/ONS).

As Seções subsequentes estão organizadas da seguinte forma: A Seção 2 apresenta a formulação do problema. A Seção 3 introduz o modelo eMG e apresenta o modelo NSM-eMG proposto neste trabalho. A Seção 4 exhibe e discute os resultados experimentais. E por fim, a Seção 5 apresenta as conclusões do trabalho.

2. Formulação do problema

No Brasil, a matriz energética é fortemente dependente da geração hidrelétrica, tornando a previsão de vazões um fator estratégico para o planejamento energético em médio e longo prazo [Treistman et al., 2023]. O Operador Nacional do Sistema Elétrico (ONS), responsável pela gestão do Sistema Interligado Nacional (SIN), realiza previsões baseadas em diversos fatores hidrológicos, como precipitação, evapotranspiração e umidade do solo [Maciel et al., 2020].

2.1. *Soil Moisture Accounting Procedure* (SMAP)

O modelo *Soil Moisture Accounting Procedure* (SMAP), desenvolvido por [Lopes et al., 1982], é uma abordagem determinística utilizada pelo Operador Nacional do Sistema Elétrico (ONS) para estimar componentes do balanço hídrico, como a umidade do solo, evapotranspiração e escoamento. Segundo [Maciel et al., 2020; Alves et al., 2023], as estimativas de vazão baseiam-se na precipitação e no comportamento de reservatórios conceituais.

O modelo representa o sistema hidrológico por meio de quatro reservatórios conceituais, cujos estados são atualizados a cada passo de tempo. A Figura 1 ilustra o esquema da metodologia SMAP.

A precipitação média na bacia, $P_b(t)$, é obtida como média ponderada dos valores observados nas estações pluviométricas:

$$P_b(t) = \sum_{k=1}^n P_k(t) k e_k \quad (1)$$

dado que:

$$\sum_{k=1}^n k e_k = 1 \quad (2)$$

Em seguida, calcula-se a média temporal ponderada, $P_d(t)$:




Figura 1: Diagrama do modelo SMAP [Alves et al., 2023].

$$P_d(t) = \sum_{k=m}^n P_b(t+k)kt_k \quad (3)$$

A precipitação efetiva considerada pelo modelo, $P(t)$, é:

$$P(t) = P_d(t)P_{cof} \quad (4)$$

Esta precipitação alimenta os reservatórios do SMAP (Figura 1), cuja interação determina os componentes de escoamento. A vazão total $Q_{calc}(t)$ [m³/s] é calculada por:

$$Q_{calc}(t) = \left(\frac{Ed1(t) + Ed2(t) + Ed3(t) + Eb(t)}{86,4} \right) Ad \quad (5)$$

onde $Ed1(t)$ representa o escoamento superficial direto (gerado quando a precipitação excede a capacidade de infiltração do solo), $Ed2(t)$ corresponde ao escoamento subsuperficial rápido (fluxo através da zona não-saturada do solo), $Ed3(t)$ é o escoamento superficial retardado (drenagem lenta das camadas superficiais do solo), $Eb(t)$ indica o escoamento de base (fluxo subterrâneo sustentado pelo lençol freático), Ad é a área de drenagem da bacia hidrográfica em km², e o fator 86,4 converte as unidades de mm/dia para m³/s. Para detalhes completos das equações dos reservatórios, consultar [Lopes et al., 1982; Maciel et al., 2020].

3. Novel Set-Membership evolving Multivariable Gaussian (NSM-eMG)

Nesta Seção é apresentado o modelo proposto neste artigo. Inicialmente, apresenta-se brevemente o modelo *evolving Multivariable Gaussian* (eMG) na Subseção 3.1. Em seguida, é apresentado o mecanismo adaptativo implementado no modelo: *Novel Set-Membership* (NSM), Subseção 3.2.

A incorporação do mecanismo adaptativo NSM ao modelo eMG resulta na concepção do modelo NSM-eMG. Essa modificação foi implementada com o objetivo de estender as funcionalidades do modelo eMG, oferecendo uma contribuição significativa ao escopo deste trabalho. Ao incorporar o NSM, busca-se proporcionar ao modelo uma maior adaptabilidade, ao mesmo tempo em que se almeja aprimorar sua capacidade preditiva.

