

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Marcos Vinícius Gonçalves da Rocha**

**Previsão de Vazão de Curto Prazo em Bacias Hidrográficas do Sistema  
Interligado Nacional Utilizando Novos Modelos Fuzzy Evolutivos Gaussianos  
Multivariáveis Aprimorados**

Juiz de Fora

2026

Marcos Vinícius Gonçalves da Rocha

**Previsão de Vazão de Curto Prazo em Bacias Hidrográficas do Sistema Interligado Nacional Utilizando Novos Modelos Fuzzy Evolutivos Gaussianos Multivariáveis Aprimorados**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos.

Orientador: Prof. Dr. Ivo Chaves da Silva Junior

Juiz de Fora

2026

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Rocha, Marcos Vinícius Gonçalves da.

Previsão de Vazão de Curto Prazo em Bacias Hidrográficas do Sistema Interligado Nacional Utilizando Novos Modelos Fuzzy Evolutivos Gaussianos Multivariáveis Aprimorados / Marcos Vinícius Gonçalves da Rocha. – 2026.  
118 f. : il.

Orientador: Ivo Chaves da Silva Junior

Exame de Tese de Doutorado – Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2026.

1. mecanismos adaptativos. 2. previsão de vazão. 3. sistemas fuzzy evolutivos. I. Silva Junior, Ivo Chaves da, orient. II. Título.

**Marcos Vinícius Gonçalves da Rocha**

**Previsão de Vazão de Curto Prazo em Bacias Hidrográficas do Sistema Interligado Nacional Utilizando Novos Modelos Fuzzy Evolutivos Gaussianos Multivariáveis Aprimorados**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos.

Aprovada em 11 de maio de 2026.

**BANCA EXAMINADORA**

**Ivo Chaves da Silva Junior** - Orientador

Universidade Federal de Juiz de Fora

**Prof. Dr. Petrônio Cândido de Lima e Silva**

Instituto Federal do Norte de Minas Gerais

**Profa. Dra. Patrícia Teixeira Leite Asano**

Universidade Federal do ABC

**Prof. Dr. Igor Delgado de Melo**

Universidade Federal de Juiz de Fora

**Prof. Dr. Leonardo Willer de Oliveira**

Universidade Federal de Juiz de Fora



Documento assinado eletronicamente por **Ivo Chaves da Silva Junior, Professor(a)**, em 11/05/2026, às 10:50, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 11/05/2026, às 10:55, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Igor Delgado de Melo, Professor(a)**, em 11/05/2026, às 10:56, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **PATRICIA TEIXEIRA LEITE ASANO, Usuário Externo**, em 12/05/2026, às 15:09, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Petrônio Cândido de Lima e Silva, Usuário Externo**, em 25/05/2026, às 18:54, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no Portal do SEI-Uffj ([www2.uffj.br/SEI](http://www2.uffj.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **2921570** e o código CRC **B56483C6**.

*Aos meus pais, Antonio (em memória) e Geni.*

## AGRADECIMENTOS

Em primeiro lugar, aos meus pais, pelos valores ensinados e por todo apoio ao longo desta caminhada. A vocês, minha gratidão.

Aos familiares e amigos que se fizeram presentes durante esta jornada, pela escuta, incentivo e compreensão.

À Universidade Federal de Juiz de Fora e ao Programa de Pós-Graduação em Engenharia Elétrica (PPEE/UFJF), aos professores, servidores e colegas que, com ética e profissionalismo, contribuíram para minha formação acadêmica.

De maneira especial, ao meu orientador, Ivo Chaves da Silva Junior, por sua postura humana, pela excelência na orientação e pelos ensinamentos compartilhados.

Aos membros da banca examinadora, pela disponibilidade na análise deste trabalho e pelas contribuições apresentadas.

Por fim, agradeço ao sistema público de educação do Brasil e ao povo brasileiro que o sustenta.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

*“If you can't fly then run, if you can't run then walk, if you can't walk then crawl, but whatever you do you have to keep moving forward.”*

(MARTIN LUTHER KING JR., 1960)

## RESUMO

A gestão eficiente dos recursos hídricos é um pilar fundamental do setor de geração hidrelétrica em todo o mundo, com implicações sociais, ambientais e econômicas significativas. Nesse contexto, métodos de previsão de vazão precisos constituem ferramentas essenciais para apoiar um planejamento energético confiável e sustentável. O presente estudo investiga a aplicabilidade e a eficácia de sistemas fuzzy evolutivos visando ao aprimoramento da previsão de vazão de curto prazo no sistema hidrológico brasileiro. Como contribuição original, três abordagens inéditas são propostas por meio da incorporação de mecanismos adaptativos de atualização de hiperparâmetros à estrutura do modelo *evolving Multivariable Gaussian* (eMG), introduzindo uma modificação metodológica baseada na adaptação dinâmica do nível de significância ( $\lambda$ ) em função do erro de previsão. Esta é a primeira aplicação conhecida desses mecanismos adaptativos em sistemas fuzzy evolutivos para a previsão de vazões. O desempenho dos modelos propostos foi avaliado em comparação com o modelo de referência atualmente utilizado pelo Operador Nacional do Sistema Elétrico (ONS), o SMAP/ONS, além de outras abordagens clássicas da literatura para essa aplicação, como redes neurais baseadas em aprendizado profundo, redes LSTM. A análise utilizou dados de vazão e de precipitação estimada via satélite, cobrindo um período de onze anos (2011–2021). Foram consideradas seis bacias hidrográficas estratégicas do Sistema Interligado Nacional (SIN): Furnas, Itaipu, Itumbiara, São Simão, Três Marias e Tucuruí, abrangendo bacias de pequeno e de grande porte, com ampla diversidade de regimes hidrológicos. Foi desenvolvido um protocolo de avaliação robusto, no qual os resultados demonstram que os modelos propostos superaram consistentemente os modelos de benchmark considerados, apresentando redução expressiva nos erros de previsão e viés próximo de zero. Para corroborar esses achados, um protocolo de validação estatística confirmou a significância dessas melhorias na maioria dos cenários testados. Devido à sua natureza adaptativa e eficiência computacional, os modelos propostos lidam de forma eficaz com a variabilidade inerente às observações de vazão, oferecendo soluções robustas e promissoras para aplicações em tempo real na gestão hidrelétrica nacional, e como consequência uma geração de eletricidade segura e confiável para atendimento da demanda do país.

Palavras-chave: bacias hidrográficas; mecanismos adaptativos; previsão de vazão; sistemas fuzzy evolutivos.

## ABSTRACT

Efficient water resource management is a fundamental pillar of the hydropower generation sector worldwide, with significant social, environmental, and economic implications. In this context, accurate streamflow forecasting methods constitute essential tools to support reliable and sustainable energy planning. This study investigates the applicability and effectiveness of evolving fuzzy systems aimed at improving short-term streamflow forecasting in the Brazilian hydrological system. As an original contribution, three novel approaches are proposed by incorporating adaptive hyperparameter update mechanisms into the evolving Multivariable Gaussian (eMG) model structure, introducing a methodological modification based on the dynamic adaptation of the significance level ( $\lambda$ ) according to the prediction error. This is the first known application of such adaptive mechanisms in evolving fuzzy systems for streamflow forecasting. The performance of the proposed models was evaluated against the benchmark model currently used by the National System Operator (ONS), the SMAP/ONS, as well as other classical approaches in the literature for this application, such as deep learning (LSTM) networks. The analysis used streamflow and satellite-based precipitation data, covering an eleven-year period (2011–2021). Six strategic river basins of the National Interconnected System (SIN) were considered: Furnas, Itaipu, Itumbiara, São Simão, Três Marias, and Tucuruí, encompassing small and large-scale basins with a wide diversity of hydrological regimes. A robust evaluation protocol was developed, and results demonstrate that the proposed models consistently outperformed the benchmark models, showing a significant reduction in forecast errors and near-zero bias. To corroborate these findings, a statistical validation protocol confirmed the significance of these improvements in most tested scenarios. Due to their adaptive nature and computational efficiency, the proposed models effectively handle the variability inherent in streamflow observations, offering robust and promising solutions for real-time applications in national hydropower management, and consequently contributing to a safe and reliable electricity generation system capable of meeting the country's demand.

Keywords: adaptive mechanisms; evolving fuzzy systems; river basins; streamflow forecasting.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Mecanismo de aprendizado do modelo eMG . . . . .	31
Figura 2 – Diagrama conceitual do modelo SMAP . . . . .	44
Figura 3 – Diagrama conceitual do modelo SMAP/ONS . . . . .	45
Figura 4 – Mapa da Divisão Hidrográfica do Brasil . . . . .	50
Figura 5 – Caracterização espacial da Região Hidrográfica do Paraná . . . . .	52
Figura 6 – Caracterização espacial da Região Hidrográfica do São Francisco . . . . .	54
Figura 7 – Caracterização espacial da Região Hidrográfica do Tocantins–Araguaia . . . . .	55
Figura 8 – Esquema de validação cruzada – Estudo de Caso 1 . . . . .	59
Figura 9 – Séries históricas de vazão e precipitação – Estudo de Caso 1 . . . . .	66
Figura 10 – Boxplots comparativos de desempenho global – Estudo de Caso 1 . . . . .	74
Figura 11 – Séries temporais das vazões previstas – Estudo de Caso 1 . . . . .	76
Figura 12 – Séries históricas de vazão e precipitação – Estudo de Caso 2 . . . . .	87
Figura 13 – Esquema de validação cruzada – Estudo de Caso 2 . . . . .	88
Figura 14 – Séries temporais das vazões previstas – Estudo de Caso 2 . . . . .	93
Figura 15 – Séries históricas de vazão e precipitação – Estudo de Caso 3 . . . . .	98
Figura 16 – Séries temporais das vazões previstas – Estudo de Caso 3 . . . . .	101

## LISTA DE TABELAS

Tabela 1 – Síntese comparativa dos modelos evolutivos . . . . .	43
Tabela 2 – Principais características geográficas das bacias selecionadas . . . . .	51
Tabela 3 – Principais características geográficas das bacias de generalização . . . . .	54
Tabela 4 – Intervalos de busca para otimização de hiperparâmetros . . . . .	60
Tabela 5 – Métricas de avaliação de desempenho . . . . .	62
Tabela 6 – Visão geral comparativa dos estudos de caso propostos . . . . .	64
Tabela 7 – Estatísticas descritivas das séries de vazão e precipitação 2011–2019 . . . . .	67
Tabela 8 – Configurações otimizadas para os modelos evolutivos . . . . .	70
Tabela 9 – Métricas globais de desempenho . . . . .	71
Tabela 10 – Métricas de desempenho da bacia de Furnas . . . . .	75
Tabela 11 – Métricas de desempenho da bacia de Itaipu . . . . .	77
Tabela 12 – Métricas de desempenho da bacia de Itumbiara . . . . .	78
Tabela 13 – Métricas de desempenho da bacia de São Simão . . . . .	79
Tabela 14 – Análise de significância estatística – Estudo de Caso 1 . . . . .	80
Tabela 15 – Estatísticas descritivas das séries de vazão e precipitação 2019–2021 . . . . .	88
Tabela 16 – Métricas de desempenho da bacia de Furnas – Estudo de Caso 2 . . . . .	91
Tabela 17 – Métricas de desempenho da bacia de Itaipu – Estudo de Caso 2 . . . . .	91
Tabela 18 – Métricas de desempenho da bacia de Itumbiara – Estudo de Caso 2 . . . . .	91
Tabela 19 – Métricas de desempenho da bacia de São Simão – Estudo de Caso 2 . . . . .	91
Tabela 20 – Análise de significância estatística – Estudo de Caso 2 . . . . .	95
Tabela 21 – Estatísticas das séries de vazão e precipitação – Estudo de Caso 3 . . . . .	98
Tabela 22 – Métricas de desempenho da bacia de Três Marias . . . . .	99
Tabela 23 – Métricas de desempenho da bacia de Tucuruí . . . . .	100
Tabela 24 – Análise de significância estatística – Estudo de Caso 3 . . . . .	103

## LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas e Saneamento Básico
CNRH	Conselho Nacional de Recursos Hídricos
eFS	Sistema Fuzzy evolutivo ( <i>evolving Fuzzy System</i> )
eMG	<i>evolving Multivariable Gaussian</i>
FIG-FTS	<i>Fuzzy Information Granule-Fuzzy Time Series</i>
FL	Lógica Fuzzy ( <i>Fuzzy Logic</i> )
IBGE	Instituto Brasileiro de Geografia e Estatística
IL	Limite Inferior ( <i>Inferior Limit</i> )
INPE	Instituto Nacional de Pesquisas Espaciais
LSTM	<i>Long Short-Term Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MGN	Morgan–Granger–Newbold
ML	Aprendizado de Máquina ( <i>Machine Learning</i> )
MLP	Perceptron Multicamadas ( <i>Multilayer Perceptron</i> )
MME	Ministério de Minas e Energia
MVS	<i>Modified Variable Step-Size</i>
MVS-eMG	<i>Modified Variable Step-Size evolving Multivariable Gaussian</i>
MVSA	<i>Modified Variable Step-Size Adaptive</i>
MVSA-eMG	<i>Modified Variable Step-Size Adaptive evolving Multivariable Gaussian</i>
NSE	<i>Nash–Sutcliffe Efficiency</i>
ONS	Operador Nacional do Sistema Elétrico
PACF	Função de Autocorrelação Parcial ( <i>Partial Autocorrelation Function</i> )
PBIAS	<i>Percent Bias</i>
PL	Aprendizado Participativo ( <i>Participatory Learning</i> )
RH	Região Hidrográfica
RMSPE	<i>Root Mean Square Percentage Error</i>
RNN	Rede Neural Recorrente ( <i>Recurrent Neural Network</i> )
SIN	Sistema Interligado Nacional
SL	Limite Superior ( <i>Superior Limit</i> )
SMAP	<i>Soil Moisture Accounting Procedure</i>
VS	<i>Variable Step-Size</i>
VS-eMG	<i>Variable Step-Size evolving Multivariable Gaussian</i>
VSA	<i>Variable Step-Size Adaptive</i>
VSA-eMG	<i>Variable Step-Size Adaptive evolving Multivariable Gaussian</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>14</b>
1.1	OBJETIVOS . . . . .	18
1.1.1	<b>Objetivo Geral</b> . . . . .	18
1.1.2	<b>Objetivos Específicos</b> . . . . .	18
1.2	CONTRIBUIÇÕES . . . . .	19
1.3	PRODUÇÃO CIENTÍFICA RELACIONADA . . . . .	20
1.4	ESTRUTURA DO TRABALHO . . . . .	20
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>21</b>
2.1	PREVISÃO DE VAZÃO NO CONTEXTO DO SISTEMA INTERLIGADO NACIONAL . . . . .	21
2.2	MODELAGEM HIDROLÓGICA BASEADA EM DADOS . . . . .	22
2.3	SISTEMAS FUZZY: CONCEITOS GERAIS E APLICAÇÃO NA HIDROLOGIA . . . . .	25
2.4	SISTEMAS FUZZY EVOLUTIVOS: FUNDAMENTOS E MODELOS . . . . .	26
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> . . . . .	<b>30</b>
3.1	EVOLVING MULTIVARIABLE GAUSSIAN (eMG) . . . . .	30
3.1.1	<b>Variable Step-Size evolving Multivariable Gaussian (VS-eMG)</b> . . . . .	36
3.2	MODELOS PROPOSTOS . . . . .	37
3.2.1	<b>Variable Step-Size Adaptive evolving Multivariable Gaussian (VSA-eMG)</b> . . . . .	38
3.2.2	<b>Modified Variable Step-Size Adaptive evolving Multivariable Gaussian (MVSA-eMG)</b> . . . . .	39
3.2.3	<b>Modified Variable Step-Size evolving Multivariable Gaussian (MVS-eMG)</b> . . . . .	41
3.2.4	<b>Síntese dos Modelos Propostos</b> . . . . .	42
3.3	SOIL MOISTURE ACCOUNTING PROCEDURE (SMAP/ONS) . . . . .	43
3.4	BENCHMARKS COMPLEMENTARES . . . . .	48
3.4.1	<b>Long Short-Term Memory (LSTM)</b> . . . . .	48
3.4.2	<b>Fuzzy Information Granular-Fuzzy Time Series (FIG-FTS)</b> . . . . .	49
3.5	CARACTERIZAÇÃO DAS ÁREAS DE ESTUDO . . . . .	49
3.5.1	<b>Região Hidrográfica do Paraná</b> . . . . .	51
3.5.2	<b>Regiões Hidrográficas Complementares</b> . . . . .	53
3.6	PROTOCOLO EXPERIMENTAL E AVALIAÇÃO . . . . .	55
3.6.1	<b>Dados Hidrológicos de Vazão e Precipitação</b> . . . . .	56
3.6.2	<b>Definição das Variáveis de Entrada dos Modelos</b> . . . . .	56
3.6.3	<b>Metodologia de Validação</b> . . . . .	57
3.6.4	<b>Otimização de Hiperparâmetros dos Modelos Evolutivos</b> . . . . .	59

3.6.5	Métricas de Avaliação de Desempenho . . . . .	61
3.6.6	Análise de Significância Estatística . . . . .	62
3.6.7	Visão Geral dos Estudos de Caso Propostos . . . . .	63
4	<b>ESTUDO DE CASO 1: ANÁLISE DE DESEMPENHO EM CONDIÇÕES HIDROLÓGICAS REPRESENTATIVAS . . . . .</b>	<b>65</b>
4.1	CENÁRIO EXPERIMENTAL . . . . .	65
4.1.1	Preditores de Referência Estáticos e Lineares . . . . .	68
4.1.2	Configuração dos Modelos de Previsão Orientados a Dados . . . . .	68
4.2	RESULTADOS DA OTIMIZAÇÃO DE HIPERPARÂMETROS . . . . .	69
4.3	AVALIAÇÃO GLOBAL MULTIBACIA . . . . .	70
4.4	BACIA DE FURNAS . . . . .	75
4.5	BACIA DE ITAIPU . . . . .	77
4.6	BACIA DE ITUMBIARA . . . . .	78
4.7	BACIA DE SÃO SIMÃO . . . . .	78
4.8	ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA . . . . .	79
4.9	DISCUSSÃO . . . . .	84
5	<b>ESTUDO DE CASO 2: AVALIAÇÃO DE ROBUSTEZ SOB ESTRESSE HÍDRICO . . . . .</b>	<b>85</b>
5.1	CENÁRIO EXPERIMENTAL . . . . .	86
5.1.1	Caracterização do Cenário de Estresse Hídrico . . . . .	88
5.1.2	Configuração dos Modelos de Previsão . . . . .	89
5.2	ANÁLISE INTEGRADA DE DESEMPENHO E ROBUSTEZ . . . . .	90
5.3	ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA . . . . .	94
6	<b>ESTUDO DE CASO 3: GENERALIZAÇÃO ESPACIAL E ADAPTAÇÃO A REGIMES HIDROLÓGICOS DISTINTOS . . . . .</b>	<b>97</b>
6.1	CENÁRIO EXPERIMENTAL . . . . .	97
6.1.1	Configuração dos Modelos de Previsão . . . . .	99
6.2	ANÁLISE INTEGRADA DE DESEMPENHO E GENERALIZAÇÃO ESPACIAL . . . . .	99
6.3	ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA . . . . .	102
7	<b>DISCUSSÃO INTEGRADA E LIMITAÇÕES . . . . .</b>	<b>104</b>
8	<b>CONCLUSÃO . . . . .</b>	<b>108</b>
8.1	TRABALHOS FUTUROS . . . . .	110
	<b>REFERÊNCIAS . . . . .</b>	<b>112</b>

## 1 INTRODUÇÃO

À medida que os desafios globais relacionados aos recursos hídricos se intensificam, a previsão confiável de vazões torna-se essencial para garantir a segurança hídrica em diferentes contextos. Nesse cenário, a gestão dos recursos hídricos assume grande relevância sob as perspectivas social, ambiental e econômica. O aprimoramento das capacidades de previsão de vazões desempenha, portanto, um papel central nas atividades de gestão da água, apoiando operações de geração hidrelétrica, prevenção de enchentes e a tomada de decisões estratégicas e operacionais em níveis local e regional (GIRIHAGAMA et al., 2022).

Atualmente, a energia hidrelétrica, gerada a partir do aproveitamento do potencial hidráulico dos cursos d'água, é uma das principais fontes de energia renovável em escala global. Nesse contexto, o setor de geração hidrelétrica representa uma indústria de elevado impacto econômico em todo o mundo. O uso de sistemas de previsão para estimar afluências futuras pode melhorar significativamente o desempenho desse setor em termos de geração de energia, despacho otimizado e mitigação de riscos operacionais (XU et al., 2014).

Considerando as incertezas inerentes ao ciclo hidrológico, abordagens de previsão desempenham um papel importante na operação e no planejamento estratégico de sistemas de geração de energia, possibilitando um uso mais eficiente e sustentável da água. Esses desafios são particularmente relevantes em países emergentes, onde a energia hidrelétrica exerce papel central na segurança energética e no desenvolvimento socioeconômico.

A complexidade e a variabilidade dos sistemas de vazão tornam a previsão precisa e oportuna uma tarefa desafiadora para hidrólogos. Essa dificuldade é ampliada pela necessidade de avaliar e mensurar os diversos fatores que influenciam os sistemas hidrológicos, tais como distribuições caóticas, padrões periódicos de fluxo e as relações não lineares entre os elementos das bacias hidrográficas, dado que esses sistemas são inerentemente dinâmicos e incertos (TRIPURA; ROY; BARBHUIYA, 2021; KHOZANI; PRECHT; IONITA, 2025).

A maioria dos modelos hidrológicos fornece representações simplificadas desses sistemas e de seus mecanismos físicos, devido a lacunas no entendimento dos processos hidrológicos. Como resultado, suas previsões inevitavelmente carregam um certo grau de incerteza (KE et al., 2024), fator que muitas vezes compromete a credibilidade das estimativas e dificulta a tomada de decisão no planejamento operacional (PORTELE et al., 2021).

À medida que o horizonte de previsão se estende, a complexidade e a incerteza associadas ao processo preditivo aumentam (LETTENMAIER; WOOD; WALLIS, 1994). Deste modo, informações hidrológicas, em especial previsões de vazão precisas, constituem um dos principais elementos para fornecer suporte consistente aos operadores envolvidos na gestão de recursos hídricos e no planejamento energético (RAMOS; GÁMEZ, 2018).

Diferentes horizontes temporais de previsão podem ser categorizados de acordo com finalidades distintas: as previsões de curto prazo (horárias ou diárias) são importantes para o despacho operacional, o controle de cheias e a formação do preço da energia no mercado de curto prazo; as previsões de médio prazo (mensais ou sazonais) são fundamentais para o planejamento da operação energética anual, a gestão dos reservatórios e a mitigação de riscos de seca; por fim, previsões de longo prazo orientam investimentos estratégicos em infraestrutura, como a expansão da capacidade de geração e transmissão (RAMOS; GÁMEZ, 2018).

No contexto operacional, a gestão ótima dos reservatórios depende intrinsecamente do equilíbrio entre a demanda energética e a disponibilidade hídrica. A vazão afluenta, atual e futura, é a variável estocástica determinante nesse processo, influenciando diretamente o “valor da água” e o custo marginal de operação. Dessa forma, a robustez das previsões de aflúncias não é apenas uma questão hidrológica, mas um requisito econômico fundamental: superestimar vazões pode levar a vertimentos desnecessários e consequente desperdício de energia, enquanto subestimá-las pode resultar em despacho térmico excessivo e encarecimento da operação (ALGARVIO; LOPES; SANTANA, 2020).

Essa interdependência entre a disponibilidade hídrica, o valor econômico da água e as decisões operacionais é amplamente reconhecida na literatura, uma vez que as incertezas hidrológicas propagam-se diretamente para as estratégias de alocação e para os custos de produção (WOBUS et al., 2022). Nesse sentido, aprimorar o desempenho dos modelos hidrológicos de previsão possibilita um planejamento e gerenciamento energético mais eficazes (TREISTMAN et al., 2023).

Estudos recentes mostram que previsões precisas podem gerar economias operacionais significativas, especialmente sob condições de seca, uma vez que ações preventivas baseadas em previsões sazonais ajudam a mitigar perdas e melhorar a eficiência geral dos sistemas hidrológicos (PORTELE et al., 2021). De maneira complementar, a literatura reporta o potencial de aumento de receita ao permitir a flexibilização de restrições operativas em períodos de maior disponibilidade hídrica (HAMLET; HUPPERT; LETTENMAIER, 2002).

No contexto de sistemas hidrotérmicos (sistemas nos quais a geração hidrelétrica é complementada por fontes termelétricas) fortemente dependentes da regularização por reservatórios, como o brasileiro, fatores climáticos e antrópicos ampliam significativamente a complexidade e a incerteza associadas à operação do setor energético. Os efeitos das mudanças climáticas sobre os padrões hidrológicos, somados ao crescimento populacional, vêm impondo dificuldades adicionais às abordagens tradicionais de gestão de recursos hídricos. Por consequência, agentes responsáveis pelo planejamento e operação enfrentam desafios crescentes para alcançar uma gestão sustentável e integrada dos recursos hídricos, especialmente em regiões sob estresse hídrico (RAMOS; GÁMEZ, 2018).

O Brasil é um dos países cuja matriz elétrica é predominantemente composta por usinas hidrelétricas. Desse modo, a previsão confiável de vazões de curto prazo é essencial para otimizar a geração hidrelétrica, garantir a confiabilidade energética e reduzir a necessidade de fontes complementares (geralmente associadas a maiores custos operacionais e impactos ambientais) quando as fontes hidrelétricas são insuficientes para atender plenamente à demanda (MACIEL et al., 2020).

O planejamento e a coordenação do Sistema Interligado Nacional (SIN), rede integrada de geração e transmissão de energia elétrica no Brasil, são conduzidos pelo Operador Nacional do Sistema Elétrico (ONS), que rotineiramente publica previsões de aflúências naturais para os reservatórios do SIN, necessárias como entrada para modelos de otimização (NETO et al., 2023). O modelo operacional oficial de previsão de vazão de curto prazo atualmente empregado pelo ONS é o *Soil Moisture Accounting Procedure* (SMAP/ONS) (apresentado na Seção 3.3). Trata-se de um modelo de contabilidade da umidade do solo que simula a transformação chuva-vazão a partir de variáveis como precipitação e evapotranspiração, fornecendo estimativas de aflúência necessárias ao planejamento e à otimização do despacho hidrotérmico em horizontes diário e semanal (ALVES; SILVA JUNIOR; HONÓRIO, 2023).

Nesse contexto, a previsão de vazões deve atender a rigorosos requisitos operacionais, devido à escala e à complexidade do sistema hidrotérmico brasileiro, sendo sua eficácia também frequentemente desafiada por eventos climáticos extremos. Um exemplo recente que ilustra esses desafios no setor de geração hidrelétrica brasileiro foi a situação de escassez hídrica na bacia do Paraná. Segundo o Ministério de Minas e Energia (MME) (2021), entre setembro de 2020 e abril de 2021, as vazões observadas em diversas bacias das regiões Sul, Sudeste e Centro-Oeste ficaram muito abaixo das médias históricas, atingindo seus menores níveis em aproximadamente nove décadas de registro histórico.