3.1. evolving Multivariable Gaussian (eMG)

O eMG é um Sistema Fuzzy evolutivo que utiliza o conceito de aprendizagem participativa (*participatory learning* - PL) em seu processo de aprendizagem [Yager, 1990]. O PL é um mecanismo que produz conhecimento a partir dos dados como parte do processo de aprendizagem. Como resultado, a aprendizagem a partir de novos dados de entrada depende do que o sistema aprendeu e terá impacto na aprendizagem de entradas futuras. O modelo executa esse mecanismo adicionando ou excluindo uma regra, onde cada regra é uma estrutura de cluster. Sua estrutura de aprendizagem é apresentada na Figura 2.




Figura 2: Mecanismo de aprendizagem do modelo eMG. Adaptado de [Vieira et al., 2018].

Na Seção Apêndice A é apresentado o algoritmo com o roteiro simplificado do modelo eMG, introduzido primeiramente por [Lemos et al., 2010].

Conforme descrito em [Lemos et al., 2010], se, a cada passo, a medida de compatibilidade da observação atual estiver abaixo do limiar para todos os clusters (isto é, $\rho_i^k < T_\rho, \forall i = 1, \dots, c_k$), e o índice de excitação do cluster com maior compatibilidade ultrapassar o limiar (isto é, $a_i^k > T_a$ para $i = \arg \max_i \rho_i^k$), um novo cluster é criado. Caso contrário, o centro do cluster com maior compatibilidade é ajustado de acordo com a Equação 6.

$$v_i^{k+1} = v_i^k + G_i^k (x^k - v_i^k) \quad (6)$$

onde x^k é a entrada no instante k , v_i^k é o centro do cluster, para $i = 1, \dots, c^k$, e G_i^k é definido pela Equação 7.

$$G_i^k = \alpha (\rho_i^k)^{1-a_i^k} \quad (7)$$

onde $\alpha \in [0, 1]$ é a taxa de aprendizado, que controla o tamanho do passo das atualizações.

A análise empírica demonstrou que o desempenho do modelo pode ser significativamente afetado por pequenas variações em certos hiperparâmetros. Assim, este hiperparâmetro, α , foi esco-

lhido para ser atualizado por meio do mecanismo adaptativo proposto, com o objetivo de aprimorar o desempenho do modelo. A abordagem de aplicar técnicas de adaptação a hiperparâmetros que, de outro modo, permaneceriam constantes ao longo de todo processo, confere maior adaptabilidade ao modelo, dado que são atualizadas em função das medidas de erro.

3.2. Novel Set-Membership evolving Multivariable Gaussian (NSM-eMG)

Este trabalho introduz um novo modelo chamado *Novel Set-Membership evolving Multivariable Gaussian* (NSM-eMG), que incorpora o mecanismo adaptativo NSM à estrutura do eMG. O NSM é proposto neste trabalho, inspirado na estratégia de *Set-Membership* (SM), anteriormente utilizada em [Rocha et al., 2021]. Ele introduz uma estratégia de atualização para a taxa de aprendizado, α , que se adapta de acordo com a magnitude do erro normalizado $|\tilde{e}^k|$. Quando o erro excede um limiar pré-definido, $\bar{\gamma}$, a taxa de aprendizado é aumentada, sendo proporcional ao inverso da magnitude do erro, promovendo uma adaptação mais rápida. Caso contrário, ela é reduzida, também proporcionalmente ao inverso do erro, favorecendo a estabilidade. A Equação 8 representa o mecanismo adaptativo NSM.

$$\alpha^{k+1} = \begin{cases} 1 + \frac{\bar{\gamma}}{|\tilde{e}^k|}, & \text{se } |\tilde{e}^k| > \bar{\gamma} \\ 1 - \frac{\bar{\gamma}}{|\tilde{e}^k|}, & \text{caso contrário.} \end{cases} \quad (8)$$

Para não atingir valores inconsistentes, a taxa de aprendizado α é restringida dentro de limites válidos por meio de limites inferior (IL) e superior (SL) com $0 \leq IL < SL \leq 1$, sendo os valores truncados quando excedem esses limiares.

Essa estratégia adaptativa aprimora a capacidade de resposta do modelo a ambientes dinâmicos, permitindo que ele reaja rapidamente a erros significativos enquanto mantém a estabilidade quando a precisão da previsão é satisfatória. Como resultado, o modelo NSM-eMG torna-se particularmente adequado para aplicações que exigem tolerância a erros, autoajuste contínuo e desempenho robusto a longo prazo.