A Bacia do Prata é um dos sistemas hidrográficos mais relevantes da América do Sul. Ela se estende por vários países e cobre mais de 17% do território brasileiro (incluindo a bacia do Paraná), concentrando 54% da população e sendo responsável por aproximadamente 64% da geração hidrelétrica do país por meio de 84 usinas. Conseqüentemente, a limitação de recursos hídricos nessas regiões aumenta o risco de racionamento, comprometendo o abastecimento de água e elevando o custo da energia em todo o território nacional (Ministério de Minas e Energia (MME), 2021; Serviço Geológico do Brasil (SGB/CPRM), 2021).

Estudos recentes indicam o papel crescente de técnicas de inteligência artificial no aprimoramento das previsões hidrológicas e na eficiência da gestão dos recursos hídricos, visando lidar com a variabilidade hidrológica e apoiar decisões estratégicas em situações críticas (TROIN et al., 2021; CHANG; CHANG; CHEN, 2023; TOLEDO et al., 2023; TEPETIDIS et al., 2024). Apesar desse potencial, modelos estáticos convencionais,

treinados uma única vez em ambiente offline, tendem a se tornar ineficientes ou imprecisos quando expostos a mudanças nas condições operacionais ou a novos estados do sistema, como ocorre em eventos climáticos extremos (LUGHOFER, 2016).

Diante deste cenário, Škrjanc et al. (2019) destacam que o processamento de fluxos contínuos de dados (*data streams*) limita a adequação de estratégias de treinamento estáticas ou em lote (*batch*). Os dados hidrológicos utilizados para previsão de vazão, como históricos de vazão e precipitação (ALVES; SILVA JUNIOR; HONÓRIO, 2023), constituem fluxos contínuos medidos periodicamente, que comumente apresentam distribuições altamente dinâmicas, variações sazonais e ruídos provenientes de diferentes fontes (por exemplo, erros de medição, incertezas nos dados de precipitação e flutuações aleatórias de curto prazo não associadas a mudanças estruturais do sistema).

Esses fatores reforçam a necessidade de técnicas de previsão capazes de aprender de forma incremental, bem como de atualizar sua estrutura à medida que novas informações se tornam disponíveis. Partindo dessa necessidade, o presente estudo busca desenvolver a base teórica e metodológica estabelecida em Rocha et al. (2021) e Rocha et al. (2022), por meio da proposição e da análise extensiva de novos modelos fuzzy evolutivos aprimorados. Esses trabalhos investigaram aprimoramentos de desempenho na modelagem térmica de transformadores de potência ao incorporar os conceitos de *Set-Membership* (SM) e *Variable Step-Size* (VS) ao modelo *evolving Multivariable Gaussian* (eMG), originalmente proposto por Lemos, Caminhas e Gomide (2010).

No contexto de aplicação desses estudos anteriores, a modelagem térmica de transformadores, embora seja um tema relevante na literatura, envolve sistemas relativamente bem controlados e com variáveis monitoradas, o que limita a exposição dos modelos a fontes externas de incerteza. Os resultados obtidos nesses estudos demonstraram aprimoramento de desempenho significativo, o que credencia essa classe de modelos a enfrentar desafios de maior complexidade.

Vale ressaltar que, no escopo da revisão da literatura realizada para esta tese, não foram identificadas aplicações anteriores do modelo eMG e de suas variantes aprimoradas na previsão hidrológica de vazão de curto prazo. A aplicação desses modelos nesse contexto apresenta um nível de complexidade superior, uma vez que modelos hidrológicos são dinâmicos, altamente incertos e sujeitos a diversos fatores externos, como variações climáticas, usos do solo e operações de reservatórios.

Apesar dos avanços reportados na literatura recente em previsão hidrológica baseada em dados, observa-se que uma parcela significativa dos modelos propostos ainda se baseia em estruturas estáticas, treinadas em lotes (regime offline), cuja capacidade de adaptação a mudanças nas condições hidrológicas é limitada. Em contextos operacionais reais, como o do Sistema Interligado Nacional, essas limitações tornam-se particularmente críticas, uma vez que as séries de vazão e precipitação apresentam elevada variabilidade e são

frequentemente impactadas por eventos extremos e por intervenções antrópicas.

Nesse contexto, embora sistemas fuzzy evolutivos tenham demonstrado potencial para lidar com fluxos contínuos de dados e mudanças estruturais, ainda são escassos os estudos que investigam, de forma sistemática, o impacto da incorporação de mecanismos adaptativos de atualização de hiperparâmetros em aplicações de previsão de vazão. Em especial, não há evidências consolidadas sobre como tais mecanismos podem contribuir para melhorar simultaneamente o desempenho preditivo, a robustez sob estresse hídrico e a capacidade de generalização espacial em bacias hidrográficas de diferentes regimes.

Diante dessa lacuna, o presente trabalho propõe o desenvolvimento e a avaliação de novos modelos fuzzy evolutivos aprimorados, visando contribuir para o avanço do estado da arte na previsão de vazão de curto prazo no contexto operacional brasileiro, ao mesmo tempo em que oferece subsídios técnicos para aplicações em tempo real na gestão hidrelétrica nacional.

## 1.1 OBJETIVOS

Esta seção apresenta os objetivos que norteiam o desenvolvimento desta tese, detalhando o objetivo geral da pesquisa e os objetivos específicos definidos para alcançá-lo.

### 1.1.1 Objetivo Geral

Desenvolver e avaliar modelos fuzzy evolutivos aprimorados para a previsão de vazões de curto prazo em bacias hidrográficas do Sistema Interligado Nacional, considerando cenários hidrológicos operacionais reais.

### 1.1.2 Objetivos Específicos

Para alcançar o objetivo geral proposto, foram definidos os seguintes objetivos específicos:

- Propor e formalizar matematicamente três novas abordagens de modelagem fuzzy evolutiva incorporando diferentes mecanismos adaptativos de atualização de hiperparâmetros à estrutura do modelo eMG, com ênfase no controle adaptativo do processo de evolução estrutural e de aprendizado, visando ao aperfeiçoamento do desempenho preditivo tanto em regimes hidrológicos típicos quanto em eventos extremos.
- Estabelecer um protocolo experimental robusto, capaz de mitigar vieses sazonais e avaliar o desempenho dos modelos de previsão em múltiplos regimes hidrológicos ao longo das séries históricas consideradas.
- Avaliar e comparar, por meio de simulações computacionais com dados reais de bacias hidrográficas brasileiras, a eficácia das abordagens propostas frente a metodologias

de diferentes paradigmas, como o modelo conceitual atualmente empregado pelo ONS (SMAP/ONS) e modelos de referência do estado da arte, incluindo redes LSTM e outros modelos fuzzy, tanto estáticos quanto evolutivos.

- Investigar a robustez e a capacidade de generalização dos modelos evolutivos por meio de três estudos de caso: (a) desempenho em regimes sazonais típicos; (b) estabilidade durante eventos extremos de estresse hídrico; e (c) generalização espacial em bacias com características distintas.

## 1.2 CONTRIBUIÇÕES

As principais contribuições da presente tese são resumidas a seguir:

- O desenvolvimento de três novos modelos fuzzy evolutivos aprimorados, denominados: *Variable Step-Size Adaptive evolving Multivariable Gaussian* (VSA-eMG), *Modified Variable Step-Size Adaptive evolving Multivariable Gaussian* (MVSA-eMG) e *Modified Variable Step-Size evolving Multivariable Gaussian* (MVS-eMG). No escopo da revisão bibliográfica realizada nesta tese, não foram identificadas aplicações anteriores desses mecanismos adaptativos de atualização de hiperparâmetros em sistemas fuzzy evolutivos para previsão de vazões.
- O desenvolvimento e a implementação de um protocolo experimental robusto baseado em validação cruzada com janelas expandidas, utilizando sete períodos de teste independentes distribuídos ao longo das séries históricas. Diferentemente da prática usual na literatura, esse protocolo integra diferentes regimes hidrológicos sazonais (cheias, secas e períodos de transição), oferecendo uma avaliação mais fidedigna do desempenho dos modelos em condições mais próximas à realidade operativa.
- A realização de uma análise inédita de robustez e generalização espacial, avaliando a capacidade dos modelos de manterem o desempenho preditivo na Região Hidrográfica do Paraná, tanto em condições típicas quanto em cenários de estresse hídrico severo, bem como em bacias hidrográficas de regimes distintos (Regiões Hidrográficas do São Francisco e Tocantins–Araguaia), sem necessidade de reotimização de parâmetros.
- Uma validação abrangente e comparativa das abordagens propostas em relação a diferentes modelos de referência da literatura e da prática operacional, incluindo o modelo operacional adotado pelo setor elétrico brasileiro (SMAP/ONS), o modelo fuzzy evolutivo base (eMG), um modelo fuzzy evolutivo pertencente à mesma família e representativo do estado da arte (VS-eMG), um modelo fuzzy estático de referência (FIG-FTS) e uma arquitetura de aprendizado profundo baseada em redes neurais (LSTM), amplamente utilizada como referência no estado da arte para previsão

hidrológica. Os resultados demonstram superioridade estatística na maioria dos cenários avaliados, confirmando a viabilidade operacional dos modelos propostos.

Essas contribuições demonstram o potencial de modelos evolutivos aprimorados não apenas como ferramentas acadêmicas, mas também como alternativas promissoras para previsão de vazões, com potencial de aplicação em contextos operacionais reais e dinâmicos.

### 1.3 PRODUÇÃO CIENTÍFICA RELACIONADA

A produção científica relacionada a este trabalho é apresentada a seguir, contemplando dois artigos em periódicos científicos internacionais das áreas de hidrologia e de sistemas evolutivos, e um artigo em congresso científico nacional. Esses estudos decorrem diretamente do desenvolvimento desta tese, reforçando a relevância do tema e consolidando parte das contribuições científicas obtidas ao longo da pesquisa de doutorado.

- ROCHA, M. V. G.; ALVES, T. R.; SILVA JUNIOR, I. C. Improved Short-Term Streamflow Forecasting in Brazilian Basins Using Novel Enhanced Evolving Multivariable Gaussian Models. *Sustainable Water Resources Management*, 2026.
- ROCHA, M. V. G.; SILVA JUNIOR, I. C. Enhanced Evolving Multivariable Gaussian Model for Short-Term Streamflow Forecasting Under Non-Stationary Hydrological Conditions. *Evolving Systems*, 2026. Em avaliação.
- ROCHA, M. V. G.; ALVES, T. R.; SILVA JUNIOR, I. C. Previsão de Vazões para Bacias do Sistema Interligado Brasileiro Utilizando Modelo Gaussiano Multivariável Evolutivo Aprimorado. Em: 57<sup>o</sup> Simpósio Brasileiro de Pesquisa Operacional (SBPO), Gramado-RS, 2025.

### 1.4 ESTRUTURA DO TRABALHO

Este documento está estruturado da seguinte forma: Capítulo 2 apresenta a fundamentação teórica; Capítulo 3 detalha os materiais e métodos utilizados, incluindo os modelos propostos, modelos de referência, áreas de estudo e o protocolo experimental; Capítulo 4 apresenta o Estudo de Caso 1, focado na análise de desempenho em condições hidrológicas representativas; Capítulo 5 apresenta o Estudo de Caso 2, avaliando a robustez dos modelos sob estresse hídrico; Capítulo 6 apresenta o Estudo de Caso 3, investigando a generalização espacial e a adaptação a regimes hidrológicos distintos; Capítulo 7 promove a discussão integrada dos resultados e limitações; por fim, o Capítulo 8 apresenta as conclusões e recomendações para trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

A gestão eficiente dos recursos hídricos depende da capacidade de antecipar o comportamento dos sistemas fluviais. Nesse contexto, a previsão de vazão constitui um problema central da hidrologia aplicada, pois busca representar e antecipar a dinâmica dos sistemas fluviais a partir de informações observacionais e modelos matemáticos. Conforme destacado por Modi et al. (2025), previsões de vazão confiáveis são ferramentas essenciais para a tomada de decisão em múltiplos setores, especialmente em escalas sazonais, nas quais incertezas acumuladas podem comprometer estratégias de planejamento e operação. A relevância dessas previsões estende-se além da geração de energia, sendo importante para a mitigação de riscos de inundações, o planejamento agrícola, a alocação eficiente de água e a manutenção de serviços ecossistêmicos.

Previsões de vazão confiáveis são fundamentais para a gestão de riscos hidrológicos e a tomada de decisão operacional. Por exemplo, no contexto da prevenção de enchentes, sistemas eficazes de alerta dependem de tecnologias avançadas de previsão, essenciais para a análise de risco e a preparação frente a eventos extremos (LIM et al., 2022). Na operação de usinas hidrelétricas, a acurácia das previsões é determinante para o planejamento do vertimento e para a segurança de trabalhadores, equipamentos e populações a jusante (NASCIMENTO et al., 2021). Adicionalmente, Lu et al. (2017) demonstram que previsões com altos níveis de confiabilidade são indispensáveis para viabilizar instrumentos de mercado, como contratos futuros de energia, evidenciando a necessidade de modelos capazes de incorporar e quantificar incertezas.

Diante desse panorama, este capítulo apresenta os fundamentos teóricos que sustentam a previsão de vazão e a modelagem hidrológica baseada em dados. Inicialmente, discute-se a previsão de vazão no contexto do Sistema Interligado Nacional, destacando suas implicações operacionais. Em seguida, é apresentada uma visão geral da literatura sobre modelagem hidrológica orientada a dados. Na sequência, são discutidos os fundamentos dos sistemas fuzzy e suas aplicações na hidrologia. Por fim, são abordados os sistemas fuzzy evolutivos, que constituem a base conceitual deste trabalho.

### 2.1 PREVISÃO DE VAZÃO NO CONTEXTO DO SISTEMA INTERLIGADO NACIONAL

No contexto brasileiro, a previsão de vazão é um tema de grande importância para a operação do Sistema Interligado Nacional (SIN), sendo fundamental para o planejamento da geração de energia elétrica pelo Operador Nacional do Sistema Elétrico (ONS). Embora o ONS utilize uma cadeia complexa de modelos computacionais para diferentes horizontes e finalidades, o modelo chuva-vazão *Soil Moisture Accounting Procedure* (SMAP) (LOPES; BRAGA; CONEJO, 1982), que é um modelo clássico de contabilidade da umidade do solo,

é uma das principais ferramentas empregadas na geração de previsões de vazão de curto prazo em bacias hidrográficas estratégicas do SIN. Ao longo dos anos, o modelo passou por adaptações e aprimoramentos operacionais, culminando na formulação atualmente em uso, denominada SMAP/ONS (Operador Nacional do Sistema Elétrico (ONS), 2017). Sua aplicação influencia diretamente o planejamento da operação do sistema elétrico e a dinâmica do mercado de energia no Brasil (MACIEL et al., 2020).

Apesar de amplamente consolidado, o uso de modelos conceituais baseados em processos físicos, como o SMAP/ONS, apresenta limitações relevantes, especialmente em bacias de grande porte e elevada complexidade hidrológica. Nesse sentido, Ávila et al. (2022) demonstraram que essas abordagens apresentam desempenho limitado nesse tipo de sistema, sugerindo a necessidade de metodologias alternativas capazes de preservar com maior fidelidade as propriedades estatísticas dos dados observados. Diante desse cenário, esforços de pesquisas reforçam a importância de investigar técnicas mais robustas e adaptativas para lidar com as incertezas hidrológicas no contexto brasileiro.

Por exemplo, Treisman et al. (2023) apresentaram uma avaliação comparativa envolvendo cinco metodologias distintas de geração de cenários sintéticos de vazão de curto e médio prazo, em um estudo conduzido em parceria entre o ONS, a Câmara de Comercialização de Energia Elétrica (CCEE) e instituições acadêmicas. Seus resultados indicaram que abordagens alternativas, como o modelo GHCen, quando comparadas ao modelo oficial PAR(p)-A, demonstraram vantagens em métricas de curto prazo e em análises baseadas em médias móveis. Diante dessas limitações e da crescente complexidade dos sistemas fluviais, abordagens baseadas em dados têm se mostrado alternativas promissoras para complementar ou substituir modelos conceituais tradicionais.

## 2.2 MODELAGEM HIDROLÓGICA BASEADA EM DADOS

No campo da hidrologia, a aplicação de técnicas de aprendizado de máquina (*machine learning* – ML) remonta à década de 1990 e, desde então, muitos pesquisadores têm explorado diversas abordagens para modelagem chuva–vazão e previsão de vazões em escala global (GIRIHAGAMA et al., 2022). Essas técnicas oferecem uma alternativa promissora, ou um complemento, às abordagens convencionais baseadas em modelos físicos ou estatísticos para a modelagem hidrológica, constituindo uma solução para superar os desafios associados à elevada complexidade, dinâmica e não linearidade observadas nos processos hidrológicos (CHANG; CHANG; CHEN, 2023).

Em uma revisão de mais de 700 estudos publicados ao longo dos últimos 40 anos, Troin et al. (2021) sistematizaram a evolução das previsões de vazão baseadas em conjuntos (*ensemble forecasting*), destacando seu papel consolidado em diferentes contextos operacionais. Os autores apontam que, embora abordagens baseadas em modelos físicos, estatísticos e climatológicos permaneçam relevantes, o estado da arte evidencia desafios

que tendem a ser enfrentados por meio de abordagens híbridas, combinando modelagem dinâmica com técnicas de aprendizado estatístico.

Nesse contexto, Jahanbani, Ahmed e Gu (2024) analisaram a aplicabilidade de técnicas de previsão baseadas em inteligência computacional orientada a dados (*data-driven*), ou seja, que aprendem padrões diretamente a partir das séries históricas de vazão sem dependerem explicitamente de modelos físicos. Esses métodos têm ganhado destaque devido à sua capacidade e flexibilidade em capturar as dinâmicas complexas de processos hidrológicos. Essa perspectiva reforça a importância de investigar métodos de inteligência computacional capazes de compor sistemas de previsão mais robustos, adaptativos e adequados à representação explícita da incerteza hidrológica.

Diversos estudos têm explorado técnicas de aprendizado de máquina na previsão hidrológica, reportando ganhos de desempenho em relação a abordagens tradicionais, bem como desafios associados à interpretabilidade e à adaptação a regimes não estacionários. Ghorbani et al. (2016) compararam arquiteturas clássicas, como Redes Neurais Artificiais (MLP e RBF) e Máquinas de Vetores de Suporte (SVM), para previsão de vazão em rios. Toledo et al. (2021) mostraram que o desempenho de previsão pode ser melhorado ao incluir variáveis climáticas exógenas em modelos baseados em kernel, como a *Support Vector Regression* (SVR). Mais recentemente, Khozani, Precht e Ionita (2025) avaliaram horizontes semanais, comparando redes MLP, SVR, métodos baseados em instâncias (KNN) e técnicas de *boosting* (XGBoost), reforçando o potencial dessas abordagens como alternativas robustas à modelagem tradicional.

A literatura também revela uma tendência consistente de desenvolvimento de modelos híbridos complexos para aprimorar o desempenho de arquiteturas tradicionais. Por exemplo, estudos mostram que a precisão de modelos clássicos como o Perceptron Multicamadas (MLP) pode ser significativamente aprimorada ao integrá-los com algoritmos avançados de otimização. Abordagens como *Grey Wolf Optimization* (GWO) (TIKHAMARINE et al., 2020), *Intelligent Water Drop* (IWD) (PHAM et al., 2020) e *Sunflower Optimization* (SFA) (SAMMEN et al., 2021) foram propostas para superar limitações tradicionais do MLP, como a convergência a mínimos locais e a lentidão no processo de convergência.

Entre as técnicas de estado da arte em hidrologia, modelos de aprendizado profundo (*deep learning*) têm se tornado uma área de investigação central devido à sua capacidade de capturar dependências temporais complexas em séries temporais hidrológicas. As redes *Long Short-Term Memory* (LSTM) (HOCHREITER; SCHMIDHUBER, 1997), em particular, são amplamente utilizadas para essa finalidade (MACIEL et al., 2020).

Aplicações avançadas demonstraram que o desempenho das redes LSTM pode ser significativamente aprimorado ao incorporar inovações arquiteturais, como mecanismos de atenção (GIRIHAGAMA et al., 2022), ou ao integrá-las a estruturas mais complexas,

como modelos de decomposição *ensemble* projetados para melhorar previsões de cheias (LIU et al., 2025).

Contudo, limitações inerentes às arquiteturas recorrentes têm impulsionado a investigação de alternativas mais adequadas a horizontes de previsão extensos. Nesse cenário, Tepetidis et al. (2024) analisaram o modelo *Informer*, uma variante de arquiteturas *Transformer*, com o objetivo de mitigar problemas de custo computacional e memória associados a modelos tradicionais de aprendizado profundo em aplicações de previsão de vazão. Além dos desafios computacionais, a representação de intervenções físicas também impulsiona novas abordagens.

Wang et al. (2023), por exemplo, propuseram um método híbrido físico-estatístico que acopla o modelo SWAT a funções de cópula, visando capturar tanto a dinâmica hidrológica quanto as dependências estatísticas associadas à variabilidade espacial e aos impactos de atividades humanas. Os resultados indicaram que a abordagem híbrida superou modelos puramente baseados em aprendizado profundo, como redes LSTM, especialmente em cenários caracterizados por forte regulação antrópica e presença de múltiplos reservatórios.

Acompanhando essa tendência global, pesquisas no Brasil também têm explorado uma ampla gama de abordagens orientadas a dados para melhorar as previsões hidrológicas no contexto do SIN. Exemplos incluem a aplicação de arquiteturas de ponta como *Temporal Fusion Transformers* (TFT) (MUNIZ et al., 2025), o uso de métodos *ensemble* como o método *Bayesian Model Averaging* (BMA) (TORRES et al., 2024), a aplicação de redes LSTM para previsão diária em bacias nacionais (MACIEL et al., 2020) e a investigação de diferentes fontes de dados, como previsões climáticas de larga escala (NETO et al., 2023; ÁVILA et al., 2023) ou índices climáticos específicos para aprimorar o desempenho dos modelos (TOLEDO et al., 2023; TOLEDO, 2023).

A literatura evidencia uma tendência ao desenvolvimento de arquiteturas cada vez mais complexas como estratégia para aprimorar o desempenho preditivo em aplicações hidrológicas. Embora esses avanços tenham ampliado a capacidade de representar dinâmicas não lineares, frequentemente implicam maior custo computacional, aumento da complexidade de parametrização e redução da interpretabilidade dos modelos. Além disso, em cenários hidrológicos dinâmicos, modelos de estrutura fixa podem apresentar limitações para manter o desempenho ao longo do tempo, reforçando o interesse por abordagens capazes de combinar desempenho preditivo com mecanismos de aprendizado incremental e adaptação contínua.

### 2.3 SISTEMAS FUZZY: CONCEITOS GERAIS E APLICAÇÃO NA HIDROLOGIA

A teoria da Lógica Fuzzy (*Fuzzy Logic* – FL), introduzida por Zadeh (1965), constitui uma abordagem baseada em regras do tipo “se–então”, voltada à modelagem de sistemas caracterizados por incerteza e imprecisão, por meio da utilização de conjuntos fuzzy e funções de pertinência. Essa modelagem é realizada por meio da atribuição de graus de pertinência aos dados de entrada, permitindo sua representação de forma gradual, em contraste com abordagens baseadas em valores exatos.

Na previsão de vazão, a aplicação da teoria de lógica fuzzy tem demonstrado melhorias significativas, principalmente quando combinada com algoritmos de aprendizado de máquina (ML), em comparação com a aplicação isolada dos modelos de ML. Em outras palavras, a lógica fuzzy funciona como uma ferramenta de suporte importante aos modelos de ML, contribuindo para previsões mais precisas e oferecendo melhores soluções frente à complexidade do problema de previsão (JAHANBANI; AHMED; GU, 2024).

Embora muitas abordagens baseadas em dados utilizem modelos de estrutura fixa, Sistemas Fuzzy (FS) representam um paradigma baseado em regras que oferece um conjunto distinto de vantagens para lidar com a incerteza hidrológica. Esses sistemas têm ganhado crescente atenção em estudos ambientais e hidrológicos devido à sua capacidade de lidar com incerteza, não linearidade e a natureza dinâmica dos processos naturais.

Nesse sentido, Silva et al. (2019) ressaltam que a modelagem explícita da incerteza, aliada ao baixo custo computacional, reforça a versatilidade dos sistemas fuzzy em cenários de tomada de decisão sob risco. Khazaeiathar et al. (2022) demonstraram que técnicas de *clustering* baseadas em fuzzy podem identificar padrões de comportamento semelhantes em séries temporais de vazões, simplificando a estrutura dos modelos e melhorando a precisão das previsões.

Tripura, Roy e Barbhuiya (2021) mostraram que integrar lógica fuzzy com redes neurais possibilita a incorporação de conhecimento humano e o tratamento da ambiguidade inerente aos sistemas hidrológicos, resultando em previsões mais precisas e robustas do que abordagens neurais convencionais. Além disso, Severiano et al. (2021) destacaram que sistemas fuzzy fornecem uma representação interpretável e adaptativa, capaz de lidar com mudanças na distribuição dos dados (*concept drift*), além de exigir menor custo computacional quando comparados a modelos complexos de aprendizado profundo.

Isso evidencia um conhecido compromisso nessa área entre precisão preditiva e outras características desejáveis dos modelos, como interpretabilidade e eficiência computacional. A importância desse compromisso é reforçada pelas conclusões de Jahanbani, Ahmed e Gu (2024), que enfatizam que nenhum modelo orientado a dados é universalmente adequado para todos os cenários de previsão hidrológica, destacando a aplicabilidade de abordagens adaptativas e evolutivas capazes de se ajustar às diferentes condições hidroló-

gicas.

Um aspecto importante nesse campo é a capacidade de aprender a partir de fluxos contínuos de dados. Segundo Škrjanc et al. (2019), fluxos de dados (*data-streams*) são a principal razão para a necessidade de aplicar modelos evolutivos e adaptativos (ou seja, modelos capazes de ajustar seus parâmetros e estrutura conforme mudanças nos dados), dando origem aos sistemas fuzzy evolutivos. Isso se deve ao fato de que fluxos de dados representam sequências teoricamente infinitas de amostras, impossíveis de serem processadas em um único lote, impulsionando a adoção de modelos capazes de aprender e se adaptar incrementalmente.

## 2.4 SISTEMAS FUZZY EVOLUTIVOS: FUNDAMENTOS E MODELOS

Os primeiros trabalhos que fundamentaram o paradigma de Sistemas Fuzzy evolutivos (*evolving Fuzzy Systems* – eFS) basearam-se em redes neurais auto-organizáveis e nas arquiteturas fuzzy iniciais. Um avanço conceitual significativo ocorreu com o desenvolvimento da classe de modelos baseados na estrutura Takagi–Sugeno (TS) (TAKAGI; SUGENO, 1985). Essa abordagem introduziu uma estrutura capaz de representar dinâmicas não lineares, múltiplos modos de operação e variações de parâmetros e estrutura.

Fritzke (1994) propôs uma rede auto-organizável para aprendizado supervisionado e não supervisionado, denominada SONFIN, posteriormente expandida para uma versão recorrente, RSONFIN (JUANG; LIN, 1998; JUANG; LIN, 1999). Paralelamente, Kasabov (2001) introduziu o modelo EFuNN, com aprendizado local e incremental, e posteriormente apresentou o modelo DENFIS, que estima a saída comparando a posição do vetor de entrada com regras existentes (KASABOV; SONG, 2002). Esses modelos iniciais inspiraram o desenvolvimento de arquiteturas fuzzy evolutivas mais complexas.

É importante destacar que, no contexto da literatura consolidada sobre sistemas fuzzy evolutivos, o termo evolutivo (*evolving*) refere-se à capacidade desses modelos de adaptar sua estrutura incrementalmente (isto é, a evolução das regras) à medida que novos dados se tornam disponíveis, permitindo um aprendizado online. Por convenção na literatura, o termo evolutivo é tradicionalmente grafado com “e” minúsculo nos nomes dos modelos e em seus respectivos acrônimos (por exemplo, eTS, ePL), associando-os especificamente a essa família de modelos.

É fundamental, portanto, distinguir este conceito daquele empregado na Computação Evolutiva (*Evolutionary Computation*), tradicionalmente associado a algoritmos de otimização populacional bio-inspirados, como os Algoritmos Genéticos (AG) e a Otimização por Enxame de Partículas (PSO). No contexto desta tese, o termo evolutivo denota exclusivamente a adaptação estrutural incremental dos modelos baseados em lógica fuzzy para lidar com fluxos contínuos de dados, não estando relacionado a mecanismos de seleção natural, operadores genéticos ou gerações.

No início dos anos 2000, Angelov e Filev (2003), Angelov e Filev (2004) propuseram o modelo *evolving Takagi–Sugeno* (eTS), que atualiza o sistema recursivamente por meio da adição ou atualização de regras, introduzindo formalmente o conceito de evolução estrutural incremental em sistemas fuzzy, ampliando sua capacidade de adaptação em sistemas complexos. O modelo eTS é encontrado na literatura como referência para uma ampla variedade de modelos fuzzy evolutivos, incluindo: Simpl\_eTS (ANGELOV; FILEV, 2005), xTS (ANGELOV; ZHOU, 2008), Mod\_eTS (BIREK; PETROVIC; BOYLAN, 2014), eTS+ (ANGELOV; FILEV; KASABOV, 2010), Simpl\_eTS+ (ANGELOV, 2011), eTS-LS-SVM (KOMIJANI et al., 2012) e eTS-KRLS (SHAFIEEZADEH-ABADEH; KALHOR, 2016).

Outros modelos relevantes desse período incluem FLEXFIS (LUGHOFER, 2008) e SOFMLS (RUBIO, 2009). Lima et al. (2010) introduziram o modelo *evolving Participatory Learning* (ePL), que incorpora o conceito de Aprendizado Participativo (*Participatory Learning* – PL). O ePL serviu de base para o desenvolvimento do modelo eMG (LEMOS; CAMINHAS; GOMIDE, 2010), e foi posteriormente estendido para as variantes ePL+ (MACIEL; GOMIDE; BALLINI, 2012) e ePL-KRLS (MACIEL et al., 2017).

Os eFS são destacados na literatura como sistemas fuzzy altamente adaptativos, combinando a capacidade de compactação e representação de informações evolutivas dos sistemas fuzzy com métodos recursivos de aprendizado de máquina. Essa arquitetura permite que os eFS aprendam continuamente a partir de fluxos de dados, adaptando sua estrutura e funcionalidade de forma dinâmica (VIEIRA; GOMIDE; BALLINI, 2018). Como resultado, algoritmos de clusterização baseados nesse processo de aprendizado tendem a ser robustos a dados ruidosos, pois outliers isolados provavelmente serão incompatíveis com a crença atual do sistema e, conseqüentemente, poderão ser descartados ou ter seus efeitos suavizados (LEMOS; CAMINHAS; GOMIDE, 2010).

Essa robustez teórica também é corroborada na prática hidrológica, uma vez que estudos têm demonstrado que sistemas fuzzy evolutivos e de aprendizado online são particularmente eficazes ao lidar com processos chuva–vazão não estacionários, onde modelos de estrutura fixa podem ter dificuldades em manter o desempenho. Por exemplo, modelos neuro-fuzzy evolutivos (como o GSETSK) demonstraram produzir bases de regras mais compactas e adaptativas do que abordagens estáticas como o ANFIS, resultando em maior eficiência em aplicações complexas (ASHRAFI; CHUA; QUEK, 2019).

De forma semelhante, tem sido relatado que sistemas fuzzy evolutivos online podem alcançar desempenho comparável ao de modelos baseados em processos físicos (como o HEC-HMS) na modelagem chuva–vazão baseada em eventos, oferecendo maior flexibilidade sob condições de disponibilidade limitada de dados (KWIN et al., 2016). No contexto de bacias brasileiras, evidências indicam que sistemas fuzzy evolutivos podem superar modelos tradicionais como o SMAP na previsão de afluência, especialmente quando mecanismos

de aprendizado adaptativo são empregados para lidar com regimes hidrológicos variáveis (LUNA et al., 2009).

Entre as arquiteturas de sistemas fuzzy evolutivos, destaca-se o modelo *evolving Multivariable Gaussian* (eMG), proposto por Lemos, Caminhas e Gomide (2010), devido às suas características estruturais e ao seu mecanismo adaptativo de aprendizado, que proporcionam flexibilidade e precisão na representação dos dados. De acordo com Orellana et al. (2025), modelos multivariáveis podem incorporar explicitamente o comportamento da incerteza à sua estrutura, explorando distribuições probabilísticas assimétricas para representar e caracterizar adequadamente a incerteza.

A estrutura do modelo eMG baseia-se no conceito de Aprendizado Participativo, o que permite uma adaptação eficiente da base de regras à medida que o fluxo de dados evolui. Entre suas características principais estão o uso de funções de pertinência multivariáveis nos antecedentes das regras, que preservam interações entre variáveis de entrada, além de um algoritmo de clusterização recursivo robusto a ruídos e outliers devido ao efeito de suavização promovido pelo conceito de PL.

A aplicação do eMG em tarefas de previsão, identificação e monitoramento se encontra bem documentada na literatura. Souza et al. (2012), por exemplo, demonstraram a eficácia desses modelos na modelagem térmica de transformadores de potência, evidenciando seu potencial em ambientes industriais dinâmicos e sujeitos a incertezas. Essa linha de pesquisa foi posteriormente expandida com o desenvolvimento de novas variantes evolutivas para modelagem térmica, conforme discutido em Rocha et al. (2021), Rocha et al. (2022).

Estudos recentes também têm explorado o modelo eMG em diferentes contextos de previsão e identificação de sistemas, demonstrando sua versatilidade e robustez em múltiplos domínios de aplicação. Por exemplo, Mei, Zhao e Gu (2024) incluíram o eMG como modelo de referência em um estudo comparativo de sistemas fuzzy evolutivos para identificação de sistemas não lineares, confirmando sua relevância contínua na área. Do mesmo modo, Linhares e Silva (2023) aplicaram o eMG como modelo de referência para previsão em fluxos de dados em tempo real, destacando seu desempenho estável e consistente em condições dinâmicas.

Modelos mais recentes têm incorporado diferentes mecanismos adaptativos de atualização de hiperparâmetros baseados no erro, aprimorando o desempenho dos eFS. Nesse cenário, destacam-se os modelos adaptativos SM-ePL-KRLS e ESM-ePL-KRLS (ALVES et al., 2020), bem como o modelo VS-ePL-KRLS (QUEIROZ et al., 2022), variantes aprimoradas do modelo ePL-KRLS. De forma semelhante, o modelo eMG deu origem a diferentes variantes, com destaque para os modelos adaptativos SM-eMG e ESM-eMG (ROCHA et al., 2021), bem como os modelos MSM-eMG e VS-eMG (ROCHA et al., 2022).

Paralelamente, outros trabalhos propuseram melhorias no algoritmo central do eMG, introduzindo novos mecanismos de gerenciamento de regras (RODRIGUES; SILVA; LEMOS, 2022) ou desenvolvendo arquiteturas específicas para aplicações como previsão espaço-temporal (SEVERIANO et al., 2021). Todos esses modelos têm apresentado aumento consistente em adaptabilidade e robustez, bem como melhorias de desempenho em relação aos seus modelos evolutivos de base. Assim, nesse cenário de avanços e aprimoramentos, o eMG é adotado como base para as abordagens propostas neste trabalho, conforme apresentado no capítulo a seguir.

Por fim, estabelece-se uma distinção conceitual importante: enquanto o termo evolutivo, como definido anteriormente, refere-se à capacidade de modificar a estrutura do próprio modelo fuzzy (isto é, a evolução do conjunto de regras), o termo adaptativo (*adaptive*), embora frequentemente utilizado como sinônimo de evolutivo na literatura de eFS, designa neste trabalho o ajuste dinâmico de hiperparâmetros em resposta à variação do erro, em concordância com a terminologia oriunda da filtragem adaptativa. Essa definição será adotada de forma consistente nas seções subsequentes, nas quais os mecanismos adaptativos passam a ser explicitamente discutidos e explorados. Tais mecanismos atuam de maneira complementar à estrutura evolutiva, refinando a plasticidade dos modelos ao longo do processo de aprendizado incremental.

Em síntese, esta fundamentação teórica evidencia que, embora modelos físicos e abordagens baseadas em aprendizado profundo tenham contribuído de forma significativa para a previsão hidrológica, persistem desafios associados à adaptação online, à interpretabilidade e à robustez em cenários caracterizados por alta variabilidade hidrológica. Nesse cenário, os Sistemas Fuzzy evolutivos (em particular o modelo eMG e suas variantes aprimoradas) destacam-se como alternativas promissoras para aplicações operacionais de previsão de vazão, ao combinar capacidade de aprendizado incremental, flexibilidade estrutural e transparência do processo decisório. Esses aspectos motivam diretamente o desenvolvimento metodológico apresentado no capítulo seguinte.

### 3 MATERIAIS E MÉTODOS

Este capítulo apresenta a fundamentação metodológica que sustenta o desenvolvimento desta pesquisa. Inicialmente, é apresentado o modelo *evolving Multivariable Gaussian* (eMG), que serve de base para as abordagens propostas. Na sequência, são formalizados matematicamente os três modelos desenvolvidos neste trabalho, abordando seus respectivos mecanismos adaptativos. Também são apresentados os modelos de referência utilizados para comparação, incluindo o modelo operacional SMAP/ONS e outros benchmarks da literatura. Em seguida, são caracterizadas as bacias hidrográficas selecionadas para os estudos de caso. Por fim, é descrito pormenorizadamente todo o protocolo experimental desenvolvido para execução e avaliação dos modelos.

#### 3.1 EVOLVING MULTIVARIABLE GAUSSIAN (eMG)

O modelo *evolving Multivariable Gaussian* (eMG), proposto por Lemos, Caminhas e Gomide (2010), foi selecionado como base para este estudo porque suas características inerentes abordam diretamente os principais desafios na previsão hidrológica. Três características principais se destacam para a aplicação de previsão de vazão, conforme apresentado a seguir.

Primeiro, sua capacidade de aprendizado online permite a adaptação contínua a partir de um fluxo de dados. Essa abordagem incremental elimina a necessidade de retreinamento periódico do zero à medida que novas observações se tornam disponíveis, oferecendo uma vantagem operacional significativa sobre modelos de aprendizado em lote (offline). Segundo, o modelo é inerentemente capaz de capturar dinâmicas não lineares complexas; esta é uma característica importante, visto que a relação entre chuva e vazão é altamente não linear. Finalmente, sua estrutura baseada em regras fornece um grau de interpretabilidade, em contraste com modelos caixa-preta (*black-box*), como redes neurais, onde a lógica de tomada de decisão é distribuída entre milhares de parâmetros internos.

Em resumo, o modelo eMG opera por meio de um mecanismo de aprendizado online *single-pass*, no qual cada amostra é processada apenas uma vez, que pode ser conceitualmente dividido em três estágios sinérgicos, conforme ilustrado na Figura 1. No primeiro estágio, de inferência fuzzy, a estrutura baseada em regras vigente processa o vetor de entrada ( $x^k$ ) para calcular a previsão ( $\hat{y}^k$ ). O erro de previsão resultante é então usado para conduzir a adaptação nos estágios subsequentes.

No segundo estágio, de adaptação estrutural, o modelo utiliza o conceito de Aprendizado Participativo para decidir se cria uma nova regra ou atualiza uma existente. Ainda dentro desse estágio, ocorre o processo de atualização dos hiperparâmetros que é proposto nesse trabalho e será discutido e formalmente apresentado nas seções seguintes. Finalmente, no terceiro estágio, de adaptação de parâmetros, um algoritmo recursivo de

mínimos quadrados ponderados estima os parâmetros consequentes das regras existentes.

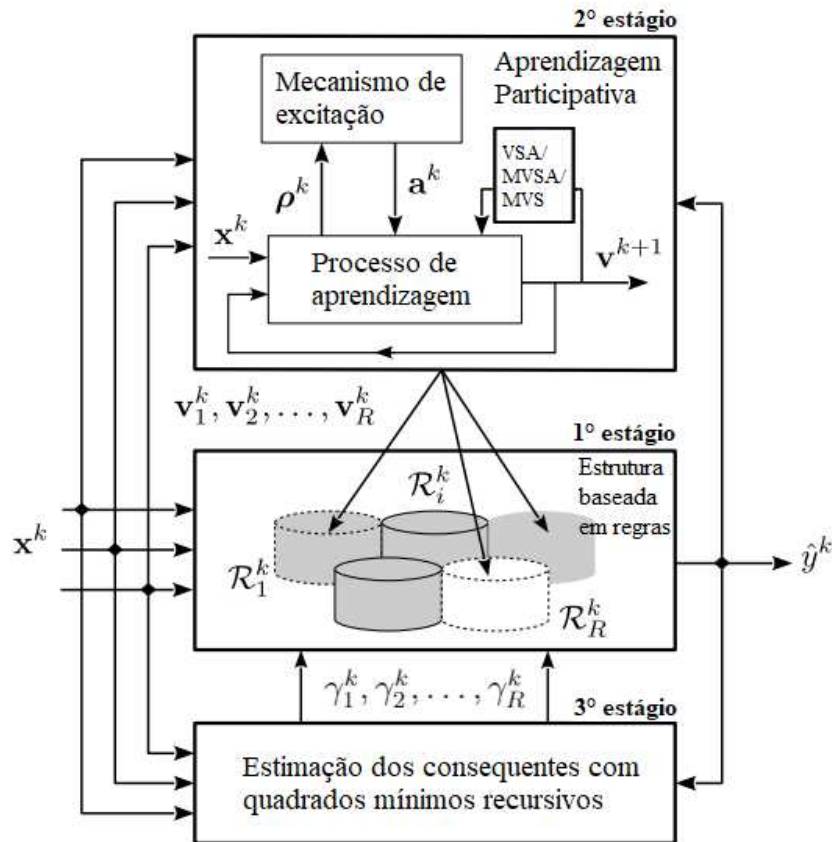


Figura 1 – Mecanismo de aprendizado do modelo eMG, que serve como base para as variantes adaptativas propostas. O diagrama destaca os três principais estágios de operação. Para cada vetor de entrada ( $x^k$ ), as regras fuzzy do modelo ( $\mathcal{R}_i^k$ ) produzem uma previsão ( $\hat{y}^k$ ). Variáveis internas incluem os centros de clusters ( $v_i^k$ ), parâmetros consequentes ( $\gamma_i^k$ ), medida de compatibilidade ( $\rho^k$ ) e índice de excitação ( $a^k$ ). O bloco de adaptação (VSA/MVSA/MVS), contribuição deste trabalho, indica onde os mecanismos propostos são aplicados dentro do processo de aprendizado. Adaptado de Rocha et al. (2021) e Lemos, Caminhas e Gomide (2010).

O eMG é um modelo fuzzy evolutivo que estabelece uma associação entre as funções de pertinência gaussianas multivariáveis, que compõem os antecedentes das regras, e os parâmetros estimados dessas funções de pertinência, que são obtidos por meio de um algoritmo de mínimos quadrados recursivos ponderados que atualiza os parâmetros dos consequentes das regras. A formulação do modelo é apresentada a seguir, baseada na proposta original de Lemos, Caminhas e Gomide (2010).

Este modelo utiliza o conceito de aprendizado participativo (*Participatory Learning* – PL) em seu processo de aprendizado (YAGER, 1990). O PL é um mecanismo que produz conhecimento a partir dos dados como parte do processo de aprendizagem. Como resultado, o aprendizado de um novo dado de entrada depende do que o sistema já aprendeu e impacta no aprendizado de entradas futuras.

O modelo executa este mecanismo para atualização de sua base de regras. O número de regras do modelo eMG corresponde ao número de clusters identificados pelo algoritmo de agrupamento em cada iteração. A cada passo, um novo cluster pode ser criado, um cluster existente pode ser atualizado ou removido, ou ainda dois clusters semelhantes podem ser mesclados. Desse modo, o conjunto de regras é dinamicamente ajustado ao longo de todo o processo de aprendizado.

Os antecedentes das regras são definidos a partir de conjuntos fuzzy gaussianos multivariáveis, construídos a partir do centro e da matriz de dispersão de cada cluster. Assim, cada regra  $\mathcal{R}_i$  assume a forma:

$$\mathcal{R}_i : \mathbf{SE} \ x^k \ \text{é} \ H_i \ \mathbf{ENTÃO} \ y_i^k = \gamma_{i0}^k + \sum_{j=1}^m \gamma_{ij}^k x_i^k \quad (3.1)$$

onde  $x^k$  é o vetor de entrada de dimensão  $1 \times m$ ,  $H_i$  é o conjunto fuzzy associado ao  $i$ -ésimo cluster,  $m$  é o número de variáveis de entrada,  $y_i^k$  é a saída local gerada pela  $i$ -ésima regra e  $\gamma_{i0}^k$  e  $\gamma_{ij}^k$  são os parâmetros consequentes no passo  $k$ .

A saída global é uma média ponderada das saídas locais, conforme apresentado na Equação 3.2:

$$\hat{y}^k = \sum_{i=1}^{c^k} \Psi_i(x^k) y_i^k \quad (3.2)$$

onde  $\Psi_i(x^k)$  são as funções de pertinência normalizadas, calculadas de acordo com a Equação 3.3:

$$\Psi_i(x^k) = \frac{\exp \left[ (x^k - v_i^k) \Sigma_i^{-1} (x^k - v_i^k)^T \right]}{\sum_{i=1}^{c^k} \exp \left[ (x^k - v_i^k) (\Sigma_i^k)^{-1} (x^k - v_i^k)^T \right]} \quad (3.3)$$

sendo  $v_i^k$  o centro do  $i$ -ésimo cluster, para  $i = 1, \dots, c^k$ , e  $c^k$  o número de regras no passo  $k$ .  $\Sigma_i^k$  é a matriz de dispersão estimada recursivamente conforme a Equação 3.4:

$$\Sigma_i^{k+1} = (1 - G_i^k) (\Sigma_i^k - G_i^k (x^k - v_i^k) (x^k - v_i^k)^T) \quad (3.4)$$

onde  $G_i^k$  é definido pela Equação 3.5:

$$G_i^k = \alpha (\rho_i^k)^{1-a_i^k} \quad (3.5)$$

onde  $\alpha \in [0, 1]$  é a taxa de aprendizado.

A medida de compatibilidade ( $\rho_i^k \in [0, 1]$ ) e o índice de excitação ( $a_i^k \in [0, 1]$ ) regem a atualização da base de regras, isto é, o processo de criação, atualização ou remoção de regras a cada passo  $k$ . A medida de compatibilidade indica o grau de similaridade entre uma nova entrada e os clusters existentes, sendo calculada pela Equação 3.6:

$$\rho_i^k = \exp \left[ -0,5(x^k - v_i^k)(\Sigma_i^k)^{-1}(x^k - v_i^k)^T \right] \quad (3.6)$$

O índice de excitação indica quando a estrutura de regras atual precisa ser revisada frente a uma nova entrada, atuando como um complemento da medida de compatibilidade. O cálculo do índice de excitação é apresentado na Equação 3.7:

$$a_i^k = p(NV_i^k < nv_i^k) \quad (3.7)$$

em que  $NV_i^k$  é a variável aleatória que representa o número de violações do limiar em uma janela de tamanho  $w$ , modelada por uma distribuição binomial, e  $nv_i^k$  é o valor observado dessa variável na janela considerada, calculado conforme a Equação 3.8:

$$nv_i^k = \begin{cases} \sum_{j=0}^{w-1} o_i^{k-j}, & k > w \\ 0, & \text{caso contrário} \end{cases} \quad (3.8)$$

e  $o_i^k$  indica as ocorrências das violações calculadas segundo a Equação 3.9:

$$o_i^k = \begin{cases} 0, & \text{se } M(x^k, v_i^k) < \chi_{n,\lambda}^2 \\ 1, & \text{caso contrário} \end{cases} \quad (3.9)$$

onde  $\chi_{n,\lambda}^2$  é uma distribuição qui-quadrado com  $n$  graus de liberdade,  $n$  é o número de amostras,  $\lambda \in [0, 1]$  é o nível de significância, e  $M(x^k, v_i^k)$  é a distância-M apresentada na Equação 3.10:

$$M(x^k, v_i^k) = (x^k - v_i^k)(\Sigma_i^k)^{-1}(x^k - v_i^k)^T \quad (3.10)$$

O modelo cria uma nova regra quando a medida de compatibilidade é menor que seu limiar ( $T_\rho$ ), e o índice de excitação associado a esta regra excede o seu limiar ( $T_a$ ), ou seja,  $\rho_i^k < T_\rho \quad \forall \quad i = 1, \dots, c^k$  e  $a_i^k > T_a$  para  $i = \arg \max_i \rho_i^k$ . Os valores de  $T_\rho$  e  $T_a$  são obtidos das Equações 3.11 e 3.12, respectivamente.

$$T_\rho = \exp \left( -0,5\chi_{m,\lambda}^2 \right) \quad (3.11)$$

$$T_a = 1 - \lambda \quad (3.12)$$

onde  $\chi_{m,\lambda}^2$  representa o valor da distribuição qui-quadrado com  $m$  graus de liberdade (correspondente à dimensão do vetor de entrada) para um nível de significância  $\lambda$ .

Ainda nesta etapa, o vetor de entrada inicializa o centro do cluster da nova regra, ou seja,  $v_{new} = x^k$ . Os parâmetros consequentes são calculados pela Equação 3.13:

$$\gamma_{new}^k = \frac{\sum_{i=1}^{c^k} \gamma_i^k \rho_i^k}{\sum_{i=1}^{c^k} \rho_i^k} \quad (3.13)$$

onde  $\omega \in [10^2, 10^4]$ . Também é atualizada a matriz de covariância  $Q_{new}^k = \omega I_{m+1}$ , onde  $I_{m+1}$  é uma matriz identidade de ordem  $m + 1$ .

Caso as condições para criação de uma nova regra não sejam satisfeitas, o modelo ajusta o centro do cluster associado à maior medida de compatibilidade usando a Equação 3.14:

$$v_i^{k+1} = v_i^k + G_i^k(x^k - v_i^k) \quad (3.14)$$

Finalmente, o modelo calcula a medida de compatibilidade entre duas regras usando a Equação 3.15 para eliminar clusters redundantes. Se a compatibilidade exceder o limiar, ou seja,  $\rho_i^k(v_j^k, v_i^k) > T_\rho$ , então a média dos dois centros de cluster substitui o centro do cluster mesclado, os parâmetros consequentes do novo cluster são atualizados conforme a Equação 3.16 e a matriz  $Q_{merged}^k$  é calculada conforme a Equação 3.17.

$$\rho_i^k(v_j^k, v_i^k) = \exp \left[ -0,5(v_j^k - v_i^k)(\Sigma_i^k)^{-1}(v_j^k - v_i^k)^T \right] \quad (3.15)$$

$$\gamma_{merged}^k = \frac{\gamma_i^k \rho_i^k + \gamma_j^k \rho_j^k}{\rho_i^k + \rho_j^k} \quad (3.16)$$

$$Q_{merged}^k = \omega I_{m+1} \quad (3.17)$$

Os parâmetros consequentes e a matriz  $Q$  são atualizados recursivamente pelas Equações 3.18 e 3.19, respectivamente, utilizando mínimos quadrados recursivos (LJUNG, 1999; ÅSTRÖM; WITTENMARK, 2013). Eles são inicializados como segue:  $\gamma^0 = [y^0 \ 0 \ \dots \ 0]$  e  $Q^k = \omega I_{m+1}$ .

$$\gamma_i^{k+1} = \gamma_i^k + Q_i^{k+1} x^k \Psi_i(x^k) [y_i^k - ((x^k)^T \gamma_i^k)] \quad (3.18)$$

$$Q_i^{k+1} = Q_i^k - \frac{\Psi_i(x^k) Q_i^k x^k (x^k)^T Q_i^k}{1 + (x^k)^T Q_i^k x^k} \quad (3.19)$$

Destaca-se, portanto, a importância do nível de significância ( $\lambda$ ) no eMG, uma vez que esse hiperparâmetro controla a criação e a adaptação das regras. Nesse sentido,  $\lambda$  é adotado como o principal parâmetro a ser ajustado pelos mecanismos adaptativos nos modelos propostos, conforme apresentado nas seções a seguir.

O Algoritmo 1 apresenta o pseudocódigo simplificado do eMG. As variáveis de entrada são descritas como a seguir:  $x$  é o vetor de entrada,  $y_d$  é o vetor de saída alvo,  $\lambda$  é o nível de significância,  $\Sigma_{init}$  é a matriz de dispersão inicial e  $w$  é o tamanho da janela. Como saída, obtém-se o valor de saída predito  $\hat{y}$ . O número final de regras, resultado do processo evolutivo, é considerado um indicador da complexidade estrutural do modelo.

---

**Algoritmo 1: Pseudocódigo Simplificado do Algoritmo eMG (evolving Multivariable Gaussian).**

---

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

**Saída:**  $\hat{y}$

**Inicialização:**  $v_1^1 = x^1, \gamma_1 = [y^1 \ 0 \ \dots \ 0], Q_1 = \omega I_{m+1}$

$\Sigma_{init} = \sigma I_m, T_a = 1 - \lambda, T_\rho = \exp(-0, 5\chi_{m,\lambda}^2)$

**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**

$o_i^k = 1$

**end**

**if**  $k > w$  **then**

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

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

**end**

**end**

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

Saída global:  $\hat{y}^k = \sum_{i=1}^c \Psi_i(x^k) y_i^k$

**if**  $\rho_i < T_\rho$  e  $a_i > T_a$  para  $i = \arg \max_i \rho_i^k$  **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**

  Atualiza um cluster existente:

  Encontra a regra mais compatível:  $i = \arg \max_i \rho_i^k$

  Atualiza o centro de regra e a matriz de dispersão

  // O mecanismo VSA/MVSA/MVS é inserido aqui

**end**

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

  Atualiza os parâmetros do consequente e a matriz  $Q$

**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:  $v_j = \text{mean}(v_i, v_j)$

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

    Mescla a matriz  $Q$  e os parâmetros do consequente

**end**

**end**

**end**

---

Análises empíricas demonstraram que o desempenho do modelo eMG pode ser significativamente afetado por pequenas alterações em certos hiperparâmetros (configurações determinadas a priori que controlam o treinamento, como taxa de aprendizado, tamanho da janela, entre outros) (ROCHA et al., 2021; ROCHA et al., 2022). Dentre estes, o nível de significância é particularmente importante, pois mesmo variações mínimas nesse hiperparâmetro podem ocasionar mudanças substanciais nos resultados. Desse modo, o nível de significância será utilizado nos mecanismos adaptativos de atualização de hiperparâmetros. Vale destacar que a aplicação de técnicas adaptativas a hiperparâmetros que, de outra forma, permaneceriam constantes durante o processo, melhora a adaptabilidade do modelo, uma vez que passam a ser atualizados com base em medidas de erro.