4. Resultados Experimentais

Para avaliar a eficácia do modelo proposto, o problema de previsão de vazão é abordado. Também é realizada uma comparação com o eMG original, utilizado como referência base entre os modelos fuzzy evolutivos. Além disso, dois modelos não evolutivos da literatura, SMAP/ONS e o *Fuzzy Information Granular Fuzzy Time Series* (FIG-FTS) [Alves et al., 2023], são incluídos para ampliar o escopo da comparação.

As simulações computacionais realizadas neste estudo seguem a metodologia apresentada em [Alves et al., 2023]. Duas bacias hidrográficas de importância estratégica para o SIN foram selecionadas para as simulações: Furnas e Itaipu.

O conjunto de dados é composto pelo valor de precipitação estimada por satélite e pela entrada natural da bacia. Os dados cobrem o período de amostragem de 31 de agosto de 2019 a 31 de dezembro de 2021, resultando em 854 amostras por bacia. Os dados de precipitação e de entrada foram obtidos no portal SINTEGRE/ONS [Operador Nacional do Sistema Elétrico (ONS), 2024]. Para realizar a previsão, os dados foram organizados de modo que o modelo previsse a saída no instante de tempo k com base em $n = 5$ saídas anteriores.

Além disso, seguindo a metodologia proposta no estudo mencionado, o conjunto de dados foi dividido em dois períodos distintos: um intervalo de dois anos para treinamento dos modelos de previsão e um intervalo de 70 dias para testes. A fase de teste foi estruturada em cinco janelas de validação, cada uma com 14 dias. A avaliação seguiu a abordagem de janela deslizante, conforme ilustrado na Figura 3.




Figura 3: Esquema de validação com janela deslizante. Adaptado de [Alves et al., 2023].

Para avaliar a eficácia dos diferentes modelos de forma precisa, este trabalho utiliza as seguintes métricas: Erro Percentual Absoluto Médio (MAPE), Equação 9; Percentual Bias (PBIAS), Equação 10; e Erro Quadrático Médio Percentual (RMSPE), Equação 11.

$$\text{MAPE } [\%] = \frac{\sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|}{n} 100\% \quad (9)$$

$$\text{PBIAS } [\%] = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{\sum_{i=1}^n y_i} 100\% \quad (10)$$

$$\text{RMSPE } [\%] = \sqrt{\frac{\sum_{i=1}^n \left(\frac{\hat{y}_i - y_i}{y_i} \right)^2}{n}} 100\% \quad (11)$$

onde $\hat{y}_i$ é a entrada prevista, y_i é a entrada observada e n é o número de amostras.

Os hiperparâmetros iniciais do modelo base eMG [Lemos et al., 2010] e do modelo proposto NSM-eMG foram definidos por meio de uma busca em grade. Cada modelo foi avaliado em 250 execuções, totalizando 500 simulações. Para o modelo eMG, os hiperparâmetros otimizados foram: taxa de aprendizado $\alpha = 0,01$, nível de significância $\lambda = 0,50$, tamanho da janela $w = 20$ e matriz de dispersão inicial $\Sigma = 0,01$. No modelo NSM-eMG, os valores selecionados foram: $\alpha = 0,01$, $\lambda = 0,10$, $w = 2$, $\Sigma = 0,01$, $\bar{\gamma} = 0,0055$ e $\beta = 0,80$. Além disso, foram adotados os parâmetros fixos $IL = 0$ e $SL = 1$. Todas as simulações foram realizadas no MATLAB R2023a e executadas em um computador pessoal com processador Intel Core i5-1135G7 (2,40 GHz) e 8 GB de RAM.

Todos os resultados apresentados são expressos como a média $\pm$ desvio padrão, refletindo o desempenho do modelo ao longo das cinco janelas de avaliação previamente definidos pelo procedimento de janela deslizante. Os resultados do SMAP/ONS e FIG-FTS são apresentados apenas como valores médios calculados ao longo do período de avaliação pelo procedimento de janela deslizante.

4.1. Furnas

A usina hidrelétrica de Furnas está localizada no Rio Grande, em Minas Gerais, Brasil. Possui uma capacidade instalada total de 1.216 MW. O reservatório possui uma área de aproximadamente 1.440 km², com um volume útil de armazenamento de aproximadamente 22,95 km³

[Alves et al., 2023]. Os resultados de previsão para a bacia de Furnas são apresentados na Tabela 1, que resume o desempenho de cada modelo em termos de MAPE, PBIAS, RMSPE e número médio de regras finais. A Figura 4 mostra os resultados obtidos em comparação com os valores reais, incluindo o intervalo de confiança de 95% (IC 95%) das previsões do modelo NSM-eMG. O IC indica a faixa em que os valores previstos tendem a se concentrar, refletindo a incerteza estatística associada às previsões.