A partir dessa característica central, o eMG tem servido como base para o desenvolvimento de novos modelos que incorporam diferentes mecanismos de atualização adaptativa de hiperparâmetros. Trabalhos recentes exploraram essa direção ao propor variantes capazes de ajustar hiperparâmetros críticos de forma adaptativa em resposta ao erro, incluindo modelos como o SM-eMG (ROCHA et al., 2021) e o VS-eMG (ROCHA et al., 2022). Esses avanços demonstraram que a inclusão desses mecanismos pode aumentar substancialmente a capacidade de adaptação dos sistemas fuzzy evolutivos.

Essa vertente é amplamente explorada na literatura de eFS, na qual modelos evolutivos de base dão origem a novos modelos (variantes) com diferentes modificações estruturais, visando ganhos de desempenho e maior robustez frente a diferentes condições de operação, conforme discutido na Seção 2.4. A seguir são apresentados os modelos que compõem a família eMG utilizada ao longo de todo o trabalho.

### 3.1.1 Variable Step-Size evolving Multivariable Gaussian (VS-eMG)

O *Variable Step-Size evolving Multivariable Gaussian* (VS-eMG) é uma variante adaptativa do modelo eMG, introduzida em trabalhos anteriores (ROCHA et al., 2022). Nessa formulação, o nível de significância é atualizado dinamicamente a cada iteração com base no erro instantâneo, permitindo que o modelo ajuste sua sensibilidade estrutural a momentos de maior ou menor incerteza. Em estudos recentes, o VS-eMG apresentou desempenho superior quando comparado a outras variantes do eMG, sendo, portanto, adotado neste trabalho como benchmark representativo do estado da arte em sistemas fuzzy evolutivos.

O mecanismo central do VS-eMG atua modificando o nível de significância ( $\lambda$ ), segundo a Equação 3.20:

$$\lambda^{k+1} = \begin{cases} \frac{\lambda^k}{\beta}, & \text{se } |e^k| > \bar{\gamma} \\ \lambda^k \beta, & \text{caso contrário} \end{cases} \quad (3.20)$$

Quando o módulo do erro de predição no instante  $k$ , definido como  $|e^k| = |y^k - \hat{y}^k|$  (isto é, a diferença entre o valor observado  $y^k$  e o valor predito  $\hat{y}^k$ ), excede o limiar de sensibilidade  $\bar{\gamma}$ , o modelo aumenta o nível de significância através da divisão pelo parâmetro de adaptação  $\beta \in (0, 1]$ , tornando-se mais propenso à criação ou atualização de regras (característica denominada plasticidade). Caso contrário,  $\lambda$  é reduzido, induzindo um comportamento estrutural mais estável (implicando menor plasticidade). Esse ajuste dinâmico conduz a um equilíbrio entre capacidade adaptativa e robustez estrutural, característica que motiva seu uso como benchmark evolutivo neste estudo.

### 3.2 MODELOS PROPOSTOS

Nesta seção, são apresentadas as principais contribuições inéditas deste trabalho, consistindo no desenvolvimento de três novos modelos fuzzy evolutivos. Essas abordagens fundamentam-se na incorporação de mecanismos adaptativos de atualização de hiperparâmetros à estrutura do eMG original, conforme descrito a seguir.

Especificamente, são propostos os modelos *Variable Step-Size Adaptive evolving Multivariable Gaussian* (VSA-eMG), *Modified Variable Step-Size Adaptive evolving Multivariable Gaussian* (MVSA-eMG) e *Modified Variable Step-Size evolving Multivariable Gaussian* (MVS-eMG). Essas variantes do eMG original visam agregar funcionalidades distintas, ampliando sua adaptabilidade e aprimorando sua capacidade preditiva frente a dinâmicas complexas.

Para contextualizar a implementação operacional dessas abordagens, retoma-se o diagrama esquemático do fluxo de aprendizado apresentado anteriormente na Figura 1. Conforme ilustrado nesse esquema, as variantes propostas compartilham a mesma arquitetura base do eMG, diferenciando-se exclusivamente pela lógica interna do bloco de adaptação (identificado na figura como VSA/MVSA/MVS). É nesse módulo que os mecanismos adaptativos descritos nas subseções a seguir são integrados, atuando na atualização dinâmica do nível de significância ( $\lambda$ ), preservando a estrutura geral do mecanismo de aprendizado por regras.

A adoção de estratégias distintas de atualização do nível de significância reflete a necessidade de equilibrar plasticidade e estabilidade estrutural ao longo do aprendizado incremental. Ao atuar de maneira adaptativa sobre  $\lambda$ , em função do erro de previsão, os modelos propostos ganham a capacidade de modular, em tempo real, a sensibilidade do mecanismo de criação de regras.

Estratégias mais permissivas favorecem a expansão estrutural para capturar novas dinâmicas, enquanto abordagens mais restritivas priorizam a estabilidade do conjunto de regras e a parcimônia do sistema, favorecendo estruturas mais simples. Essa diferenciação nas regras de atualização dos mecanismos introduzidos altera a trajetória de aprendizado de cada variante, permitindo que os modelos desenvolvam características operacionais

distintas e, conseqüentemente, forneçam previsões com diferentes perfis de erro (aspecto fundamental para a robustez da modelagem em cenários de incerteza).

### 3.2.1 Variable Step-Size Adaptive evolving Multivariable Gaussian (VSA-eMG)

Uma contribuição inédita deste trabalho é o desenvolvimento, aplicação e avaliação extensiva de um novo modelo, variante do eMG, denominado *Variable Step-Size Adaptive evolving Multivariable Gaussian* (VSA-eMG). O modelo foi desenvolvido, em consonância com a literatura de modelos evolutivos, por meio do aprimoramento do modelo eMG original, ao se incorporar o mecanismo de adaptação de hiperparâmetros *Variable Step-Size Adaptive* (VSA) ao seu processo de aprendizado. Esse mecanismo tem origem em técnicas de filtragem adaptativa (HARRIS; CHABRIES; BISHOP, 1986; EVANS; XUE; LIU, 1993), desenvolvidas para melhorar a taxa de convergência de algoritmos de aprendizado online, preservando o desempenho em regime permanente.

Nesse contexto, o mecanismo VSA atua diretamente no processo de criação de regras do modelo eMG; mais especificamente, ele atua modificando o nível de significância ( $\lambda$ ) à medida que cada nova amostra  $k$  é processada. A lógica do mecanismo funciona da seguinte maneira: se o valor absoluto do erro  $|e^k|$  exceder um limiar de sensibilidade  $\bar{\gamma} \in [0, 1]$ , o valor de  $\lambda$  é acrescido de um parâmetro de adaptação,  $\beta \in (0, 1]$ . Caso contrário,  $\lambda$  é reduzido pelo mesmo parâmetro. Esse comportamento é formalmente definido pela Equação 3.21:

$$\lambda^{k+1} = \begin{cases} \lambda^k + \beta, & \text{se } |e^k| > \bar{\gamma} \\ \lambda^k - \beta, & \text{caso contrário} \end{cases} \quad (3.21)$$

Para garantir consistência, o valor de  $\lambda$  é restringido dentro de um intervalo válido definido por limites inferior ( $IL = 0$ ) e superior ( $SL = 1$ ). Caso o valor atualizado de  $\lambda$  ultrapasse algum desses limites, ele é ajustado para o limite válido mais próximo. Essa estrutura evita que o nível de significância adquira valores inconsistentes, preservando a estabilidade do modelo. O funcionamento detalhado do mecanismo VSA, implementado no modelo VSA-eMG, é descrito no Algoritmo 2.

---

**Algoritmo 2: Pseudocódigo do mecanismo VSA (Variable Step-Size Adaptive) utilizado no algoritmo eMG.**

---

```

 $e^k = y^k - \hat{y}^k$ 
if  $|e^k| > \bar{\gamma}$  then
  |  $\lambda^{k+1} = \lambda^k + \beta$ 
else
  |  $\lambda^{k+1} = \lambda^k - \beta$ 
end
if  $\lambda^{k+1} < IL$  then
  |  $\lambda^{k+1} = IL$ 
end
if  $\lambda^{k+1} > SL$  then
  |  $\lambda^{k+1} = SL$ 
end

```

---

Em síntese, o VSA-eMG aumenta a plasticidade (isto é, a capacidade de criar novas regras) do modelo quando o erro é elevado e reforça sua estabilidade quando o erro é baixo. Ao ajustar continuamente o nível de significância, o modelo torna-se capaz de responder às variações de regime presentes nas séries hidrológicas, mantendo boa capacidade de adaptação sem comprometer a estabilidade do aprendizado.

O mecanismo VSA é incorporado ao modelo eMG no ponto indicado no Algoritmo 1, controlando dinamicamente a atualização do nível de significância. Ressalta-se que essa integração preserva integralmente a estrutura original do eMG, mantendo inalteradas as etapas fundamentais de criação, atualização e remoção de regras. Vale notar que essa mesma arquitetura é adotada nos demais modelos propostos neste trabalho (MVSA-eMG e MVS-eMG), os quais diferem entre si exclusivamente pelo mecanismo de adaptação empregado nessa etapa específica do algoritmo, conforme será detalhado nas subseções seguintes.

### 3.2.2 Modified Variable Step-Size Adaptive evolving Multivariable Gaussian (MVSA-eMG)

Uma segunda contribuição inédita deste trabalho consiste no desenvolvimento e aplicação de um modelo baseado no eMG, denominado *Modified Variable Step-Size Adaptive evolving Multivariable Gaussian* (MVSA-eMG). Esta proposta fundamenta-se na incorporação do mecanismo *Modified Variable Step-Size Adaptive* (MVSA) (uma versão modificada do VSA apresentado na seção anterior) ao processo de aprendizado do eMG.

De modo análogo ao VSA-eMG, o mecanismo MVSA atua atualizando o nível de significância, porém de maneira distinta: quando o valor absoluto do erro  $|e^k|$  excede o limiar de sensibilidade  $\bar{\gamma} \in [0, 1]$ , o nível de significância ( $\lambda$ ) é incrementado pelo

parâmetro de adaptação  $\beta \in (0, 1]$ . Caso contrário, o nível de significância é zerado (reset), restringindo o processo de criação de regras e favorecendo a estabilidade estrutural do modelo. Esse comportamento é formalmente definido pela Equação 3.22:

$$\lambda^{k+1} = \begin{cases} \lambda^k + \beta, & \text{se } |e^k| > \bar{\gamma} \\ 0, & \text{caso contrário} \end{cases} \quad (3.22)$$

A mesma estrutura de restrição dos valores de  $\lambda$  dentro de um intervalo válido, definido pelos limites inferior ( $IL = 0$ ) e superior ( $SL = 1$ ), é aplicada de modo a garantir consistência e robustez na implementação. O Algoritmo 3 descreve o funcionamento do mecanismo MVSA conforme empregado neste trabalho.

---

**Algoritmo 3: Pseudocódigo do mecanismo MVSA (Modified Variable Step-Size Adaptive) utilizado no algoritmo eMG.**

---

```

 $e^k = y^k - \hat{y}^k$ 
if  $|e^k| > \bar{\gamma}$  then
  |  $\lambda^{k+1} = \lambda^k + \beta$ 
else
  |  $\lambda^{k+1} = 0$ 
end
if  $\lambda^{k+1} < IL$  then
  |  $\lambda^{k+1} = IL$ 
end
if  $\lambda^{k+1} > SL$  then
  |  $\lambda^{k+1} = SL$ 
end

```

---

O modelo MVSA-eMG apresenta propriedades distintas, no sentido de preservar a capacidade de aumento da plasticidade do modelo em cenários de elevado erro de previsão, ao mesmo tempo em que determina uma rápida redução dessa plasticidade, levando à estabilidade estrutural, quando o erro atinge níveis adequados. Esse comportamento favorece a convergência para estruturas mais estáveis, mitigando o crescimento excessivo do número de regras. Assim como no VSA-eMG, o mecanismo MVSA é incorporado ao modelo eMG no ponto indicado no Algoritmo 1, atuando exclusivamente sobre a atualização do nível de significância, sem alterar o fluxo lógico do algoritmo base.

### 3.2.3 Modified Variable Step-Size evolving Multivariable Gaussian (MVS-eMG)

A terceira contribuição inédita deste trabalho consiste no desenvolvimento e avaliação de um novo modelo, variante do eMG, denominado *Modified Variable Step-Size evolving Multivariable Gaussian* (MVS-eMG). Esta proposta baseia-se na incorporação do mecanismo Modified Variable Step-Size (MVS) (uma versão modificada do mecanismo *Variable Step-Size* (VS), também fundamentada em métodos de filtragem adaptativa (EVANS; XUE; LIU, 1993)) ao processo de aprendizado do eMG original.

O modelo MVS-eMG ajusta o nível de significância ( $\lambda$ ) a cada instante de tempo com base no erro de previsão, de maneira análoga ao VSA-eMG e ao MVSA-eMG. No entanto, adota uma regra de atualização distinta: quando o valor absoluto do erro  $|e^k|$  excede o limiar de sensibilidade  $\bar{\gamma}$ ,  $\lambda$  é dividido pelo parâmetro de adaptação  $\beta \in (0, 1]$ . Caso contrário,  $\lambda$  é redefinido para zero. Esse procedimento é formalmente descrito pela Equação 3.23:

$$\lambda^{k+1} = \begin{cases} \frac{\lambda^k}{\beta}, & \text{se } |e^k| > \bar{\gamma} \\ 0, & \text{caso contrário} \end{cases} \quad (3.23)$$

Aplica-se o mesmo procedimento de restrição de  $\lambda$  a um intervalo válido, definido pelos limites inferior ( $IL = 0$ ) e superior ( $SL = 1$ ), conforme adotado nos modelos VSA-eMG e MVSA-eMG. O funcionamento detalhado do mecanismo MVS, tal como implementado no modelo MVS-eMG, é descrito no Algoritmo 4.

---

**Algoritmo 4: Pseudocódigo do mecanismo MVS (Modified Variable Step-Size) utilizado no algoritmo eMG.**

---

```

 $e^k = y^k - \hat{y}^k$ 
if  $|e^k| > \bar{\gamma}$  then
  |  $\lambda^{k+1} = \lambda^k / \beta$ 
else
  |  $\lambda^{k+1} = 0$ 
end
if  $\lambda^{k+1} < IL$  then
  |  $\lambda^{k+1} = IL$ 
end
if  $\lambda^{k+1} > SL$  then
  |  $\lambda^{k+1} = SL$ 
end

```

---

A lógica desse modelo visa modular a plasticidade do modelo, porém de forma mais incisiva. Ao aumentar de maneira abrupta o valor de  $\lambda$  quando o erro de previsão é elevado, os limiares de criação de regras ( $T_\rho$  e  $T_a$ ) tornam-se mais permissivos, conduzindo o modelo a uma adaptação rápida. Em contrapartida, ao redefinir  $\lambda$  para zero quando o erro é reduzido, esses limiares tornam-se máximos, induzindo o modelo a um estado de elevada estabilidade estrutural.

No contexto da previsão de vazões, esse comportamento é particularmente vantajoso, pois permite que o modelo responda prontamente a mudanças hidrológicas abruptas, ao mesmo tempo em que preserva a estabilidade durante períodos de regime típico. O mecanismo MVS é incorporado ao modelo eMG no ponto indicado no Algoritmo 1, atuando exclusivamente sobre a atualização do nível de significância, sem alterar o fluxo lógico do algoritmo base.

### 3.2.4 Síntese dos Modelos Propostos

Embora todas as abordagens apresentadas compartilhem integralmente a arquitetura base do eMG, elas divergem fundamentalmente no mecanismo de atualização do nível de significância ( $\lambda$ ). Enquanto o eMG original mantém  $\lambda$  fixo, suas variantes avançadas introduzem mecanismos adaptativos para modular sua plasticidade frente à variabilidade do erro, cada uma com uma regra específica. A Tabela 1 sumariza as diferenças operacionais entre os modelos de referência (eMG (LEMOS; CAMINHAS; GOMIDE, 2010) e VS-eMG (ROCHA et al., 2022)) e as propostas inéditas (VSA-eMG, MVSA-eMG e MVS-eMG).

Percebe-se, a partir desses critérios, que o nível de significância exerce papel central no equilíbrio entre plasticidade e estabilidade do modelo, pois afeta simultaneamente os limiares de compatibilidade ( $T_\rho$ ) e de excitação ( $T_a$ ). Valores elevados de  $\lambda$  tornam os limiares mais permissivos, favorecendo a criação de novas regras e ampliando a capacidade adaptativa do modelo frente a mudanças no regime dos dados. Em contraste, valores reduzidos de  $\lambda$  impõem critérios mais restritivos tanto à compatibilidade quanto à excitação, promovendo maior estabilidade estrutural, menor crescimento do conjunto de regras e maior parcimônia ao longo do aprendizado incremental.

Do ponto de vista da complexidade computacional, os modelos propostos introduzem apenas um número reduzido de operações adicionais por iteração, consistindo essencialmente na comparação do erro, atualização de  $\lambda$  e verificação de limites. Nesse sentido, o controle adaptativo de  $\lambda$  tende a favorecer a convergência dos modelos ao reduzir atualizações estruturais desnecessárias. Dessa forma, os modelos propostos estabelecem uma relação entre o aumento incremental da complexidade estrutural, decorrente da incorporação dos mecanismos de adaptação de hiperparâmetros, e a melhoria da capacidade preditiva, associada ao aumento da adaptabilidade, promovendo simultaneamente um processo evolutivo parcimonioso e estável.

Tabela 1 – Síntese comparativa das estratégias de adaptação do nível de significância ( $\lambda$ ) responsáveis pela modulação da plasticidade e da estabilidade estrutural nos modelos evolutivos baseados no eMG.

<b>Modelo</b>	<b>Regra de Atualização de <math>\lambda</math></b>
eMG — <i>evolving Multivariable Gaussian</i> (LEMOS; CAMINHAS; GOMIDE, 2010)	$\lambda^{k+1} = \lambda^k$
VS-eMG — <i>Variable Step-Size evolving Multivariable Gaussian</i> (ROCHA et al., 2022)	$\lambda^{k+1} = \begin{cases} \frac{\lambda^k}{\beta}, & \text{se }  e^k  > \bar{\gamma} \\ \lambda^k \beta, & \text{caso contrário} \end{cases}$
<b>Modelos propostos</b>	
VSA-eMG — <i>Variable Step-Size Adaptive evolving Multivariable Gaussian</i>	$\lambda^{k+1} = \begin{cases} \lambda^k + \beta, & \text{se }  e^k  > \bar{\gamma} \\ \lambda^k - \beta, & \text{caso contrário} \end{cases}$
MVSA-eMG — <i>Modified Variable Step-Size Adaptive evolving Multivariable Gaussian</i>	$\lambda^{k+1} = \begin{cases} \lambda^k + \beta, & \text{se }  e^k  > \bar{\gamma} \\ 0, & \text{caso contrário} \end{cases}$
MVS-eMG — <i>Modified Variable Step-Size evolving Multivariable Gaussian</i>	$\lambda^{k+1} = \begin{cases} \frac{\lambda^k}{\beta}, & \text{se }  e^k  > \bar{\gamma} \\ 0, & \text{caso contrário} \end{cases}$

Em síntese, embora os modelos VSA-eMG, MVSA-eMG e MVS-eMG compartilhem a arquitetura evolutiva do eMG, a forma como o nível de significância é ajustado ao longo do aprendizado estabelece comportamentos operacionais distintos. Essa distinção permite avaliar o impacto de diferentes estratégias de adaptação de hiperparâmetros sobre o desempenho preditivo, frente à variabilidade dos regimes hidrológicos.

### 3.3 SOIL MOISTURE ACCOUNTING PROCEDURE (SMAP/ONS)

O modelo *Soil Moisture Accounting Procedure* (SMAP/ONS) é adotado como referência operacional (benchmark) no estudo principal conduzido neste trabalho (Estudo de Caso 1), por se tratar do modelo hidrológico conceitual empregado pelo Operador Nacional do Sistema Elétrico (ONS) no processo de previsão de vazões afluentes aos reservatórios do Sistema Interligado Nacional.

Destaca-se que, enquanto a formulação dos modelos eMG segue a notação generalista da literatura de sistemas evolutivos (vetores  $x$  e escalares  $y$ ), a descrição do modelo SMAP/ONS adota a terminologia específica do domínio hidrológico. Por esse motivo, embora a literatura utilize frequentemente a letra  $Q$  para representar vazão, neste trabalho adotam-se  $y$  e  $\hat{y}$  para denotar, respectivamente, a vazão observada e a vazão prevista nos demais capítulos, a fim de evitar ambiguidade com a matriz de covariância  $Q$ , intrínseca ao eMG (Equação 3.17). Dessa forma, o uso de  $Q$  como vazão restringe-se exclusivamente à presente seção, na qual a notação original da documentação do ONS é preservada.

O modelo SMAP foi originalmente desenvolvido por Lopes, Braga e Conejo (1982) e foi projetado para estimar os componentes do balanço hídrico em uma bacia, incluindo umidade do solo, evapotranspiração e escoamento. Em sua formulação clássica, o modelo SMAP é estruturado a partir de três reservatórios lineares hipotéticos: o reservatório do solo ( $R_{solo}$ ), responsável pelo armazenamento e processos de infiltração; o reservatório superficial ( $R_{sup}$ ), associado ao escoamento direto gerado na bacia; e o reservatório subterrâneo ( $R_{sub}$ ), que representa o escoamento de base.

A Figura 2 ilustra o diagrama representativo da metodologia SMAP. Ressalta-se que todas as variáveis e parâmetros de calibração ilustrados neste diagrama estrutural serão formalmente definidos e detalhados na sequência, conjuntamente com as equações do modelo.

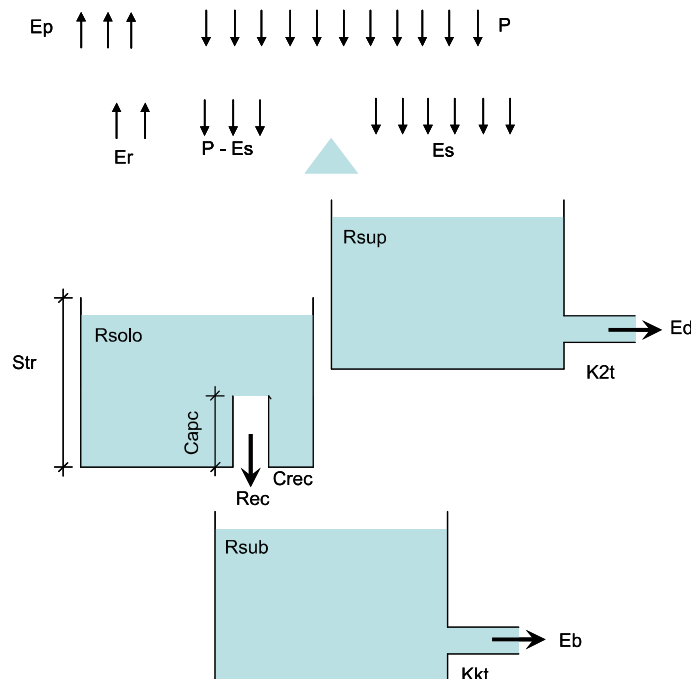


Figura 2 – Diagrama conceitual do modelo SMAP (Operador Nacional do Sistema Elétrico (ONS), 2017).

No presente estudo, emprega-se a versão operacional SMAP/ONS, formalmente apresentada pelo Operador Nacional do Sistema Elétrico (ONS) (2017), a qual incorpora uma série de aprimoramentos metodológicos com o objetivo de melhorar sua adequação às características das bacias hidrográficas brasileiras. As principais modificações em relação ao SMAP original incluem:

- uso de coeficientes de distribuição temporal da precipitação;
- aplicação de fatores de ajuste para a precipitação e evapotranspiração potencial;
- inclusão de um quarto reservatório, associado às áreas de planície;

- possibilidade de empregar até dois coeficientes de recessão no reservatório de escoamento superficial;
- implementação de um mecanismo de assimilação e otimização das variáveis de estado, permitindo que o modelo corrija suas estimativas com base no desvio entre as vazões simuladas e observadas imediatamente antes do dia de previsão.

A Figura 3 ilustra o diagrama representativo da metodologia SMAP/ONS.

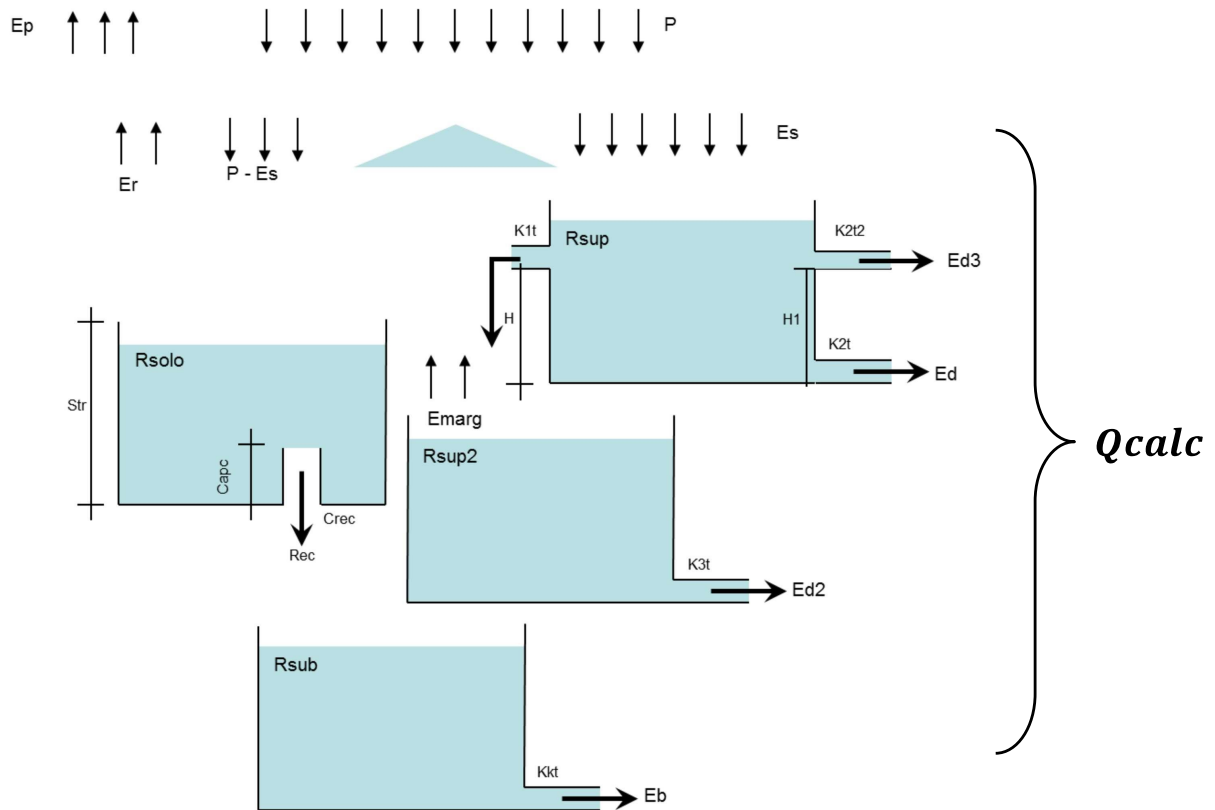


Figura 3 – Diagrama conceitual do modelo SMAP/ONS (Operador Nacional do Sistema Elétrico (ONS), 2017).

Para os propósitos deste estudo, a nomenclatura SMAP/ONS será empregada a partir deste ponto para indicar a implementação prática do modelo SMAP no ambiente operacional do ONS. Um resumo deste modelo determinístico é apresentado a seguir, com base em Alves (2024) e Operador Nacional do Sistema Elétrico (ONS) (2017).

A vazão é estimada com base nas descargas dos reservatórios que correspondem a diferentes elementos da bacia. Nesse processo, os totais diários da evapotranspiração potencial ( $E_p(t)$ ) e das vazões médias diárias observadas ( $Q_{obs}(t)$ ) são derivados das saídas do modelo.

Inicialmente, o modelo calcula a precipitação total diária da bacia,  $P_b(t)$  [mm/dia], como uma média ponderada da precipitação observada em cada estação, conforme definido nas Equações 3.24 e 3.25:

$$P_b(t) = \sum_{k=1}^n P_k(t)ke_k \quad (3.24)$$

$$\sum_{k=1}^n ke_k = 1 \quad (3.25)$$

onde  $P_k(t)$  são os valores de precipitação observados nas estações pluviométricas consideradas na bacia, e  $ke_k$  são os coeficientes de representação espacial de cada estação pluviométrica.

Em seguida, a precipitação média do dia,  $P_d(t)$  [mm/dia], é calculada como uma média ponderada da precipitação observada ao longo de uma janela temporal específica, conforme representado na Equação 3.26:

$$P_d(t) = \sum_{k=m}^n P_b(t+k)kt_k \quad (3.26)$$

onde  $kt_k$  são os coeficientes de representação temporal, e  $m$  e  $n$  definem a janela temporal considerada.

Assim, a precipitação média na bacia,  $P(t)$  [mm/dia], é computada conforme mostrado na Equação 3.27:

$$P(t) = P_d(t)P_{cof} \quad (3.27)$$

onde  $P_{cof}$  é o coeficiente de ajuste da precipitação, utilizado para ajustar o volume precipitado na bacia de modo a garantir o balanço hídrico.

Para representar o sistema hidrológico, o modelo SMAP/ONS emprega quatro reservatórios, cujas variáveis de estado são atualizadas a cada passo de tempo, conforme definido nas Equações 3.28, 3.29, 3.30 e 3.31:

$$Rsolo(t) = \min \left\{ Rsolo(t-1) + P(t) - Es(t) - Er(t) - Rec(t), Str \right\} \quad (3.28)$$

$$Rsub(t) = Rsub(t-1) + Rec(t) - Eb(t) \quad (3.29)$$

$$Rsup(t) = Rsup(t-1) + Es(t) - Marg(t) - Ed(t) - Ed3(t) + \max \left\{ 0, \left[ (Rsolo(t-1) + P(t) - Es(t) - Er(t) - Rec(t)) - Str \right] \right\} \quad (3.30)$$

$$R_{sup2}(t) = R_{sup2}(t - 1) + Marg(t) - Ed2(t) - Emarg(t) \quad (3.31)$$

onde:

- $R_{solo}(t)$  é o reservatório do solo no tempo  $t$  [mm];
- $R_{sub}(t)$  é o reservatório subterrâneo no tempo  $t$  [mm];
- $R_{sup}(t)$  é o reservatório superficial no tempo  $t$  [mm];
- $R_{sup2}(t)$  é o reservatório superficial e da planície de inundação no tempo  $t$  [mm];
- $Str$  é a capacidade de saturação de água no solo [mm];
- $P(t)$  é a precipitação média na bacia, considerada pelo modelo no tempo  $t$  [mm/dia];
- $Es(t)$  é o escoamento para o reservatório de superfície no tempo  $t$  [mm/dia];
- $Er(t)$  é a evapotranspiração real do solo no tempo  $t$  [mm/dia];
- $Rec(t)$  é a recarga subterrânea no tempo  $t$  [mm/dia];
- $Eb(t)$  é o escoamento de base do reservatório subterrâneo no tempo  $t$  [mm/dia];
- $Marg(t)$  é o extravasamento lateral (pelas margens) no tempo  $t$  [mm/dia];
- $Emarg(t)$  é a evaporação da planície de inundação no tempo  $t$  [mm/dia];
- $Ed(t)$  é o primeiro escoamento superficial do reservatório superficial no tempo  $t$  [mm/dia];
- $Ed2(t)$  é o segundo escoamento superficial do reservatório superficial e da planície de inundação no tempo  $t$  [mm/dia];
- $Ed3(t)$  é o terceiro escoamento superficial (para grandes vazões) no tempo  $t$  [mm/dia];
- $t$  é o instante de tempo [dia].

Os fluxos de transferência entre os reservatórios (como  $Es(t)$ ,  $Rec(t)$ ,  $Ed(t)$ ,  $Marg(t)$ , etc.) são calculados por um conjunto de equações específicas que foram omitidas por brevidade. Conforme ilustrado na Figura 3, esses fluxos são governados por parâmetros de calibração e limiares, como as constantes de recessão ( $K1t$ ,  $K2t$ ,  $K2t2$ ,  $K3t$ ,  $Kkt$ ), os limiares de armazenamento ( $Capc$ ,  $H$ ,  $H1$ ) e o parâmetro de recarga ( $Crec$ ). A formulação matemática detalhada de cada uma dessas funções pode ser consultada nas referências citadas (LOPES; BRAGA; CONEJO, 1982; Operador Nacional do Sistema Elétrico (ONS), 2017; MACIEL et al., 2020).

Com base nos valores de escoamento dos reservatórios  $R_{solo}$ ,  $R_{sub}$ ,  $R_{sup}$  e  $R_{sup2}$ , que contribuem para a vazão total na bacia estudada,  $Q_{calc}$  [m<sup>3</sup>/s], é determinada conforme a Equação 3.32:

$$Q_{calc}(t) = \left( \frac{Ed(t) + Ed2(t) + Ed3(t) + Eb(t)}{86,4} \right) Ad \quad (3.32)$$

onde  $Ad$  é a área de drenagem da bacia considerada [km<sup>2</sup>]. O fator 86,4 ajusta adequadamente a unidade de tempo.

Uma característica fundamental de sua operação é o uso não apenas da precipitação, mas também da vazão observada como dado de entrada. A vazão observada é utilizada em um processo de assimilação, cujo objetivo é atualizar os estados internos dos reservatórios (como  $R_{solo}(t)$ ,  $R_{sup}(t)$ , etc.). Este processo de correção contínua serve para melhorar a continuidade da previsão e reduzir o acúmulo de viés ao longo do tempo. Na prática, essa assimilação é realizada por meio de um procedimento de otimização bio-inspirado aplicado em uma janela móvel de dados correspondente ao histórico recente (30 dias anteriores à previsão) (ALVES, 2024).

Apesar de amplamente utilizado, o modelo SMAP/ONS apresenta limitações associadas à sua estrutura conceitual simplificada. Embora essa abordagem possa alcançar resultados satisfatórios em situações convencionais, ela tende a representar inadequadamente a complexidade de bacias com características heterogêneas ou sob condições extremas (ÁVILA et al., 2023). Ao não considerar explicitamente a variabilidade espacial e a incerteza inerentes aos processos hidrológicos, o modelo pode apresentar redução de desempenho, especialmente em cenários de alta variabilidade climática.

Essas limitações reforçam a importância do desenvolvimento e aplicação de abordagens mais flexíveis e adaptativas, como os modelos propostos, capazes de lidar com incertezas e capturar as dinâmicas não lineares de sistemas hidrológicos complexos.

### 3.4 BENCHMARKS COMPLEMENTARES

Visando estabelecer uma base comparativa robusta para as arquiteturas evolutivas propostas, esta seção descreve os métodos de referência selecionados, os quais representam paradigmas consolidados na literatura de previsão hidrológica: o aprendizado profundo e a lógica fuzzy com estrutura fixa.

#### 3.4.1 Long Short-Term Memory (LSTM)

A rede de Memória de Longo Prazo (*Long Short-Term Memory* – LSTM), proposta por Hochreiter e Schmidhuber (1997), é uma arquitetura de aprendizado profundo do tipo recorrente (*Recurrent Neural Network* – RNN), projetada para capturar dependências temporais de longo prazo e mitigar o problema do desvanecimento do gradiente. Sua

capacidade de modelar dependências temporais complexas torna essa arquitetura particularmente adequada para séries hidrológicas, caracterizadas por dinâmicas não lineares e efeitos de memória associados aos processos de precipitação e escoamento. Esta arquitetura é amplamente utilizada em modelagem hidrológica e previsão de vazão e representa um benchmark do estado da arte em aprendizado profundo, sendo um importante benchmark para a análise comparativa dos modelos propostos neste trabalho.

No presente estudo, a rede foi configurada segundo uma arquitetura comumente adotada na literatura, composta por uma camada oculta com 50 unidades de memória, seguida por uma camada de *dropout* com fator de probabilidade de 0,1 para regularização e prevenção de overfitting. A camada de saída é do tipo densa (*fully connected*) com um único neurônio, responsável pela projeção final da vazão prevista. O treinamento foi realizado utilizando o algoritmo de otimização Adam, com taxa de aprendizado inicial de 0,01, *minibatch* de 64 amostras e duração fixa de 200 épocas.

### 3.4.2 Fuzzy Information Granular-Fuzzy Time Series (FIG-FTS)

Como representativo da classe de modelos fuzzy orientados a dados, porém sem mecanismos de evolução online (isto é, com estrutura fixa de regras), adotou-se o modelo *Fuzzy Information Granular-Fuzzy Time Series* (FIG-FTS). A implementação utilizada neste trabalho baseia-se na metodologia validada por Alves (2024), a qual foi avaliada em um amplo conjunto de bacias hidrográficas brasileiras, consolidando-se como um benchmark consistente no contexto do Sistema Interligado Nacional.

Esse modelo se fundamenta na abordagem clássica de séries temporais fuzzy, diferenciando-se pela utilização de grânulos de informação construídos a partir das variáveis de entrada. Embora a metodologia FIG permita estratégias de granulação baseadas na distribuição dos dados, nesta implementação adotou-se um particionamento do universo de discurso em grade fixa de alta resolução ( $k = 800$  para a variável alvo, vazão), de modo a capturar as nuances da série temporal. A inferência é realizada por meio do mapeamento de relações lógicas ponderadas entre esses grânulos, sem a inclusão de novos conjuntos fuzzy ou a atualização de parâmetros durante a fase de teste, caracterizando um modelo de natureza estática.

## 3.5 CARACTERIZAÇÃO DAS ÁREAS DE ESTUDO

O Brasil possui uma extensa rede hidrográfica, organizada para atender a diferentes usos, em especial o planejamento e a gestão dos recursos hídricos. A Divisão Hidrográfica Nacional, instituída pelo Conselho Nacional de Recursos Hídricos (CNRH), estabelece doze Regiões Hidrográficas (RH) no território brasileiro.

Essas regiões correspondem a bacias, grupos de bacias ou sub-bacias hidrográficas próximas, que compartilham características naturais, sociais e econômicas semelhantes. De

acordo com a Agência Nacional de Águas e Saneamento Básico, essa forma de organização visa orientar o planejamento e gerenciamento dos recursos hídricos em todo o país (Agência Nacional de Águas e Saneamento Básico (ANA), 2025a). A distribuição espacial das regiões hidrográficas brasileiras é apresentada na Figura 4.



Figura 4 – Mapa da Divisão Hidrográfica do Brasil, segundo o Instituto Brasileiro de Geografia e Estatística (IBGE) (2024).

Dentre essas doze grandes divisões hidrográficas, este trabalho adota um recorte estratégico voltado àquelas que desempenham papel central para a segurança energética dentro do SIN. A seleção das áreas de estudo priorizou tanto a representatividade hidrológica quanto a relevância operacional, organizando-se em dois eixos: um foco primário na Região Hidrográfica do Paraná, dada sua importância na matriz elétrica brasileira; e uma avaliação complementar nas Regiões Hidrográficas do São Francisco e do Tocantins–Araguaia, com o objetivo de investigar a capacidade de generalização dos modelos em regimes hidrológicos

e condições climáticas distintas. As características específicas dessas regiões e das bacias selecionadas são discutidas nas subseções a seguir.

### 3.5.1 Região Hidrográfica do Paraná

A Região Hidrográfica do Paraná se destaca no cenário brasileiro devido à sua extensão territorial, intensa atividade econômica e alta demanda por recursos hídricos. Cobrindo aproximadamente 879.873 km<sup>2</sup>, cerca de 10% do território brasileiro, esta região abrange sete estados: São Paulo, Paraná, Mato Grosso do Sul, Minas Gerais, Goiás, Santa Catarina e Distrito Federal.

Esta é a região mais populosa do país e apresenta o maior nível de desenvolvimento econômico. Por esse motivo, concentra as maiores demandas por recursos hídricos, com destaque para o uso industrial. Além disso, é a região que apresenta a maior área irrigada do país, resultante da forte demanda agrícola, e o maior aproveitamento do potencial hidráulico para fins de geração de energia.

O presente estudo concentra-se em quatro bacias principais dentro dessa RH: Furnas, Itaipu, Itumbiara e São Simão. Essas bacias foram selecionadas com base em três critérios principais: sua elevada importância estratégica para o sistema hidrelétrico brasileiro; a disponibilidade de registros hidrológicos de longo prazo e alta qualidade; e a sua representatividade das diversas condições hidrológicas da Região Hidrográfica do Paraná, incluindo grandes afluentes e uma ampla gama de escalas operacionais. As principais características geográficas, hidrológicas e operacionais de cada uma das quatro bacias estão resumidas na Tabela 2.

Tabela 2 – Principais características geográficas, hidrológicas e operacionais das bacias selecionadas e suas respectivas usinas hidrelétricas (Agência Nacional de Águas e Saneamento Básico (ANA), 2025b).

<b>Característica</b>	<b>Furnas</b>	<b>Itaipu</b>	<b>Itumbiara</b>	<b>São Simão</b>
Latitude	20°40'12.0"S	25°25'12.0"S	18°25'12.0"S	19°01'12.0"S
Longitude	46°19'12.0"W	54°34'48.0"W	49°06'00.0"W	50°30'00.0"W
Estado(s)	Minas Gerais	Paraná	Goiás/Minas Gerais	Goiás/Minas Gerais
Rio	Grande	Paraná	Paranaíba	Paranaíba
Área de Drenagem (km <sup>2</sup> )	77.427	820.000	144.000	171.370
Área do Reservatório (km <sup>2</sup> )	~1.440	~1.350	~778	~722
Cota Máx. Reservatório (m)	768	220	519	401
Capacidade Instalada (MW)	1.216	14.000	2.082	1.710

As informações apresentadas na Tabela 2 evidenciam a heterogeneidade estrutural entre as bacias analisadas, com diferenças expressivas tanto na área de drenagem quanto na capacidade instalada das usinas associadas. Essas discrepâncias refletem escalas hidrológicas e operacionais distintas, impondo desafios adicionais à modelagem preditiva, especialmente no que se refere à adaptação dos modelos a diferentes magnitudes de

vazão e regimes de operação. As localizações geográficas aproximadas das hidrelétricas correspondentes às bacias selecionadas são apresentadas na Figura 5.

As quatro bacias analisadas estão hidraulicamente interconectadas dentro da RH do Paraná, formando uma topologia em cascata que influencia diretamente a dinâmica das vazões observadas. A usina de Itumbiara situa-se no Rio Paranaíba e, como um reservatório de acumulação a montante, regula significativamente o fluxo que chega à usina de São Simão, localizada a jusante no mesmo rio. Paralelamente, a usina de Furnas opera como um reservatório estratégico de cabeceira no Rio Grande. A usina de Itaipu situa-se na confluência dos rios Paranaíba e Grande, formando o Rio Paraná, onde está localizada a usina de Itaipu. Consequentemente, Itaipu atua como uma bacia integradora, cuja vazão afluente é o resultado da operação combinada de todo o sistema a montante, incluindo as descargas reguladas de Furnas, Itumbiara e São Simão. Essa forte interdependência hidrológica adiciona uma camada de complexidade à tarefa de previsão de vazão, impondo desafios de modelagem superiores aos encontrados na previsão pontual em bacias isoladas.

A confluência dos rios Paranaíba e Grande forma o Rio Paraná, onde está localizada a usina de Itaipu. Consequentemente, Itaipu atua como uma bacia integradora, cuja vazão afluente é o resultado da operação combinada de todo o sistema a montante, incluindo as descargas reguladas de Furnas, Itumbiara e São Simão. Essa forte interdependência hidrológica adiciona uma camada de complexidade à tarefa de previsão de vazão, impondo desafios de modelagem superiores aos encontrados na previsão pontual em bacias isoladas.

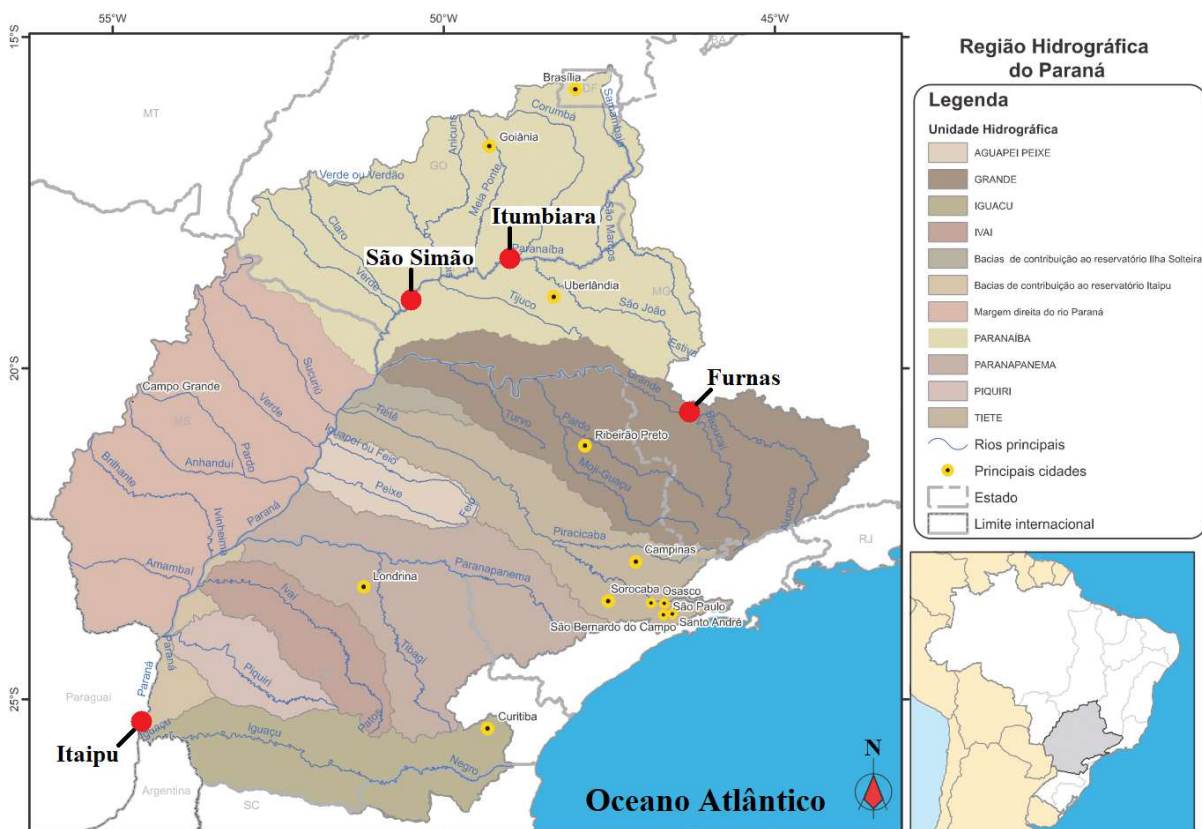


Figura 5 – Caracterização espacial da Região Hidrográfica do Paraná e das quatro bacias selecionadas neste estudo (destacadas com marcadores vermelhos em suas localizações aproximadas). O painel à esquerda apresenta um mapa detalhado da região e de sua rede hidrográfica, com ênfase nas bacias analisadas. O painel à direita indica a localização da região no território brasileiro. Adaptado de Agência Nacional de Águas e Saneamento Básico (ANA) (2025b).

### 3.5.2 Regiões Hidrográficas Complementares

Duas Regiões Hidrográficas complementares foram selecionadas para os experimentos de generalização espacial, cujos detalhes serão apresentados no Capítulo 6. As Regiões Hidrográficas do São Francisco e do Tocantins–Araguaia foram escolhidas por apresentarem regimes climáticos distintos entre si e em relação à bacia do Paraná, além de contarem com dados consistentes e de longo prazo.

A Região Hidrográfica do Tocantins–Araguaia ocupa aproximadamente 10,8% do território nacional e se estende por seis unidades federativas: Goiás, Tocantins, Pará, Maranhão, Mato Grosso e o Distrito Federal. A região engloba predominantemente os biomas Cerrado e Amazônia, com zonas de transição bem definidas entre eles. Sua precipitação média anual é inferior à média brasileira, resultando em regimes hidrológicos mais secos em grande parte do território.

Dentro dessa RH, a bacia de Tucuruí foi selecionada pela sua elevada relevância para o sistema elétrico brasileiro, pela grande capacidade instalada e pelas particularidades do regime hidrológico do rio Tocantins, que contrasta de forma significativa com as bacias do estudo principal.

A segunda região hidrográfica selecionada, a Região Hidrográfica do São Francisco, corresponde a aproximadamente 7,5% do território nacional e abrange sete estados: Bahia, Minas Gerais, Pernambuco, Alagoas, Sergipe, Goiás e o Distrito Federal. Trata-se de uma região historicamente marcada pela variabilidade climática e pela ocorrência de longos períodos de estiagem, apresentando precipitações anuais muito abaixo da média nacional. Ainda assim, desempenha papel estratégico na geração de energia para o Nordeste e no atendimento aos múltiplos usos da água.

Dentro dessa RH, a bacia de Três Marias foi escolhida por sua importância na regularização do rio São Francisco e por apresentar um regime hidrológico notavelmente distinto das demais bacias consideradas.

Em contraste com a topologia em cascata observada na seção anterior, estas bacias pertencem a regiões hidrográficas distintas e não apresentam conexão hidráulica entre si ou com a RH do Paraná. Essa condição de isolamento hidrológico e geográfico é fundamental para o objetivo deste estudo, pois submete os modelos a regimes de vazão e padrões climáticos independentes, permitindo uma avaliação rigorosa da capacidade de aprendizado e adaptação a novos ambientes dos modelos propostos.

Diante das características apresentadas, essas bacias se mostram particularmente relevantes para a análise de generalização espacial, por contemplarem condições hidrológicas e climáticas distintas. Suas principais características estão resumidas na Tabela 3.

Tabela 3 – Principais características geográficas, hidrológicas e operacionais das bacias de generalização selecionadas e suas respectivas usinas hidrelétricas (Agência Nacional de Águas e Saneamento Básico (ANA), 2025b).

Característica	Três Marias	Tucuruí
Latitude	18°12'49.0"S	03°49'56.0"S
Longitude	45°15'40.0"W	49°38'59.0"W
Estado	Minas Gerais	Pará
Rio	São Francisco	Tocantins
Área de Drenagem (km <sup>2</sup> )	50.761	758.000
Área do Reservatório (km <sup>2</sup> )	~1.040	~2.850
Cota Máxima do Reservatório (m)	572,5	72
Capacidade Instalada (MW)	396	8.370

Os dados da Tabela 3 confirmam a disparidade de escala entre as bacias selecionadas. Essa variação de dimensões é fundamental para verificar se os modelos conseguem manter a consistência tanto em grandes sistemas quanto em usinas de menor porte, independentemente da ordem de grandeza das vazões. As localizações espaciais aproximadas das hidrelétricas correspondentes às bacias selecionadas (indicadas pelos marcadores vermelhos) são apresentadas nas Figuras 6 e 7.

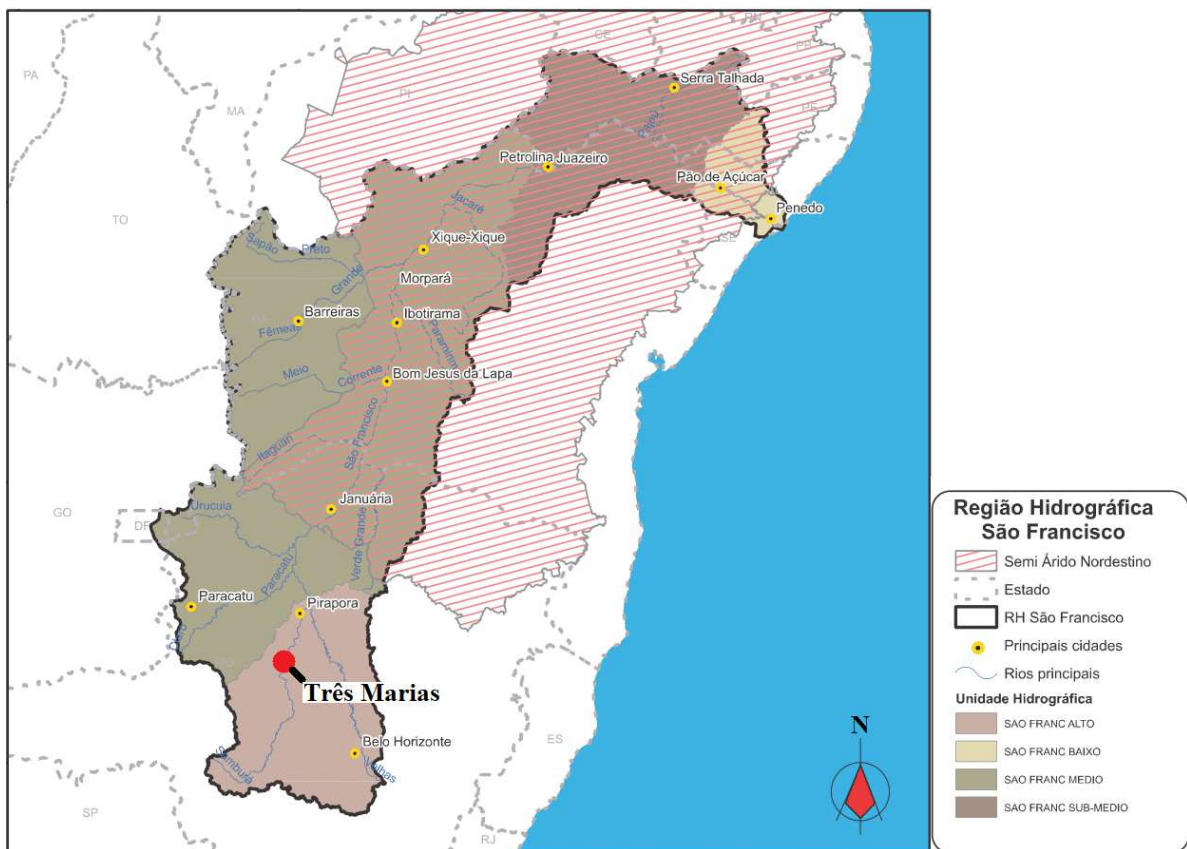


Figura 6 – Caracterização espacial da RH do São Francisco. Adaptado de Agência Nacional de Águas e Saneamento Básico (ANA) (2025b).