Tabela 1: Métricas de desempenho dos modelos para a bacia de Furnas.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	Regras Finais
SMAP/ONS [Alves et al., 2023]	19,36	-18,15	23,31	-
FIG-FTS [Alves et al., 2023]	23,19	-23,95	27,50	-
eMG [Lemos et al., 2010]	$11,4382 \pm 7,3140$	$5,1853 \pm 14,7871$	$14,2974 \pm 8,2850$	$4,00 \pm 0,00$
NSM-eMG	$7,9783 \pm 2,2045$	$0,5619 \pm 4,0140$	$10,1755 \pm 2,9945$	$14,00 \pm 0,71$




Figura 4: Resultados da previsão de vazão para a bacia de Furnas.

O modelo NSM-eMG obteve o melhor desempenho na bacia de Furnas, alcançando um MAPE de 7,98% (contra 19,36% do SMAP/ONS) e PBIAS de 0,56%, demonstrando maior acurácia e menor tendenciosidade que os demais métodos. Enquanto o SMAP/ONS apresentou subestimação sistemática (PBIAS= -18,15%), o NSM-eMG manteve erros consistentemente menores (RMSPE= 10,18%), devido à sua estrutura adaptativa. Esses resultados comprovam que o modelo NSM-eMG, nesse caso, supera tanto os modelos de comparação quanto a versão original do eMG em termos de precisão na previsão de vazões.

4.2. Itaipu

A usina hidrelétrica de Itaipu está localizada no Rio Paraná, no estado do Paraná, Brasil. Possui uma capacidade instalada total de 14.000 MW. O reservatório cobre uma área de aproximadamente 1.350 km², com um volume útil de armazenamento de aproximadamente 29 km³ [Alves et al., 2023]. Os resultados de previsão para a bacia de Itaipu são apresentados na Tabela 2, que re-

sume o desempenho de cada modelo. A Figura 5 mostra os resultados obtidos em comparação com os valores reais, incluindo o intervalo de confiança de 95% (IC 95%) para o modelo NSM-eMG.

Tabela 2: Métricas de desempenho dos modelos para a bacia de Itaipu.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	Regras Finais
SMAP/ONS [Alves et al., 2023]	12,74	-10,30	15,21	-
FIG-FTS [Alves et al., 2023]	11,03	-10,85	13,73	-
eMG [Lemos et al., 2010]	$4,7370 \pm 5,1344$	$3,1895 \pm 7,4699$	$5,4700 \pm 5,4550$	$5,00 \pm 0,00$
NSM-eMG	$2,6868 \pm 1,6695$	$0,4405 \pm 2,5226$	$3,4607 \pm 2,1635$	$20,60 \pm 0,55$




Figura 5: Resultados da previsão de vazão para a bacia de Itaipu.

O modelo NSM-eMG demonstrou desempenho superior na bacia de Itaipu, alcançando MAPE de 2,69% - significativamente menor que os 12,74% do SMAP/ONS e 11,03% do FIG-FTS. Com PBIAS próximo de zero (0,44%), o modelo evitou as subestimações sistemáticas observadas nos demais métodos ($PBIAS \approx -10\%$). A precisão do NSM-eMG é corroborada pelo baixo RMSPE (3,46%), aproximadamente 4 vezes menor que o do SMAP/ONS, aliado a uma estrutura mais complexa (20,6 regras), indicando maior capacidade de capturar a dinâmica hidrológica desta bacia de grande porte.

4.3. Avaliação Geral dos Modelos

A Tabela 3 apresenta o desempenho médio dos modelos nas bacias de Furnas e Itaipu. Os resultados consolidados revelam que o NSM-eMG obteve o melhor desempenho global, com um erro médio absoluto percentual (MAPE) 67% menor que o do modelo SMAP/ONS (5,33% contra 16,05%). Além disso, apresentou viés praticamente nulo (PBIAS de 0,50%), contrastando com as tendências de subestimação observadas nos modelos de referência, que chegaram a -17,40%. O NSM-eMG também demonstrou maior robustez, exibindo os menores desvios padrão em todas as métricas avaliadas.