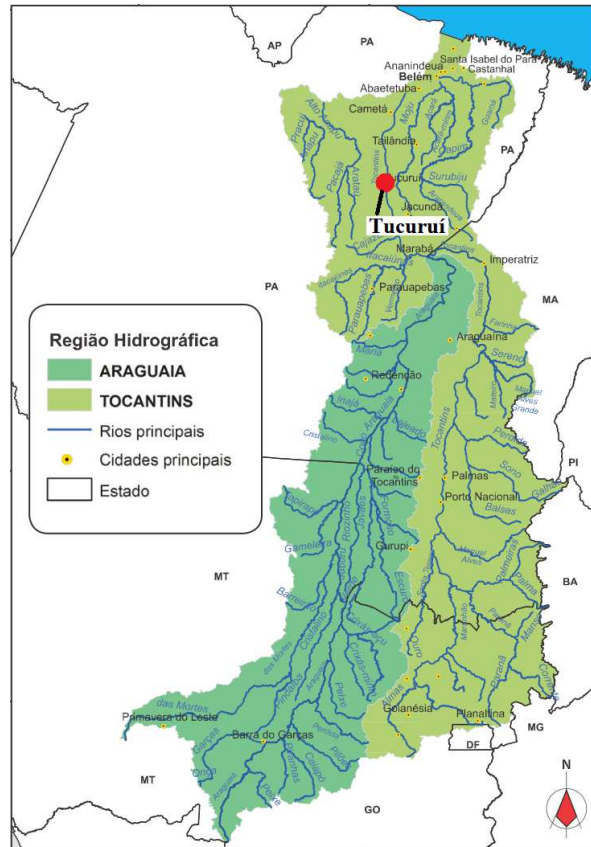


Figura 7 – Caracterização espacial da RH do Tocantins–Araguaia. Adaptado de Agência Nacional de Águas e Saneamento Básico (ANA) (2025b).

### 3.6 PROTOCOLO EXPERIMENTAL E AVALIAÇÃO

Esta seção apresenta o quadro metodológico completo desenvolvido para assegurar uma comparação consistente e robusta entre os modelos de previsão. São detalhados os dados hidrológicos utilizados, a configuração geral dos modelos de previsão, incluindo a estrutura de entrada, a metodologia de validação e a estratégia de otimização de hiperparâmetros. Em seguida, descreve-se o protocolo de avaliação, apresentando as métricas de desempenho utilizadas e os testes estatísticos empregados para determinar a significância dos resultados.

O protocolo experimental foi desenvolvido para possibilitar uma execução padronizada dos modelos de previsão e uma análise robusta dos resultados, com atenção especial à avaliação dos modelos propostos segundo critérios técnicos alinhados à realidade operacional elétrica e hidrológica. O quadro metodológico descrito nesta seção é inicialmente aplicado no Estudo de Caso 1, que estabelece o baseline metodológico da tese, sendo posteriormente reutilizado, com adaptações específicas, nos Estudos de Caso 2 e 3.

### 3.6.1 Dados Hidrológicos de Vazão e Precipitação

A previsão de vazões em bacias hidrográficas baseia-se, de forma recorrente na literatura, na utilização conjunta de séries históricas de vazão e precipitação, uma vez que essas variáveis fornecem informações complementares sobre os processos hidrológicos que governam a resposta do sistema (MACIEL et al., 2020; ALVES, 2024; Operador Nacional do Sistema Elétrico (ONS), 2017). Portanto, vazão e precipitação constituem as principais variáveis de interesse deste estudo, compondo as entradas dos modelos de previsão empregados ao longo deste trabalho.

Nesse contexto, as bases de dados experimentais utilizadas neste trabalho compreendem registros diários de vazão e precipitação referentes às bacias analisadas nos diferentes estudos de caso, considerando recortes temporais específicos em cada experimento. Os dados foram obtidos por meio da plataforma SINTEGRE, sistema oficial disponibilizado publicamente pelo Operador Nacional do Sistema Elétrico (ONS) (2024).

A vazão é expressa em metros cúbicos por segundo ( $\text{m}^3/\text{s}$ ), enquanto a precipitação é expressa em milímetros (mm), sendo obtida a partir do produto MERGE. Desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) e incorporado à base de dados do SINTEGRE, o produto MERGE integra dados de sensoriamento remoto e observações pluviométricas em uma grade regular com resolução espacial de  $0,25^\circ$  (aproximadamente 25 km) e resolução temporal diária; este conjunto de dados apresenta desempenho comparável às médias areais baseadas em pluviômetros em regiões com redes de observação densas e precisão superior em áreas com cobertura escassa, respaldando sua aplicação em estudos de previsão hidrológica e operacional (ROZANTE et al., 2010).

As séries temporais utilizadas correspondem diretamente aos dados disponibilizados pelas fontes citadas, não estando de forma explícita a aplicação de procedimentos adicionais de pré-processamento, tais como imputação de dados ausentes ou tratamento específico de valores atípicos nos dados. Os dados de todas as bacias hidrográficas consideradas nos Estudos de Caso 1, 2 e 3, bem como os códigos-fonte dos modelos computacionais propostos neste trabalho, encontram-se disponíveis publicamente em um repositório online, disponível em: <<https://github.com/rochamarcos-cloud/dados-tese-marcosrocha>>.

### 3.6.2 Definição das Variáveis de Entrada dos Modelos

Para determinar uma configuração de entrada apropriada para os modelos de previsão, foi realizada uma análise da Função de Autocorrelação Parcial (*Partial Autocorrelation Function* – PACF) para cada conjunto de dados de vazão das bacias consideradas no Estudo de Caso 1 (apresentado na Seção 3.6.7), visando identificar o número de defasagens significativas (lags) nas séries temporais de vazão. Esse procedimento segue a mesma abordagem para definição de entradas adotada em Lemos, Caminhas e Gomide (2010).

Os resultados indicaram que as cinco primeiras defasagens de vazão foram consistentemente significativas em todos os casos, enquanto defasagens de ordem superior exibiram correlações mais fracas e variáveis. Além disso, a precipitação também é considerada como variável de entrada, por apresentar relação física direta com a geração de vazão, sendo amplamente reconhecida como uma variável explicativa relevante em modelos hidrológicos (ALVES, 2024).

Dessa forma, para manter uma estrutura de variáveis de entrada padronizada entre os modelos de previsão, bem como evitar um custo computacional excessivo devido ao uso de um número elevado de defasagens, selecionou-se uma configuração comum composta pelas cinco últimas observações de vazão e pela precipitação atual.

O mapeamento entrada-saída resultante é representado pela função  $f$ , que define a relação entre o vetor de entrada  $x^k$  e a variável-alvo central deste trabalho: a vazão prevista  $\hat{y}^k$  ( $\text{m}^3/\text{s}$ ), conforme formalizado nas Equações 3.33 e 3.34.

$$\hat{y}^k = f(x^k) \quad (3.33)$$

$$x^k = [y^{k-1}, y^{k-2}, y^{k-3}, y^{k-4}, y^{k-5}, P^k] \quad (3.34)$$

onde  $y^k$  é a vazão observada ( $\text{m}^3/\text{s}$ ),  $P^k$  é a precipitação estimada via satélite (mm) e  $k$  denota o passo de tempo atual (dia).

Esta configuração de entrada foi uniformemente aplicada a todos os modelos de previsão orientados a dados (data-driven) considerados neste estudo (i.e., FIG-FTS, LSTM e família eMG). Em contrapartida, o modelo conceitual SMAP/ONS opera sob uma lógica distinta baseada em balanço hídrico, utilizando a vazão observada para a inicialização e atualização de seus estados internos, bem como a precipitação aliada a um conjunto de parâmetros físicos calibrados individualmente para cada bacia, conforme detalhado na Seção 3.3.

### 3.6.3 Metodologia de Validação

Na literatura de previsão com modelos fuzzy evolutivos, a validação (neste contexto entendida como a estratégia de avaliação do desempenho preditivo) é tradicionalmente conduzida por meio de duas etapas: (a) treinamento, em que a estrutura de regras fuzzy do modelo é adaptada evolutivamente com base nos dados de treino; e (b) teste, em que a estrutura construída na etapa de treinamento é avaliada em dados não observados. É prática comum reservar a porção final da série temporal para teste (por exemplo, 10% ou 20% do conjunto de dados) e utilizar o restante da série para treinamento (BERGMEIR; BENÍTEZ, 2012).

Embora usual, essa estratégia apresenta limitações significativas quando aplicada a séries temporais com dinâmicas sazonais, nas quais um único período de tempo é incapaz de refletir de forma adequada a dinâmica global do sistema estudado. Nesse contexto, alinhar a previsão de vazão de curto prazo a esse tipo de validação pode tornar a análise vulnerável, uma vez que os resultados passam a depender de um intervalo temporal específico, muitas vezes definido de forma arbitrária e que não representa a diversidade de regimes hidrológicos, como períodos de seca (menores índices de precipitação) e de cheia (maiores índices de precipitação).

Diante do exposto, este trabalho utiliza um esquema de validação cruzada com janelas expandidas e múltiplos períodos de teste independentes. Essa estratégia permite que os modelos sejam avaliados sob diferentes regimes hidrológicos (secas, cheias e períodos de transição entre seca e cheia), assegurando que o erro estimado não dependa de eventos isolados da série temporal. Tal característica é particularmente relevante para a avaliação de modelos de previsão, pois confere maior representatividade e robustez às métricas de desempenho, conforme recomendado por Tashman (2000) e Bergmeir e Benítez (2012).

Vale destacar que a estratégia de validação adotada representa uma das contribuições metodológicas deste trabalho. Diferentemente da prática usual na literatura de modelos orientados a dados (*data-driven*) aplicados à previsão de vazão, esta tese integra explicitamente critérios de diversidade de regimes hidrológicos na seleção dos períodos de teste. Até onde se tem conhecimento, essa abordagem constitui um rigor metodológico ainda pouco explorado em trabalhos correlatos, oferecendo uma avaliação mais fidedigna do desempenho dos modelos de previsão empregados.

Para cada período de teste, define-se o horizonte de previsão de vazão de curto prazo fixo de 14 dias, em consonância com as metodologias adotadas por outros estudos recentes de previsão de vazão de curto prazo em bacias brasileiras (MACIEL et al., 2020; ALVES, 2024). Este horizonte é particularmente relevante para a operação de usinas hidrelétricas, despacho diário e planejamento energético de curto prazo. À medida que o horizonte de previsão se estende, a incerteza típica das previsões tende a aumentar devido aos efeitos acumulativos da variabilidade meteorológica e dos processos hidrológicos não lineares. Nesse contexto, este horizonte representa um compromisso prático entre utilidade operacional e confiabilidade preditiva, justificando sua adoção em pesquisas e aplicações operacionais, como nos sistemas de previsão do ONS (ALVES, 2024).

A metodologia de validação cruzada com janelas expandidas e múltiplos períodos de teste independentes, é aplicada aos modelos de previsão da seguinte forma: em cada fold (partição da validação cruzada temporal), os modelos passam por uma fase de aprendizado (treinamento) utilizando todos os dados disponíveis desde o início do registro histórico até o dia imediatamente anterior ao período de teste, seguida imediatamente pela fase de avaliação (teste), na qual se avalia a estrutura treinada em um horizonte de previsão de 14

dias (dados não vistos).

Após essa avaliação, o período de teste é incorporado ao conjunto histórico, expandindo a base de treinamento para o fold subsequente. Esse processo iterativo permite que os modelos assimilem progressivamente novas informações hidrológicas, ao mesmo tempo em que são avaliados em diferentes condições ao longo da série, simulando a disponibilidade real de dados em um ambiente operacional. O funcionamento do esquema é ilustrado na Figura 8.

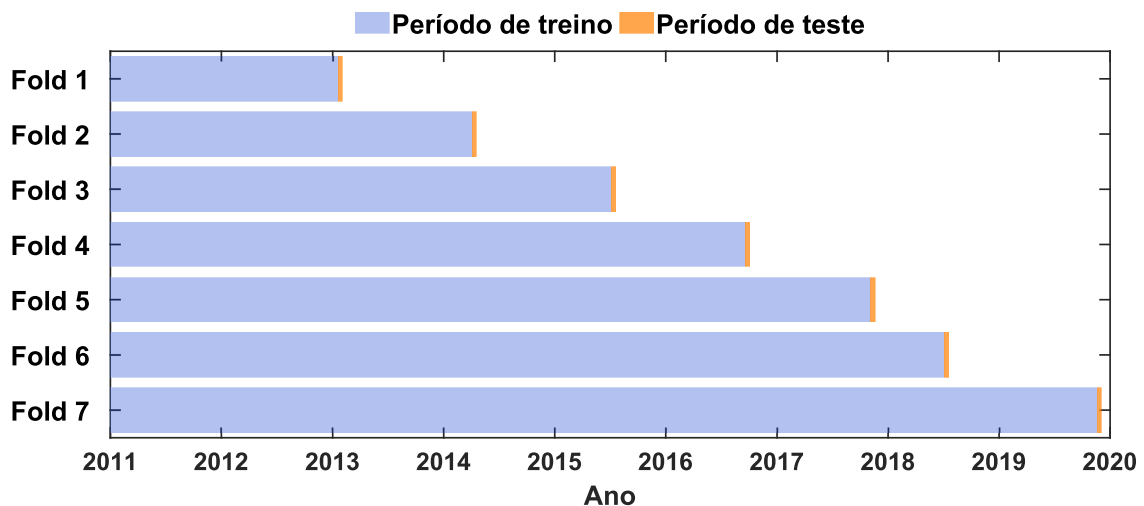


Figura 8 – Esquema de validação cruzada com janelas expandidas. O conjunto de treinamento (azul) cresce progressivamente para incorporar todo o histórico passado, enquanto os períodos de teste (laranja) avaliam o modelo em janelas independentes de 14 dias cobrindo diferentes regimes hidrológicos.

Essa metodologia de validação é aplicada de forma padronizada em todas as simulações com os modelos de previsão, respeitando estritamente os mesmos períodos de treinamento e teste em cada fold, de modo a assegurar que a análise de desempenho seja consistente e comparável. A única exceção refere-se ao modelo físico SMAP/ONS, que, devido à sua natureza conceitual, utiliza apenas os 30 dias antecedentes ao período de teste para a assimilação de seus estados internos, dispensando o uso de um histórico completo de treinamento.

Ainda assim, os períodos de teste foram mantidos rigorosamente idênticos aos dos demais modelos, garantindo a isonomia da comparação e permitindo que as diferentes abordagens sejam avaliadas sob as mesmas condições hidrológicas. Detalhes práticos de implementação, tais como os conjuntos de dados utilizados e as datas selecionadas, são apresentados especificamente em cada estudo de caso.

### 3.6.4 Otimização de Hiperparâmetros dos Modelos Evolutivos

Os hiperparâmetros dos modelos baseados em eMG foram definidos por meio de uma estratégia de busca em grade (*grid search*) sobre um espaço de busca restrito e

computacionalmente viável. O objetivo não era identificar um ótimo global, mas avaliar a robustez dos modelos em faixas representativas de valores previamente estabelecidas em estudos anteriores (ROCHA et al., 2021; ROCHA et al., 2022; LEMOS; CAMINHAS; GOMIDE, 2010).

A estratégia de busca foi adaptada para cada grupo de modelos: para o modelo eMG de referência, uma busca mais ampla sobre seus parâmetros fundamentais garantiu um ponto de comparação consistente; já para a família eMG (VS-eMG da literatura e os modelos propostos VSA-eMG, MVSA-eMG e MVS-eMG), a estratégia focou no ajuste dos parâmetros fundamentais com atenção específica aos hiperparâmetros introduzidos pelos mecanismos de adaptação (o limiar de sensibilidade ( $\bar{\gamma}$ ) e o parâmetro de adaptação ( $\beta$ )), a fim de investigar sua influência.

Para cada modelo evolutivo, a configuração final de hiperparâmetros foi selecionada como aquela que minimizou a média global de MAPE (Erro Percentual Absoluto Médio) ao longo dos sete folds de validação, calculada conjuntamente para as quatro bacias da RH do Paraná. A calibração conjunta dos hiperparâmetros foi adotada de modo a manter a viabilidade computacional do estudo e garantir a consistência das comparações entre as bacias analisadas, evitando a definição de múltiplos conjuntos específicos de parâmetros.

Essa estratégia possibilitou uma avaliação mais homogênea do desempenho dos modelos nos diferentes cenários considerados. A busca em grade, considerando conjuntamente as quatro bacias, compreendeu 1600 simulações para o modelo eMG e 2800 simulações para cada uma das variantes baseadas em eMG.

A diferença no número de simulações entre o modelo eMG e suas variantes decorre do aumento no número de hiperparâmetros introduzidos pelos mecanismos adaptativos propostos, o que amplia o espaço de busca e justifica a exploração de um maior número de combinações para avaliar adequadamente sua influência no desempenho preditivo. O espaço de busca completo para cada grupo de modelos é resumido na Tabela 4.

Tabela 4 – Intervalos de busca e número de valores considerados para a otimização de hiperparâmetros dos modelos evolutivos.

<b>Grupo de Modelos</b>	<b>Hiperparâmetro</b>	<b>Faixa de Busca</b>	<b>Nº de Valores</b>
eMG	Taxa de aprendizado ( $\alpha$ )	[0,01; 0,10]	4
	Tamanho da janela ( $w$ )	[2; 20]	10
	Nível de significância ( $\lambda$ )	[0,01; 0,20]	5
	Matriz de dispersão ( $\Sigma$ )	{0,001; 0,01}	2
Variantes eMG	Taxa de aprendizado ( $\alpha$ )	{0,01; 0,10}	2
	Tamanho da janela ( $w$ )	[2; 20]	7
	Limiar de sensibilidade ( $\bar{\gamma}$ )	[0,001; 0,009]	10
	Parâmetro de adaptação ( $\beta$ )	[0,65; 0,95]	5

O processo de otimização dos hiperparâmetros é realizado exclusivamente com base nos dados do Estudo de Caso 1, que é considerado um conjunto de dados representativo de um regime hidrológico típico das bacias analisadas. Uma vez determinados, os conjuntos de hiperparâmetros são fixados e transferidos de forma inalterada para os Estudos de Caso 2 (cenário de estresse hídrico) e 3 (generalização espacial). Os três estudos de caso citados são formalmente apresentados e discutidos nos capítulos seguintes.

Os modelos de referência não evolutivos não foram submetidos à mesma estratégia de busca em grade, pois sua otimização segue princípios distintos. O modelo de referência operacional, SMAP/ONS, é um modelo conceitual que requer um processo de calibração específico para ajustar seus parâmetros físicos a cada bacia específica. Este é um procedimento fundamentalmente diferente da otimização de hiperparâmetros aplicada aos modelos baseados em eMG.

Da mesma forma, para os benchmarks LSTM e FIG-FTS, adotaram-se configurações padrão consolidadas na literatura, as quais são comumente empregadas para obtenção de desempenho representativo, sem a necessidade de varredura exaustiva do espaço de parâmetros. Essa abordagem permitiu que o esforço de otimização fosse concentrado na classe de modelos evolutivos, garantindo ao mesmo tempo uma comparação robusta e generalizável com os modelos de referência.

### 3.6.5 Métricas de Avaliação de Desempenho

A avaliação de desempenho dos modelos de previsão foi conduzida utilizando métricas quantitativas amplamente adotadas em estudos hidrológicos. A primeira delas é o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error* – MAPE), que quantifica a magnitude média dos erros relativos. Em seguida, emprega-se o Viés Percentual (*Percent Bias* – PBIAS), indicador que revela a tendência do modelo em superestimar ou subestimar os valores observados.

Também foi considerada a métrica Erro Percentual Quadrático Médio (*Root Mean Square Percentage Error* – RMSPE), que, assim como o MAPE, avalia erros relativos, porém atribuindo maior peso a discrepâncias mais amplas. Por fim, utiliza-se a Eficiência de Nash–Sutcliffe (*Nash–Sutcliffe Efficiency* – NSE), um índice amplamente consolidado que compara o desempenho do modelo em relação à média das observações, refletindo simultaneamente a capacidade de capturar a variabilidade e a magnitude da série.

As definições matemáticas de cada métrica, juntamente com seus valores ideais, são apresentadas na Tabela 5. Além dessas métricas, também foram considerados o tempo médio de execução por fold (em segundos) e, no caso dos modelos fuzzy evolutivos, o número médio final de regras, utilizado como indicador de complexidade estrutural.

Tabela 5 – Métricas de avaliação utilizadas para analisar o desempenho dos modelos de previsão, incluindo abreviação, fórmula e valor ideal para cada métrica.

Métrica de avaliação	Abreviação	Fórmula	Valor ideal
Erro Percentual Absoluto Médio	MAPE [%]	$\frac{1}{n} \sum_{i=1}^n \left  \frac{\hat{y}_i - y_i}{y_i} \right  \times 100$	$\sim 0$
Viés Percentual	PBIAS [%]	$\frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{\sum_{i=1}^n y_i} \times 100$	$\sim 0$
Erro Percentual Quadrático Médio	RMSPE [%]	$\sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{\hat{y}_i - y_i}{y_i} \right)^2} \times 100$	$\sim 0$
Eficiência de Nash–Sutcliffe	NSE	$1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	$\sim 1$

onde  $y_i$  é a vazão observada ( $\text{m}^3/\text{s}$ ),  $\hat{y}_i$  é a vazão prevista ( $\text{m}^3/\text{s}$ ) e  $\bar{y}$  é a média das vazões observadas ao longo de todas as  $n$  amostras.

O termo acurácia é empregado neste trabalho para denotar a aderência entre as previsões dos modelos e os dados observados, com base na literatura de previsão hidrológica. Diferentemente da definição adotada em problemas de classificação (nos quais a métrica de acurácia é computada com base em acertos e erros discretos), neste contexto o termo é utilizado como uma medida sintética do desempenho preditivo.

Assim, maiores níveis de acurácia estão associados a menores magnitudes de erro (MAPE e RMSPE), menor viés sistemático (PBIAS) e maior eficiência preditiva (NSE), não sendo, portanto, tratada como uma métrica isolada, mas como uma interpretação conjunta dos indicadores de desempenho adotados.

### 3.6.6 Análise de Significância Estatística

Com o objetivo de validar a significância estatística dos resultados e conferir maior robustez às análises comparativas, adota-se neste trabalho uma abordagem de análise de significância estatística (validação estatística). Para isso, são aplicados em paralelo dois testes de hipótese com pressupostos distintos: o teste paramétrico de Morgan–Granger–Newbold (MGN) e o teste não paramétrico de Wilcoxon (*Wilcoxon Signed-Rank Test*).

A utilização conjunta dessas ferramentas permite avaliar a consistência do desempenho dos modelos tanto sob a ótica da variância dos erros quanto sob a perspectiva do ordenamento das diferenças, mitigando vieses, especialmente em cenários sujeitos a valores extremos.

O primeiro método aplicado é o teste de Morgan–Granger–Newbold (MGN) (DIEBOLD; MARIANO, 2002), um teste estatístico paramétrico empregado para verificar se dois modelos de previsão apresentam acurácias preditivas significativamente diferentes. A

estatística do teste fundamenta-se na correlação entre a soma e a diferença dos erros de previsão, sendo calculada conforme a Equação 3.35:

$$MGN = \frac{\hat{\rho}_{sd}}{\sqrt{\frac{1-\hat{\rho}_{sd}^2}{n-1}}} \quad (3.35)$$

onde  $\hat{\rho}_{sd}$  representa a correlação estimada entre a soma ( $s = r_1 + r_2$ ) e a diferença ( $d = r_1 - r_2$ ) dos resíduos dos modelos 1 ( $r_1$ ) e 2 ( $r_2$ ). A estatística segue uma distribuição  $t$  de Student com  $n - 1$  graus de liberdade. Adotando um nível de significância estatística de  $\tau_{MGN} = 5\%$ , a hipótese nula ( $H_0$ ) de igualdade de acurácia é rejeitada caso o  $p$ -valor seja inferior a  $\tau_{MGN}$ .

O segundo método empregado é o *Wilcoxon Signed-Rank Test* (WILCOXON, 1945), utilizado como uma validação estatística complementar não paramétrica e livre de distribuição. Este teste avalia se a mediana das diferenças entre os pares de erros é significativamente distinta de zero. Sua aplicação é estratégica para este estudo, pois, ao basear-se no ordenamento das diferenças entre os erros observados em cada um dos modelos comparados ( $d_k = |e_{1,k}| - |e_{2,k}|$ ), e não em suas magnitudes absolutas, o teste torna-se menos sensível a outliers, indicando qual modelo apresenta desempenho superior de forma consistente, independentemente de distorções isoladas.

O procedimento classifica os valores absolutos das diferenças  $|d_k|$  em ordem crescente, atribuindo um posto  $R_k$  a cada observação. A estatística do teste,  $W$ , é definida pelo menor valor entre a soma dos postos das diferenças positivas ( $W^+$ ) e a soma dos postos das diferenças negativas ( $W^-$ ), conforme a Equação 3.36:

$$W = \min(W^+, W^-) \quad (3.36)$$

De maneira análoga ao MGN, para um nível de significância estatística  $\tau_W = 5\%$ , rejeita-se  $H_0$  se o  $p$ -valor calculado for inferior a  $\tau_W$ , concluindo-se haver evidência estatística suficiente para afirmar que um dos modelos supera o outro na maioria das amostras de teste.

### 3.6.7 Visão Geral dos Estudos de Caso Propostos

Com o objetivo de fornecer uma aplicação e avaliação extensiva, a avaliação dos modelos propostos foi organizada em três Estudos de Caso distintos, concebidos para avaliar diferentes aspectos do desempenho preditivo e da aplicabilidade prática das arquiteturas evolutivas frente a outros benchmarks relevantes da literatura.

O protocolo experimental foi aplicado integralmente no Estudo de Caso 1, considerado o estudo principal de análise e desempenho dos modelos em condições típicas. Para os Estudos de Caso 2 e 3, o mesmo protocolo foi utilizado com ajustes específicos em cada

caso. A Tabela 6 resume as principais características metodológicas que diferenciam cada estudo, oferecendo uma visão global da estratégia experimental adotada.

Tabela 6 – Visão geral comparativa das características metodológicas fundamentais dos três estudos de caso conduzidos nesta tese.

<b>Característica</b>	<b>Estudo de Caso 1</b>	<b>Estudo de Caso 2</b>	<b>Estudo de Caso 3</b>
Foco da Análise	Avaliação de desempenho em condições típicas e otimização	Avaliação de robustez sob estresse hídrico	Avaliação de generalização espacial para regimes hidrológicos distintos
Bacias	Furnas, Itaipu, Itumbiara e São Simão	Mesmas do Estudo 1	Três Marias e Tucuruí
Período	01/2011–12/2019 (9 anos)	08/2019–12/2021 ( $\approx$ 2,5 anos)	Mesmo do Estudo 1
Modelos	SMAP/ONS, FIG-FTS, LSTM e Família eMG	LSTM e Família eMG	LSTM e Família eMG
Hiperparâmetros	Otimizados via busca em grade	Mantidos fixos (herdados do Estudo 1)	Mantidos fixos (herdados do Estudo 1)

Todas as simulações foram implementadas no ambiente MATLAB R2023a e executadas em um computador pessoal equipado com um processador Intel Core i5-1135G7 (2,40 GHz) e 8 GB de memória RAM.

## 4 ESTUDO DE CASO 1: ANÁLISE DE DESEMPENHO EM CONDIÇÕES HIDROLÓGICAS REPRESENTATIVAS

Este capítulo apresenta o estudo principal do presente trabalho, denominado Estudo de Caso 1. Este estudo é integralmente conduzido com base no protocolo experimental descrito na Seção 3.6, são apresentados e discutidos os resultados obtidos a partir da aplicação do fluxo de trabalho proposto às quatro bacias hidrográficas analisadas, localizadas na Região Hidrográfica do Paraná, descritas na Seção 3.5.1. Todas as etapas metodológicas foram conduzidas de forma sistemática, com o objetivo de avaliar o desempenho preditivo dos modelos propostos em comparação com os modelos de referência considerados.

### 4.1 CENÁRIO EXPERIMENTAL

Os dados utilizados neste estudo seguem a base de dados descrita na Seção 3.6.1, composta por registros diários de vazão e precipitação observados em quatro bacias localizadas na Região Hidrográfica do Paraná: Furnas, Itaipu, Itumbiara e São Simão. O período selecionado abrange nove anos, de 01 de janeiro de 2011 a 31 de dezembro de 2019, totalizando 3.287 amostras diárias por bacia. Esta extensão temporal é considerada suficiente para garantir a confiabilidade do treinamento e da validação dos modelos, sendo consistente com estudos similares na literatura (KHOZANI; PRECHT; IONITA, 2025; GOODARZI et al., 2024). As séries temporais completas para cada bacia são apresentadas na Figura 9.

A seleção dos períodos de teste segue um critério estratégico desenhado para cobrir a variabilidade sazonal típica das bacias da Região Hidrográfica do Paraná. De acordo com a classificação climática de Köppen (ALVARES et al., 2013), a região apresenta predominância do tipo tropical de savana (Aw), caracterizado por uma estação chuvosa concentrada entre outubro e abril e um período relativamente mais seco entre maio e setembro. Embora coexistam transições para outros tipos climáticos na região, como o tropical com inverno seco (Cwa) e o subtropical úmido (Cfa), esse padrão sazonal dominante fundamenta a definição das janelas temporais adotadas no esquema de validação. Essas janelas são definidas como períodos de cheia, de seca e de transição (esta última associada às fases de recessão e ascensão que ocorrem ao longo do ano hidrológico).

Para evitar potenciais vieses que poderiam surgir de uma seleção aleatória, os intervalos de teste foram selecionados a priori, antes da inspeção dos dados das bacias, baseando-se exclusivamente nos padrões sazonais conhecidos da RH selecionada, refletindo cenários operacionais reais em que os operadores não podem escolher eventos específicos para previsão. Padrões sazonais semelhantes têm sido amplamente descritos para outras bacias hidrográficas brasileiras na literatura (ÁVILA et al., 2023), corroborando a adequação dos períodos selecionados no presente protocolo experimental.

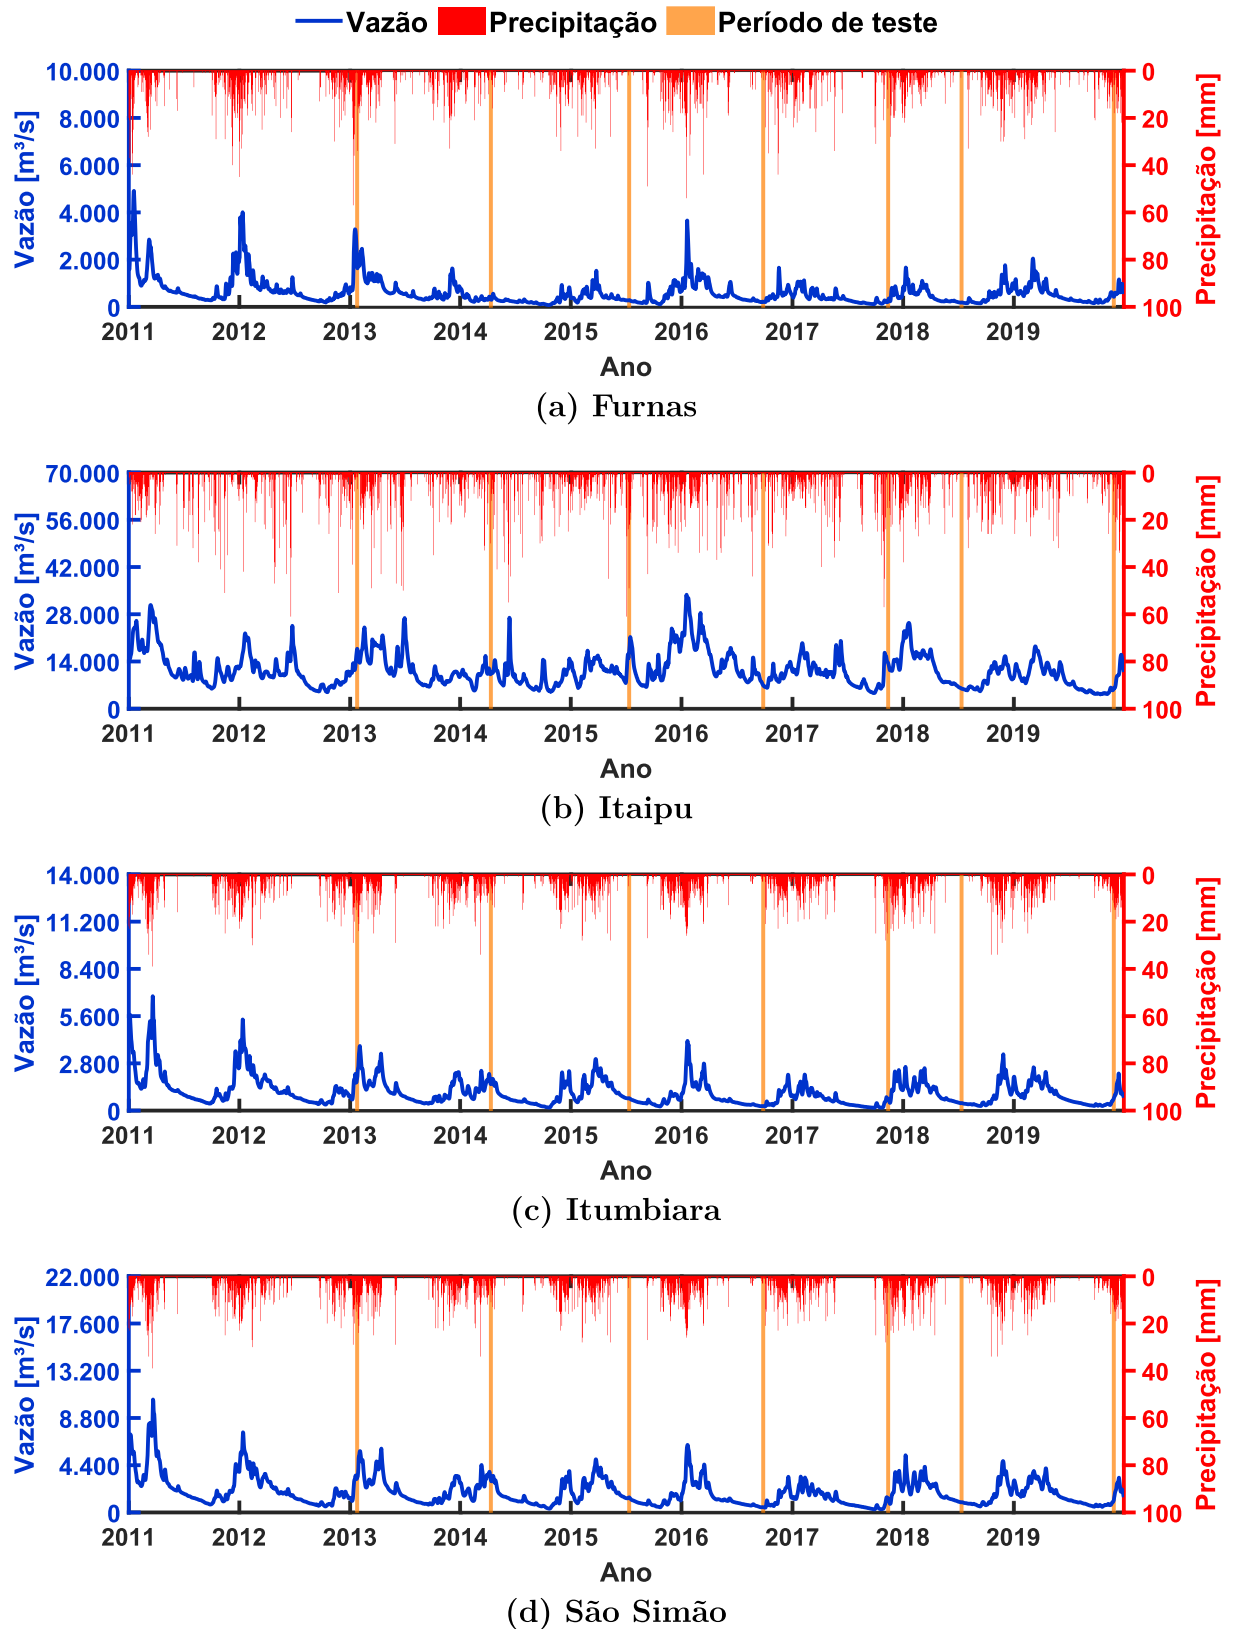


Figura 9 – Séries temporais diárias de vazão (linha azul) e precipitação (barras vermelhas) nas bacias de (a) Furnas, (b) Itaipu, (c) Itumbiara e (d) São Simão no período de 2011–2019. As faixas verticais (laranja) indicam os sete períodos de teste de 14 dias utilizados para a validação dos modelos.

A distribuição dos períodos de teste contempla sete folds selecionados cronologicamente ao longo das séries históricas. As datas, associadas aos respectivos períodos climáticos, são: 20 de janeiro – 02 de fevereiro de 2013 (fold 1, cheia); 06–19 de abril de 2014 (fold 2, transição); 06–19 de julho de 2015 (fold 3, seca); 20 de setembro – 03 de outubro de 2016 (fold 4, transição); 06–19 de novembro de 2017 (fold 5, cheia); 06–19 de julho de 2018 (fold 6, seca); e 20 de novembro – 03 de dezembro de 2019 (fold 7, cheia).

Esta estratégia assegura que o desempenho de cada modelo seja avaliado ao longo de todo o ciclo sazonal, com intervalos estrategicamente distribuídos para abranger os três principais estágios hidrológicos. A ilustração do esquema de validação empregado foi previamente apresentada na Figura 8.

A Tabela 7 apresenta as estatísticas descritivas básicas das séries de vazão afluente utilizadas no Estudo de Caso 1, considerando o período de 2011 a 2019 para as quatro bacias analisadas. São reportados os valores mínimo, máximo e a média acompanhada do respectivo desvio padrão, com o objetivo de caracterizar a escala e a variabilidade hidrológica dos dados empregados na modelagem de cada bacia.

Tabela 7 – Estatísticas descritivas das séries de vazão e precipitação no período de 2011–2019, incluindo mínimo, máximo e média  $\pm$  desvio padrão.

<b>Bacia</b>	<b>Variável</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Média</b>
Furnas	Vazão (m <sup>3</sup> /s)	75	4910	611,1 $\pm$ 541,1
	Precipitação (mm)	0	57	3,3 $\pm$ 6,2
Itaipu	Vazão (m <sup>3</sup> /s)	4246	33783	11502,4 $\pm$ 4933,1
	Precipitação (mm)	0	61	4,2 $\pm$ 7,7
Itumbiara	Vazão (m <sup>3</sup> /s)	166	6780	1086,3 $\pm$ 820,4
	Precipitação (mm)	0	39	3,3 $\pm$ 5,3
São Simão	Vazão (m <sup>3</sup> /s)	292	10520	1906,3 $\pm$ 1319,6
	Precipitação (mm)	0	39	3,3 $\pm$ 5,3

Os valores apresentados evidenciam a heterogeneidade hidrológica entre as bacias analisadas, destacando-se diferenças expressivas tanto na escala de magnitude quanto na variabilidade das vazões afluentes. Os elevados desvios padrão indicam a predominância de regimes dinâmicos, sujeitos a oscilações significativas ao longo do tempo.

Nesse contexto, o intervalo de nove anos abrange ciclos hidrológicos completos, sendo suficiente com base na literatura para caracterizar os padrões sazonais e interanuais das bacias, o que fornece uma base consistente para o treinamento e a avaliação robusta dos modelos de previsão no Estudo de Caso 1.

#### 4.1.1 Preditores de Referência Estáticos e Lineares

Com o objetivo de ampliar a discussão e fornecer uma perspectiva comparativa frente a paradigmas mais simples, este primeiro estudo de caso inclui a avaliação de dois preditores de estrutura estática e linear. A inserção dessas abordagens mais simples permite observar o comportamento preditivo de métodos menos complexos, contrastando-os de forma direta com os resultados obtidos pelas arquiteturas orientadas a dados (apresentadas na seção seguinte).

A primeira abordagem de referência incorporada é a Média Móvel Ponderada (*Weighted Moving Average* – WMA), a qual atua como um mecanismo de suavização temporal ao incorporar um horizonte histórico estendido para a previsão. Visando manter a simetria com o vetor de entradas das arquiteturas orientadas a dados concorrentes (que processam informações defasadas de  $k - 1$  a  $k - 5$ ), implementou-se uma janela de ponderação decrescente de cinco dias. Matematicamente, a previsão para o instante  $k$  é calculada conforme a Equação 4.1:

$$\hat{y}^k = \frac{5y^{k-1} + 4y^{k-2} + 3y^{k-3} + 2y^{k-4} + 1y^{k-5}}{15} \quad (4.1)$$

em que o denominador atua como fator de normalização da soma dos pesos atribuídos aos passos passados, priorizando linearmente as vazões observadas mais recentemente.

O segundo preditor de referência estabelecido é o modelo de persistência Naive. Esta abordagem simplificada assume que a dinâmica hidrológica de curto prazo é governada integralmente por sua inércia, não havendo antecipação preditiva de picos ou recessões. Conseqüentemente, o modelo Naive define que a previsão corresponde estritamente à vazão observada no instante de tempo imediatamente anterior, conforme a Equação 4.2:

$$\hat{y}^k = y^{k-1} \quad (4.2)$$

Ressalta-se que, devido à linearidade destas formulações e à completa ausência de parâmetros estruturais ajustáveis ou pesos sinápticos, a WMA e o modelo Naive não possuem a etapa computacional de treinamento. Por esse motivo, ambos são aplicados de maneira direta sobre os dados das janelas de validação, não reportando métricas de tempo e tampouco possuindo hiperparâmetros a serem otimizados ou discutidos nas etapas analíticas subsequentes.

#### 4.1.2 Configuração dos Modelos de Previsão Orientados a Dados

Conforme delineado no protocolo experimental, a avaliação de desempenho proposta neste estudo de caso fundamenta-se principalmente na análise comparativa e rigorosa entre as abordagens evolutivas desenvolvidas (VSA-eMG, MVSA-eMG e MVS-eMG) e modelos de referência consolidados na literatura e na prática operativa (SMAP/ONS, LSTM, eMG original e VS-eMG).

Para garantir a isonomia dessa avaliação, adotou-se um protocolo experimental estrito quanto à reprodutibilidade. Diferentemente dos modelos da família eMG, cuja construção e atualização estrutural são conduzidas de forma determinística a partir dos dados observados, certas arquiteturas de referência apresentam componentes estocásticos relevantes em suas formulações, como a inicialização aleatória de pesos nas redes LSTM e o procedimento de otimização bio-inspirado presente no SMAP/ONS. Nesse contexto, para estas arquiteturas, as simulações foram conduzidas com a fixação das sementes aleatórias (*random seeds*) e das condições iniciais, de modo a assegurar a reprodutibilidade dos experimentos.

Dessa forma, assegura-se que todos os modelos operem de forma determinística no sentido computacional durante a fase de teste (previsão), uma vez que eventuais componentes estocásticos de suas formulações são controlados por meio da fixação das sementes aleatórias e das condições iniciais. Assim, para um mesmo conjunto de dados de entrada, cada modelo produz sempre a mesma saída. Isso garante que a execução dos modelos seja guiada estritamente pelas propriedades estatísticas dos dados de entrada, eliminando variabilidades decorrentes de inicializações aleatórias e permitindo que as métricas de erro reflitam exclusivamente a capacidade de generalização de cada técnica frente à dinâmica hidrológica.

## 4.2 RESULTADOS DA OTIMIZAÇÃO DE HIPERPARÂMETROS

Nesta seção são apresentados os resultados da otimização de hiperparâmetros dos cinco modelos evolutivos avaliados neste trabalho (eMG original, VS-eMG da literatura e as três abordagens introduzidas neste trabalho: VSA-eMG, MVSA-eMG e MVS-eMG). Foi aplicada a estratégia de otimização, descrita na Seção **3.6.4**, exclusivamente com base nos dados do Estudo de Caso 1.

Para cada modelo, a configuração final de hiperparâmetros foi selecionada como aquela que minimizou o valor médio do MAPE ao longo dos sete folds de validação das quatro bacias. O intuito foi identificar uma configuração de hiperparâmetros que se mostrasse adequada para as quatro bacias avaliadas, evitando a obtenção de modelos excessivamente especializados em uma única bacia. A Tabela 8 apresenta as configurações finais de hiperparâmetros obtidas para cada modelo avaliado.

Tabela 8 – Configurações finais otimizadas de hiperparâmetros para os modelos de referência (eMG e VS-eMG) e os propostos (VSA-eMG, MVSA-eMG e MVS-eMG).

Hiperparâmetro	eMG	VS-eMG	VSA-eMG	MVSA-eMG	MVS-eMG
Taxa de aprendizado ( $\alpha$ )	0,01	0,01	0,01	0,01	0,01
Nível de significância ( $\lambda$ )	0,01	0,05	0,05	0,05	0,05
Tamanho da janela ( $w$ )	10	11	20	8	8
Matriz de dispersão ( $\Sigma$ )	0,01	0,01	0,01	0,01	0,01
Limiar de sensibilidade ( $\bar{\gamma}$ )	–	0,0028	0,0081	0,0046	0,0010
Parâmetro de adaptação ( $\beta$ )	–	0,9050	0,8200	0,7350	0,6500

As configurações de hiperparâmetros obtidas neste processo são fixadas e utilizadas de forma inalterada nos Estudos de Caso 2 e 3, permitindo a avaliação da robustez dos modelos sob mudança de regime hidrológico e em cenários de generalização espacial.

Reitera-se que esse processo de otimização não buscou encontrar ótimos globais através de análise exaustiva. O objetivo foi encontrar hiperparâmetros que, dentro de um espaço de busca predefinido, possibilitem que os modelos gerem resultados adequados para a aplicação proposta, tendo como referência de busca valores utilizados na literatura da família eMG. Considerando o elevado número de hiperparâmetros, essa análise se faz indispensável para o bom funcionamento dos modelos.

### 4.3 AVALIAÇÃO GLOBAL MULTIBACIA

Com o objetivo de fornecer uma visão integrada do desempenho preditivo dos modelos sob diferentes regimes hidrológicos, esta seção apresenta uma avaliação global multibacia, antecedendo a análise individualizada por bacia. O desempenho global de cada modelo é apresentado na Tabela 9, onde os valores correspondem à média aritmética simples de cada uma das métricas obtidas individualmente para cada bacia analisada. Os valores globais são determinados conforme a Equação 4.3:

$$M_{\text{global}} = \frac{1}{N} \sum_{i=1}^N M_i \quad (4.3)$$

em que  $M_{\text{global}}$  representa o valor médio global de cada métrica (por exemplo, MAPE, PBIAS e NSE),  $N$  corresponde ao número total de bacias consideradas (nesse caso,  $N = 4$ ) e  $M_i$  denota o valor da métrica obtido para a  $i$ -ésima bacia.

Embora as bacias analisadas apresentem dinâmicas hidrológicas distintas, a agregação é realizada exclusivamente sobre indicadores de desempenho comparáveis. Métricas de erro como MAPE e NSE são adimensionais, enquanto indicadores estruturais (tempo de processamento e número de regras) refletem a complexidade intrínseca dos modelos. Dessa forma, os resultados permanecem qualitativamente comparáveis, permitindo uma avaliação direta da robustez das arquiteturas frente aos diferentes cenários considerados.

Essa avaliação global é, portanto, complementar e não substitutiva à análise individualizada por bacia apresentada na sequência, na qual as particularidades hidrológicas são examinadas em maior profundidade.

Tabela 9 – Métricas globais de desempenho (média  $\pm$  desvio padrão) para todos os modelos, agregadas considerando as quatro bacias e os sete períodos de validação. O melhor valor de cada métrica é destacado em negrito. A linha horizontal separa os modelos benchmark das abordagens propostas.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
WMA	6,58 $\pm$ 1,03	-1,60 $\pm$ 1,02	7,89 $\pm$ 1,14	0,093 $\pm$ 0,135	-	-
Naive	3,31 $\pm$ 0,58	-0,64 $\pm$ 0,39	4,08 $\pm$ 0,73	0,729 $\pm$ 0,031	-	-
SMAP/ONS	21,29 $\pm$ 14,92	-16,45 $\pm$ 21,33	22,56 $\pm$ 15,31	-13,050 $\pm$ 23,016	134,89 $\pm$ 14,85	-
FIG-FTS	16,85 $\pm$ 11,53	-2,45 $\pm$ 19,85	19,24 $\pm$ 12,94	-9,481 $\pm$ 15,100	6,81 $\pm$ 2,79	-
LSTM	7,20 $\pm$ 5,53	1,95 $\pm$ 6,99	9,84 $\pm$ 8,54	-10,616 $\pm$ 29,851	30,78 $\pm$ 12,80	-
eMG	3,14 $\pm$ 2,55	0,48 $\pm$ 2,82	3,85 $\pm$ 3,11	0,062 $\pm$ 2,408	0,24 $\pm$ 0,12	<b>3,7 <math>\pm</math> 0,9</b>
VS-eMG	2,35 $\pm$ 1,32	<b>-0,06 <math>\pm</math> 1,11</b>	3,00 $\pm$ 1,90	0,749 $\pm$ 0,268	0,82 $\pm$ 0,66	5,0 $\pm$ 1,5
VSA-eMG	2,50 $\pm$ 1,91	0,26 $\pm$ 1,34	3,13 $\pm$ 2,36	0,730 $\pm$ 0,304	0,31 $\pm$ 0,13	6,1 $\pm$ 1,3
MVSA-eMG	2,45 $\pm$ 1,94	0,20 $\pm$ 1,09	3,11 $\pm$ 2,39	0,751 $\pm$ 0,314	0,43 $\pm$ 0,20	5,9 $\pm$ 1,4
MVS-eMG	<b>2,32 <math>\pm</math> 1,70</b>	0,17 $\pm$ 1,38	<b>2,89 <math>\pm</math> 2,13</b>	<b>0,788 <math>\pm</math> 0,258</b>	<b>0,19 <math>\pm</math> 0,11</b>	4,7 $\pm$ 1,3

Na Tabela 9, observa-se que os dois preditores de referência apresentaram comportamentos distintos. Enquanto a WMA obteve desempenho limitado (MAPE = 6,58% e NSE = 0,093), o modelo de persistência (Naive) mostrou-se significativamente mais competitivo, alcançando NSE médio de 0,729 e erros percentuais relativamente baixos. Esse resultado evidencia a forte persistência temporal presente nas séries de vazão analisadas, indicando que parte da capacidade preditiva pode ser obtida a partir da autocorrelação inerente ao processo hidrológico. Ainda assim, os modelos evolutivos propostos foram capazes de superar estes benchmarks, alcançando ganhos adicionais em todas as métricas avaliadas.

Embora o modelo de persistência Naive apresente métricas de erro global competitivas (impulsionadas pela forte inércia intrínseca das grandes bacias do SIN), a sua utilidade operacional é limitada. Por sua natureza puramente reativa, o preditor Naive sofre de atraso sistemático, falhando na antecipação de pontos de inflexão, como o início de ondas de cheia ou recessões agudas, o que é fundamental para operações reais.

Nesse contexto, o emprego das arquiteturas fuzzy evolutivas propostas é plenamente justificado pela sua capacidade de representar relações não lineares e padrões dinâmicos mais complexos presentes nas séries hidrológicas, fornecendo previsões mais precisas e consistentes, características desejáveis para aplicações de suporte ao planejamento e à operação hidrotérmica.

Diante disso, a análise subsequente concentra-se majoritariamente nos modelos orientados a dados considerados neste estudo (SMAP/ONS, FIG-FTS, LSTM e família eMG), buscando compreender como diferentes estratégias de treinamento e adaptação influenciam a capacidade preditiva em cenários hidrológicos complexos.

Os resultados da Tabela 9 apresentam diferenças claras entre os desempenhos dos modelos evolutivos baseados em lógica fuzzy (família eMG) e os modelos de benchmark com estrutura fixa (SMAP/ONS, FIG-FTS e LSTM). Nesse cenário, as abordagens não evolutivas (com destaque para os dois primeiros) apresentaram capacidade preditiva limitada. Os elevados valores de MAPE e RMSPE, associados às grandes variabilidades (desvios padrão) entre os períodos de validação, indicam uma dificuldade de generalização entre bacias com dinâmicas hidrológicas contrastantes.

Os valores negativos de NSE obtidos por esses modelos podem ser atribuídos à sensibilidade inerente dessa métrica a grandes erros de previsão (outliers). Adicionalmente, o SMAP/ONS e a LSTM demandaram tempos computacionais (por fold) consideravelmente mais altos (médias de 134,89 s e 30,78 s, respectivamente) que não se traduziram em maior acurácia. De maneira geral, esses resultados sugerem que abordagens convencionais de estrutura fixa podem enfrentar dificuldades intrínsecas para representar regimes de fluxo complexos, não lineares e variáveis, como os avaliados neste estudo.

Um ganho substancial de desempenho ocorre quando se transita dos modelos de referência não evolutivos para as abordagens baseadas em eMG. O eMG ( $NSE = 0,062$ ) superou todos os modelos não evolutivos, evidenciando o potencial de abordagens fuzzy evolutivas para representar o comportamento hidrológico não linear em bacias com características distintas.

As versões aprimoradas baseadas no eMG, incluindo o VS-eMG (da literatura) e as propostas VSA-eMG, MVSA-eMG e MVS-eMG, melhoraram ainda mais o desempenho preditivo, elevando a média de NSE para acima de 0,73 e exibindo viés percentual próximo de zero (variando de  $-0,06\%$  a  $0,26\%$ ), o que indica ausência de tendências sistemáticas de superestimação ou subestimação. Todas as versões aprimoradas exibiram ganho em performance em comparação ao eMG original, gerando apenas um pequeno incremento no número médio de regras finais (por exemplo, de 3,7 para o eMG contra 4,7 para o MVS-eMG, e chegando ao máximo de 6,1 para o VSA-eMG).

Na literatura de modelos evolutivos, o principal indicador de complexidade estrutural é o número de regras, sendo comum que configurações consideradas complexas envolvam dezenas ou até centenas de regras (LEMOS; CAMINHAS; GOMIDE, 2010). Nesse sentido, é importante destacar que, no cenário proposto, todos os modelos evolutivos alcançaram desempenho competitivo com baixos níveis de complexidade estrutural.

Esse comportamento evidencia a parcimônia dos modelos propostos, expressa pelo equilíbrio entre ganho de desempenho preditivo e aumento de complexidade estrutural, bem como reduz substancialmente o risco de overfitting (situação em que o modelo se torna excessivamente especializado nos dados de treinamento e perde capacidade de generalização). O próprio esquema de validação proposto e os resultados individuais em cada bacia reforçam essa afirmação.

O modelo MVS-eMG alcançou o melhor desempenho geral, apresentando os melhores resultados em quatro das seis métricas consideradas (por exemplo, MAPE = 2,32% e NSE = 0,788), além de exibir o menor tempo médio de execução (0,19 s), evidenciando o equilíbrio mais favorável, nesta análise, entre desempenho preditivo e eficiência computacional dentre os modelos avaliados.