A análise comparativa evidencia que os modelos convencionais, como o SMAP/ONS e o FIG-FTS, apresentam erros sistemáticos significativos, enquanto o modelo eMG básico já supera

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	Regras Finais
SMAP/ONS [Alves et al., 2023]	16,05 ± 4,68	-14,23 ± 5,55	19,26 ± 5,72	-
FIG-FTS [Alves et al., 2023]	17,11 ± 8,59	-17,40 ± 9,25	20,62 ± 9,74	-
eMG [Lemos et al., 2010]	8,09 ± 4,74	4,39 ± 11,13	9,88 ± 6,24	4,50 ± 0,71
NSM-eMG	5,33 ± 3,74	0,50 ± 3,24	6,82 ± 4,74	17,30 ± 4,67

Tabela 3: Desempenho médio dos modelos nas bacias de Furnas e Itaipu

os benchmarks, embora com maior variabilidade nos resultados. Esses resultados confirmam que a abordagem NSM-eMG oferece vantagens consistentes para a tarefa de previsão de vazões em diferentes escalas de bacias hidrográficas.

Destaca-se que a escolha e o ajuste dos hiperparâmetros, em especial a taxa de aprendizado (α), o nível de significância (λ) e o limiar de erro ($\bar{\gamma}$), exercem influência significativa sobre o desempenho do modelo NSM-eMG. Com base nas múltiplas execuções dos modelos, verificou-se que pequenas variações nesses parâmetros podem afetar sensivelmente os resultados. Ainda assim, o mecanismo adaptativo proposto, ao ajustar dinamicamente α em função do erro, demonstrou ser eficaz na preservação da estabilidade e da acurácia das previsões, mesmo sob distintas condições hidrológicas, reforçando a robustez e a capacidade adaptativa do modelo.

5. Conclusão

Este artigo apresentou um modelo inédito de previsão aplicado à estimativa de vazões em usinas hidrelétricas, denominado *Novel Set-Membership evolving Multivariable Gaussian* (NSM-eMG). A avaliação do modelo foi conduzida utilizando conjuntos de dados de vazão provenientes de duas importantes bacias no cenário brasileiro: Furnas e Itaipu. Métricas de desempenho como MAPE, PBIAS, RMSPE, bem como o número final de regras nos modelos evolutivos, foram empregadas para avaliar e comparar os resultados, considerando o uso de abordagens evolutivas e não evolutivas.

Foi realizada uma comparação entre o NSM-eMG, o modelo original eMG e dois modelos não evolutivos: o FIG-FTS e o SMAP/ONS, sendo este último o modelo de referência utilizado pela ONS. O modelo proposto obteve os melhores resultados tanto com os dados de Furnas quanto com os de Itaipu, superando de maneira consistente o modelo de referência SMAP/ONS. A aplicação bem-sucedida do NSM-eMG pode ser considerada uma contribuição promissora para a gestão eficiente do sistema de geração de energia hidrelétrica, oferecendo suporte à tomada de decisão para a otimização da operação.

Embora os resultados demonstrem a eficácia do modelo proposto nas bacias de Furnas e Itaipu, é importante ressaltar que a aplicação em outras regiões hidrológicas poderá fortalecer a evidência de sua capacidade de generalização. A limitação amostral deste estudo, contudo, não invalida os resultados promissores obtidos, que indicam um avanço significativo em relação aos modelos tradicionais.

Como sugestões de trabalhos futuros, considera-se a utilização de outras bases de dados que incluam uma maior diversidade de bacias hidrográficas relevantes no contexto nacional, bem como a realização de uma otimização mais abrangente dos hiperparâmetros, com o objetivo de aprimorar ainda mais o desempenho das previsões e a capacidade de generalização.

Agradecimentos

Os autores agradecem ao Instituto Nacional de Ciência e Tecnologia em Energia Elétrica (INERGE) e ao Programa de Pós-Graduação em Engenharia Elétrica (PPEE) da Universidade Federal de Juiz de Fora (UFJF) pelo suporte financeiro e institucional concedido para a realização deste trabalho. Este apoio foi fundamental para o desenvolvimento da pesquisa.

Referências

- Alves, T. d. R., Silva Júnior, I. C., e Honório, L. M. (2023). Previsão de vazão com séries temporais nebulosas para bacias do sistema interligado nacional. *Anais do Congresso Brasileiro de Inteligência Computacional (CBIC)*.
- Khozani, Z. S., Precht, E., e Ionita, M. (2024). Weekly streamflow forecasting of rhine river based on machine learning approaches. *Natural Hazards*, p. 1–19.
- Lemos, A., Caminhas, W., e Gomide, F. (2010). Multivariable gaussian evolving fuzzy modeling system. *IEEE Transactions on Fuzzy Systems*, 19(1):91–104.
- Lopes, J. E. G., Braga Jr., B. P. F., e Conejo, J. G. L. (1982). Smap: A simplified hydrologic model. In Singh, V. P., editor, *Applied Modeling in Catchment Hydrology*, p. 167–176. Water Resources Publications.
- Maciel, G. M., Cabral, V. A., Marcato, A. L. M., Silva Júnior, I. C., e Honório, L. D. M. (2020). Daily water flow forecasting via coupling between smap and deep learning. *IEEE Access*, 8: 204660–204675.
- Operador Nacional do Sistema Elétrico (ONS) (2024). Sintegre - sistema de informações da operação. <https://www.ons.org.br/>. Accessed: April 9, 2025.
- Rocha, M. V. G., Hell, M. B., Alves, K. S. T. R., Oliveira, F. L. C., e de Aguiar, E. P. (2021). Power transformers thermal modeling using an enhanced set-membership multivariable gaussian evolving fuzzy system. *Electric Power Systems Research*, 194:107088.
- Treistman, F., Penna, D. D. J., Khenayfis, L. d. S., Cavalcante, N. B. R., Souza Filho, F. d. A. d., Rocha, R. V., Estácio, A. B., Rolim, L. Z. R., Pontes Filho, J. D. d. A., Porto, V. C., et al. (2023). A framework to evaluate and compare synthetic streamflow scenario generation models. *RBRH*, 28:e43.
- Vieira, R., Gomide, F., e Ballini, R. (2018). Kernel evolving participatory fuzzy modeling for time series forecasting. In *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*, p. 1–9. IEEE.
- Wang, S., Zhong, P.-a., Zhu, F., Xu, B., Li, J., Qian, X., e Wang, B. (2023). Streamflow forecasting method with a hybrid physical process-mathematical statistic. *Stochastic Environmental Research and Risk Assessment*, 37(12):4805–4826.
- Yager, R. R. (1990). A model of participatory learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 20(5):1229–1234.

Apêndice A

Algorithm 1: eMG

Input: $x, y_d, \lambda, \omega, \Sigma_{init}, w$

Output: y_s

Inicialização: $v_1^1 = x^1, \gamma_1 = [y_1 0 0 \dots 0], Q_1 = \omega I_{m+1}, \Sigma_{init} = \Sigma I_m, T_a = 1 - \lambda, T_\rho = \exp(-0.5 \times \chi_{m,\lambda}^2)$

for $k = 2, 3, \dots, n$ **do**

for $i = 1, 2, \dots, c$ **do**

 Calcula a distância M e a medida de compatibilidade:

if $\rho_i < T_\rho$ **then**

$o_i^k = 1$

if $k > w$ **then**

$nv_i^k = \sum_{j=0}^{w-1} o_i^{k-j}$

$a_i^k = p(NV_i^k < nv_i^k)$

 Saída local: $y_i^k = \gamma_{i0}^k + \sum_{j=1}^m \gamma_{ij}^k x_i^k$

 Saída global: $\hat{y}^k = \frac{\sum_{i=1}^c \rho_i y_i^k}{\sum_{i=1}^c \rho_i}$

if $\rho_i < T_\rho$ e $a_i > T_a$ para $i = \operatorname{argmax}_i \rho_i^k$ **then**

 Cria novo cluster: $c = c + 1$

 Inicializa o centro de regras, a matriz de

 dispersão, os parâmetros do consequente, e a matriz Q :

$v_c = x^k, \Sigma_c = \Sigma_{init}$

else

 Encontra a regra mais compatível: $i = \operatorname{argmax}_i \rho_i^k$

 Atualiza o centro de regra e a matriz de dispersão

 // O NSM é chamado aqui

for $i = 1, 2, \dots, c$ **do**

 Atualiza os parâmetros do consequente e a matriz Q

for $i = 1, 2, \dots, c$ **do**

if $\rho_i(v_i, v_j) > T_\rho$ ou $\rho_j(v_j, v_i) > T_\rho$ **then**

 Remove clusters redundantes: $c = c - 1$

 Mescla os dois centros de cluster: $v_j = \operatorname{mean}(v_i, v_j)$

 Atualiza a matriz de dispersão: $\Sigma_j = \Sigma_{init}$

 Mescla a matriz Q e os parâmetros do consequente

Onde x é o vetor de entrada, y_d é o vetor de saída alvo, λ é o nível de significância, Σ_{init} é a matriz de dispersão inicial, ω é o tamanho da janela e y_s é o valor de saída predito.