O modelo MVSA-eMG registrou o segundo maior valor médio de NSE (0,751), superando marginalmente o VS-eMG (0,749). Este último, contudo, destacou-se pelo menor PBIAS (-0,06%), ainda que à custa do maior tempo de execução (0,82 s) e de uma complexidade estrutural moderada, refletida no número de regras finais (5,0). O modelo VSA-eMG também apresentou desempenho competitivo, situando-se próximo aos melhores resultados globais.

Com o objetivo de complementar os resultados agregados apresentados na Tabela 9, a Figura 10 apresenta boxplots de todas as métricas de avaliação, abrangendo todos os 28 cenários de validação (7 folds por bacia, em 4 bacias). Essa figura reforça visualmente o contraste de desempenho entre os modelos de referência não evolutivos e os modelos baseados em eMG, especialmente os modelos propostos.

Os benchmarks apresentam intervalos interquartis consideravelmente mais amplos na maioria dos casos, refletindo maior variabilidade entre bacias e folds de validação. Em contraste, os modelos eMG exibem distribuições mais compactas e concentradas próximas aos valores ótimos, com destaque para o MVS-eMG, que apresentou o melhor desempenho (tanto considerando a média quanto a mediana) em quatro das seis métricas analisadas, evidenciando sua estabilidade e confiabilidade sob diferentes condições hidrológicas.

Embora o horizonte de previsão considerado neste trabalho seja de curto prazo, é pertinente discutir o tempo de processamento dos modelos. Mesmo em escalas diárias, modelos mais rápidos apresentam vantagens claras quando aplicados a múltiplas bacias, distintos períodos de validação ou em contextos que demandam repetidas simulações, pois reduzem significativamente o custo computacional agregado. Além disso, a análise do tempo de execução permite avaliar o impacto na complexidade estrutural introduzida pelos modelos evolutivos.

Observa-se que as variantes propostas mantêm tempos de processamento competitivos em relação ao eMG original e, no caso do MVS-eMG, o tempo médio chega a ser inferior, evidenciando que o ganho preditivo foi obtido sem sobrecarga computacional significativa. Embora a eficiência computacional não seja o critério principal para avaliação hidrológica, essa informação é relevante no contexto de eFS, nos quais se busca equilibrar desempenho preditivo e complexidade estrutural.

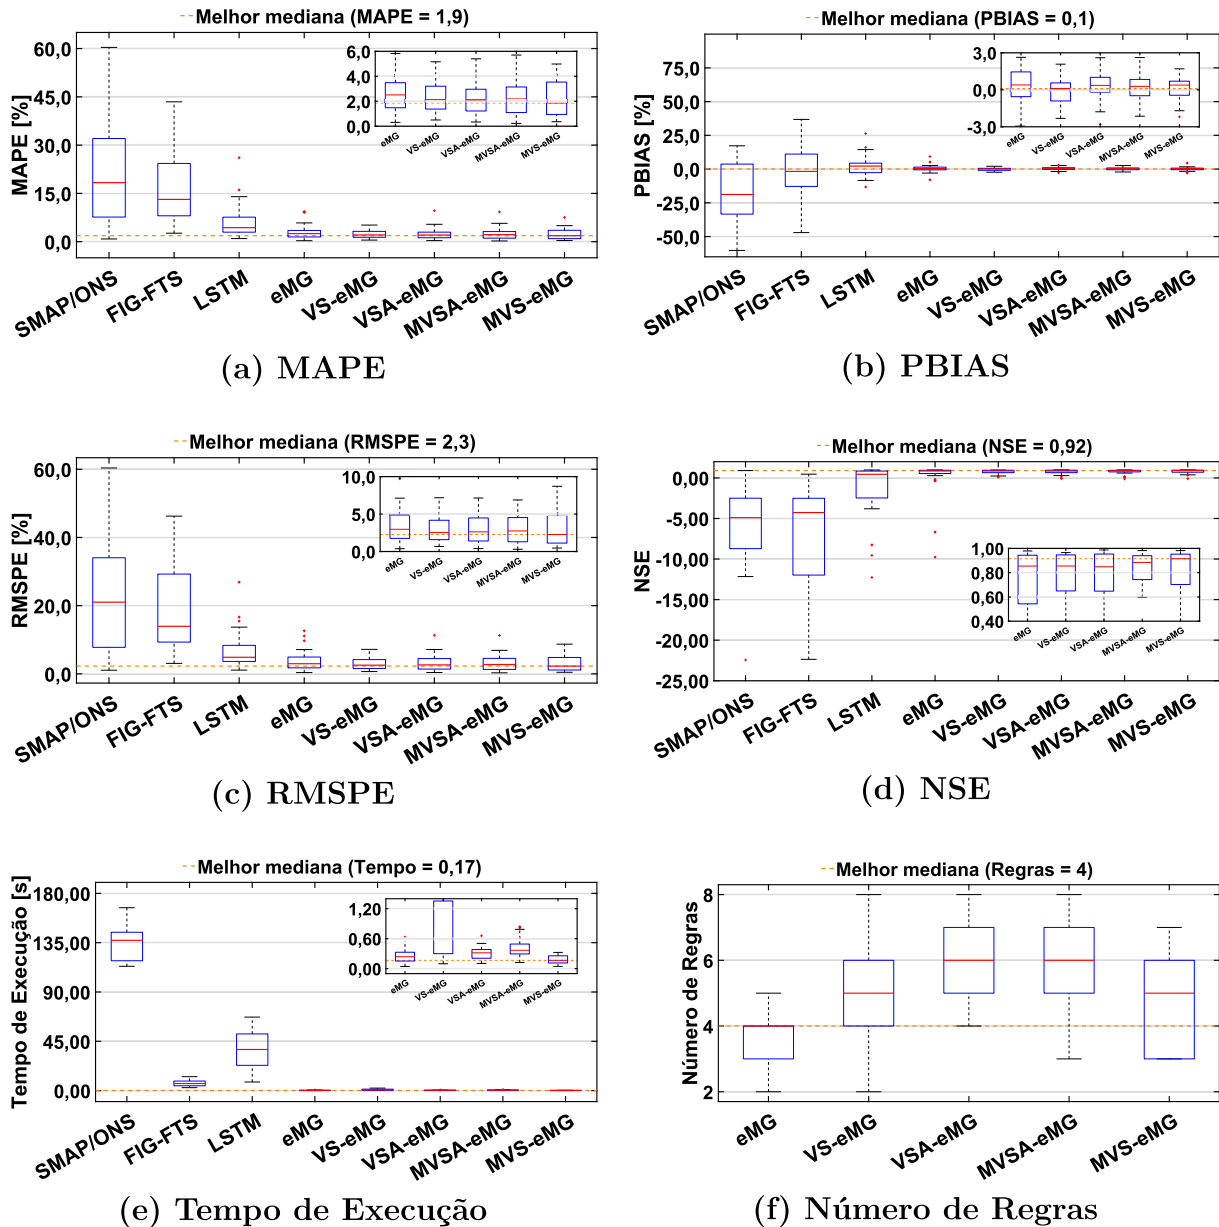


Figura 10 – Boxplots da distribuição global de desempenho de todos os modelos, agregados considerando 28 cenários de validação (7 folds em 4 bacias): (a) MAPE, (b) PBIAS, (c) RMSPE, (d) NSE, (e) Tempo de Execução e (f) Número de Regras. Os painéis ampliados (insets) fornecem uma visualização detalhada dos modelos baseados em eMG. A linha horizontal tracejada em laranja indica a melhor mediana entre todos os modelos para a respectiva métrica. Alguns outliers foram omitidos para fins de clareza visual.

Cabe destacar que a presente seção tem como objetivo analisar o comportamento global dos modelos no contexto do estudo de caso proposto, a partir da agregação dos resultados médios por bacia, permitindo a identificação de tendências gerais e padrões médios de desempenho associados às diferentes abordagens de modelagem. Essa análise fornece uma visão consolidada do comportamento dos modelos, independentemente das particularidades hidrológicas locais.

De forma complementar, uma análise igualmente relevante consiste na avaliação dos resultados obtidos individualmente em cada bacia, permitindo investigar características de desempenho específicas associadas às dinâmicas hidrológicas locais. Nesse contexto, as seções a seguir apresentam uma análise detalhada por bacia, com o objetivo de evidenciar variações de desempenho entre os períodos de validação, bem como avaliar a adaptabilidade dos modelos propostos frente a diferentes regimes de afluência e padrões de variabilidade hidrológica.

#### 4.4 BACIA DE FURNAS

A Tabela 10 apresenta as métricas de desempenho obtidas para a bacia de Furnas. Esta, que é caracterizada pelas menores afluências médias, provou ser a bacia mais desafiadora para previsão, exibindo os maiores valores de erro entre as quatro bacias. Neste cenário, o modelo VS-eMG alcançou o melhor desempenho preditivo, com o maior NSE (0,667) e o menor PBIAS ( $-0,02\%$ ).

Os modelos propostos também demonstraram desempenho competitivo: o MVS-eMG entregou o segundo melhor NSE (0,659) enquanto simultaneamente alcançou o tempo de execução mais rápido (0,29 s). Por outro lado, VSA-eMG e MVSA-eMG geraram o maior número de regras (7,6) com desempenhos competitivos. Observa-se também que o benchmark SMAP/ONS, apesar de seu NSE negativo ( $-4,136$ ), alcançou seu melhor resultado relativo nesta bacia.

Tabela 10 – Métricas de desempenho específicas da bacia de Furnas (média  $\pm$  desvio padrão) para todos os modelos avaliados. O melhor valor de cada métrica é destacado em **negrito**.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
WMA	8,05 $\pm$ 6,04	-0,21 $\pm$ 3,09	9,55 $\pm$ 7,20	0,127 $\pm$ 0,254	-	-
Naive	4,13 $\pm$ 2,70	-0,11 $\pm$ 1,67	5,13 $\pm$ 3,32	0,686 $\pm$ 0,167	-	-
SMAP/ONS	15,14 $\pm$ 8,82	-10,35 $\pm$ 15,38	16,53 $\pm$ 9,27	-4,136 $\pm$ 4,036	148,21 $\pm$ 6,19	-
FIG-FTS	19,83 $\pm$ 13,29	1,49 $\pm$ 22,78	22,22 $\pm$ 14,54	-8,340 $\pm$ 8,303	5,79 $\pm$ 1,87	-
LSTM	14,05 $\pm$ 7,04	4,49 $\pm$ 12,74	21,00 $\pm$ 10,67	-33,536 $\pm$ 54,768	22,64 $\pm$ 6,95	-
eMG	4,66 $\pm$ 3,21	2,11 $\pm$ 3,45	5,56 $\pm$ 3,49	-0,856 $\pm$ 3,953	0,38 $\pm$ 0,12	4,9 $\pm$ 0,4
VS-eMG	<b>2,78 <math>\pm</math> 0,93</b>	<b>-0,02 <math>\pm</math> 1,50</b>	<b>3,90 <math>\pm</math> 1,85</b>	<b>0,667 <math>\pm</math> 0,346</b>	0,44 $\pm$ 0,23	<b>3,4 <math>\pm</math> 1,0</b>
VSA-eMG	3,38 $\pm$ 2,81	0,99 $\pm$ 1,32	4,46 $\pm$ 3,30	0,597 $\pm$ 0,446	0,45 $\pm$ 0,09	7,6 $\pm$ 0,5
MVSA-eMG	3,67 $\pm$ 2,69	0,82 $\pm$ 1,44	4,84 $\pm$ 3,21	0,577 $\pm$ 0,432	0,64 $\pm$ 0,09	7,6 $\pm$ 0,5
MVS-eMG	3,35 $\pm$ 2,10	0,76 $\pm$ 2,04	4,18 $\pm$ 2,54	0,659 $\pm$ 0,378	<b>0,29 <math>\pm</math> 0,12</b>	5,1 $\pm$ 0,7

Complementando a análise numérica, a Figura 11 apresenta as séries temporais das vazões previstas e observadas concatenadas para os sete períodos de validação. A figura está organizada em painéis, cada um correspondente a uma bacia analisada. Visando preservar a clareza visual, a representação gráfica restringe-se ao SMAP/ONS (referência operacional), ao eMG (modelo base) e aos três modelos propostos, destacando as arquiteturas de maior interesse para o estudo.

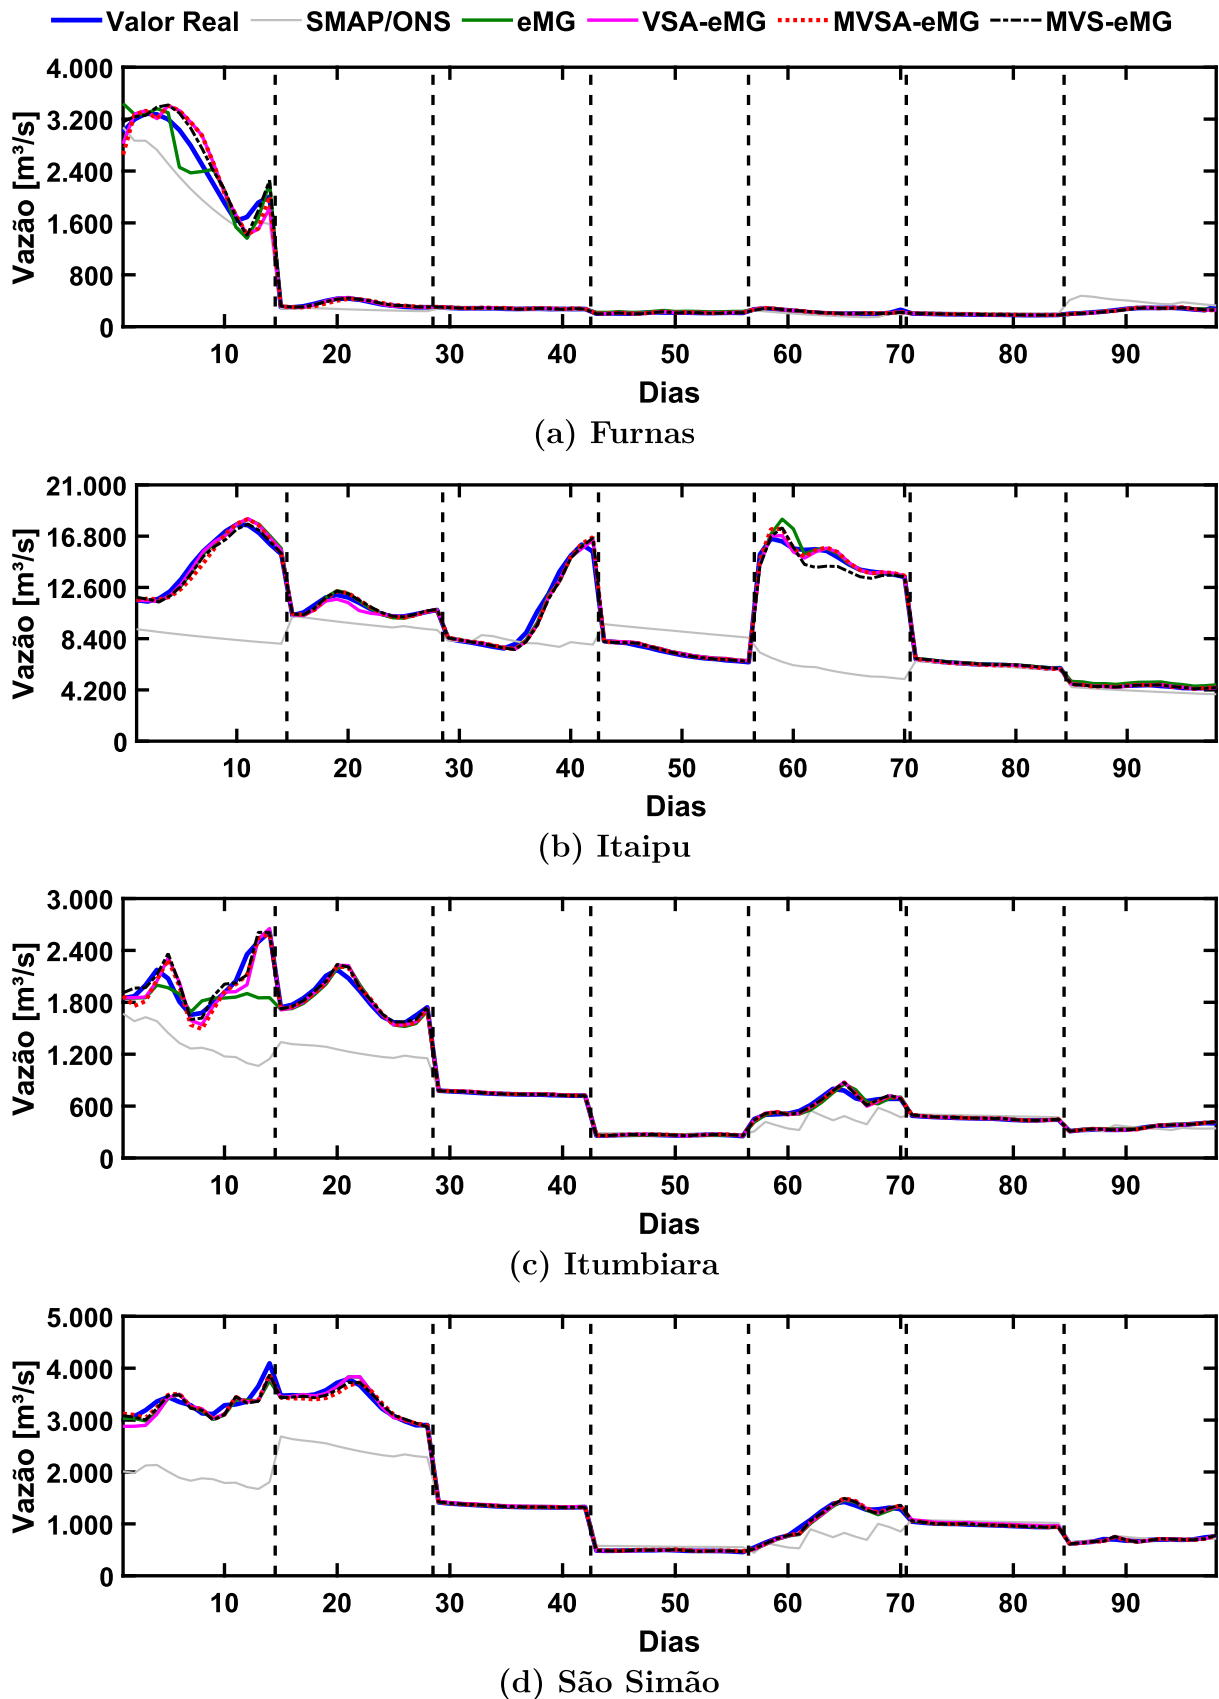


Figura 11 – Séries temporais das vazões previstas e observadas concatenadas para os sete folds de validação. Cada painel mostra a vazão observada (azul) e as previsões dos modelos (identificados na legenda superior) para as bacias de (a) Furnas, (b) Itaipu, (c) Itumbiara e (d) São Simão. As linhas verticais tracejadas indicam a separação temporal entre os folds independentes de validação (intervalos de 14 dias).

A inspeção do painel (a) da Figura 11, relativo à bacia de Furnas, evidencia que os maiores desvios ocorreram durante o primeiro fold, marcado por variações abruptas de vazão. Apesar desta dificuldade inicial, os modelos baseados em eMG exibiram alta aderência e estabilidade nos folds subsequentes, demonstrando uma forte capacidade de adaptação aos distintos regimes de vazão da bacia.

#### 4.5 BACIA DE ITAIPU

A Tabela 11 apresenta os resultados para a bacia de Itaipu, caracterizada pelas maiores afluências médias e notável variabilidade de vazão. Apesar destas condições desafiadoras, os modelos evolutivos alcançaram seu melhor desempenho geral nesta bacia, registrando as menores métricas de erro (por exemplo, MAPE) e os maiores valores de NSE neste estudo de caso.

Tabela 11 – Métricas de desempenho específicas da bacia de Itaipu (média  $\pm$  desvio padrão) para todos os modelos avaliados. O melhor valor de cada métrica é destacado em negrito.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
WMA	6,06 $\pm$ 3,75	-1,49 $\pm$ 5,03	7,49 $\pm$ 5,17	-0,106 $\pm$ 1,373	-	-
Naive	2,91 $\pm$ 1,90	-0,57 $\pm$ 2,13	3,65 $\pm$ 2,52	0,745 $\pm$ 0,239	-	-
SMAP/ONS	28,72 $\pm$ 20,27	-24,55 $\pm$ 27,31	29,78 $\pm$ 20,61	-17,323 $\pm$ 24,320	118,34 $\pm$ 3,64	-
FIG-FTS	22,06 $\pm$ 13,72	-11,83 $\pm$ 25,23	25,02 $\pm$ 15,32	-6,923 $\pm$ 4,818	7,01 $\pm$ 2,72	-
LSTM	3,41 $\pm$ 0,63	0,22 $\pm$ 2,54	4,45 $\pm$ 1,13	-0,927 $\pm$ 4,106	32,17 $\pm$ 17,28	-
eMG	2,42 $\pm$ 1,45	1,18 $\pm$ 2,01	2,97 $\pm$ 1,65	-0,201 $\pm$ 2,858	0,21 $\pm$ 0,09	<b>3,3 <math>\pm</math> 0,8</b>
VS-eMG	1,88 $\pm$ 1,28	-0,13 $\pm$ 0,82	2,37 $\pm$ 1,74	0,882 $\pm$ 0,134	0,26 $\pm$ 0,11	4,4 $\pm$ 0,8
VSA-eMG	<b>1,68 <math>\pm</math> 0,89</b>	-0,19 $\pm$ 1,14	<b>2,12 <math>\pm</math> 1,26</b>	0,875 $\pm$ 0,151	0,24 $\pm$ 0,09	5,6 $\pm$ 1,5
MVSA-eMG	1,69 $\pm$ 1,08	<b>-0,03 <math>\pm</math> 0,82</b>	2,21 $\pm$ 1,48	<b>0,885 <math>\pm</math> 0,138</b>	0,28 $\pm$ 0,11	4,3 $\pm$ 1,0
MVS-eMG	1,96 $\pm$ 1,39	-0,55 $\pm$ 1,43	2,43 $\pm$ 1,82	0,836 $\pm$ 0,227	<b>0,14 <math>\pm</math> 0,07</b>	4,7 $\pm$ 1,6

Os modelos VSA-eMG e MVSA-eMG apresentaram os melhores desempenhos em quatro métricas principais. O VSA-eMG alcançou o menor MAPE (1,68%) e RMSPE (2,12%), enquanto o MVSA-eMG registrou o melhor NSE (0,885) e PBIAS (-0,03%). O MVS-eMG também teve bom desempenho, entregando um NSE competitivo (0,836) com um número moderado de regras (4,7) e o tempo de execução mais rápido nesta bacia (0,14 s).

Entre os benchmarks, a LSTM alcançou seu melhor desempenho (NSE=-0,927), enquanto o SMAP/ONS registrou o seu pior (NSE=-17,323). Como ilustrado na Figura 11(b), os maiores erros de previsão ocorreram durante os folds 1 e 5. A habilidade dos modelos baseados em eMG de manter alta acurácia mesmo sob estas condições desafiadoras ressalta sua adaptabilidade a contextos com alta variabilidade de vazão.

#### 4.6 BACIA DE ITUMBIARA

Os resultados para a bacia de Itumbiara, apresentados na Tabela 12, destacam outro cenário desafiador, caracterizado por um comportamento hidrológico altamente diverso entre os folds (como mostrado na Figura 11(c)). Nesta bacia, o modelo proposto MVS-eMG alcançou o melhor desempenho em três métricas chave: MAPE (2,07%), RMSPE (2,61%) e NSE (0,827).

Tabela 12 – Métricas de desempenho específicas da bacia de Itumbiara (média  $\pm$  desvio padrão) para todos os modelos avaliados. O melhor valor de cada métrica é destacado em negrito.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
WMA	6,51 $\pm$ 5,16	-2,42 $\pm$ 4,84	7,61 $\pm$ 6,20	0,175 $\pm$ 0,334	-	-
Naive	3,33 $\pm$ 2,62	-0,95 $\pm$ 1,79	4,02 $\pm$ 3,25	0,726 $\pm$ 0,233	-	-
SMAP/ONS	20,40 $\pm$ 14,08	-16,70 $\pm$ 20,77	21,98 $\pm$ 15,19	-8,334 $\pm$ 6,691	134,36 $\pm$ 19,67	-
FIG-FTS	15,45 $\pm$ 10,98	-1,98 $\pm$ 20,31	17,72 $\pm$ 13,04	-8,675 $\pm$ 9,326	7,04 $\pm$ 3,09	-
LSTM	6,64 $\pm$ 2,48	2,40 $\pm$ 4,99	7,62 $\pm$ 3,01	-4,657 $\pm$ 10,926	33,50 $\pm$ 11,11	-
eMG	3,31 $\pm$ 3,07	-0,93 $\pm$ 3,22	4,21 $\pm$ 4,28	0,553 $\pm$ 0,571	<b>0,20 <math>\pm</math> 0,11</b>	<b>3,7 <math>\pm</math> 0,5</b>
VS-eMG	2,58 $\pm$ 1,71	<b>0,04 <math>\pm</math> 1,25</b>	3,17 $\pm$ 2,35	0,683 $\pm$ 0,346	1,34 $\pm$ 0,69	6,9 $\pm$ 0,7
VSA-eMG	2,40 $\pm$ 1,99	0,18 $\pm$ 0,86	2,97 $\pm$ 2,52	0,793 $\pm$ 0,236	0,31 $\pm$ 0,13	6,3 $\pm$ 0,5
MVSA-eMG	2,39 $\pm$ 2,02	0,06 $\pm$ 1,06	2,86 $\pm$ 2,39	0,795 $\pm$ 0,277	0,45 $\pm$ 0,21	6,3 $\pm$ 0,5
MVS-eMG	<b>2,07 <math>\pm</math> 1,79</b>	0,73 $\pm$ 0,46	<b>2,61 <math>\pm</math> 2,23</b>	<b>0,827 <math>\pm</math> 0,232</b>	0,21 $\pm$ 0,09	5,6 $\pm$ 1,0

Os outros modelos propostos, VSA-eMG e MVSA-eMG, também apresentaram desempenhos significativos, com o MVSA-eMG obtendo o segundo melhor NSE (0,795) e o VSA-eMG um tempo de execução entre os mais rápidos (0,31 s). Em contraste, o VS-eMG foi menos eficiente neste cenário, mostrando o tempo de execução mais lento (1,34 s) e a maior contagem de regras (6,9) entre os modelos evolutivos, com um NSE comparativamente menor (0,683). Como visto na Figura 11(c), os modelos propostos adaptaram-se efetivamente após desvios significativos nos dois primeiros folds, demonstrando sua robustez sob condições distintas.

#### 4.7 BACIA DE SÃO SIMÃO

Os resultados para a bacia de São Simão, apresentados na Tabela 13, indicam outro ambiente exigente, marcado por variabilidade substancial nas condições de vazão através dos folds (como mostrado na Figura 11(d)). Apesar disso, o modelo proposto MVS-eMG entregou seu desempenho mais consistente e preciso entre todas as bacias, apresentando melhor desempenho em quatro das seis métricas avaliadas: MAPE (1,89%), RMSPE (2,35%), NSE (0,829) e tempo de execução (0,11 s, menor tempo geral). Também exibiu pequenos desvios padrão (baixa variabilidade entre folds), a segunda menor contagem média de regras (3,3) e PBIAS próximo de zero (-0,28%), confirmando seu equilíbrio entre desempenho preditivo, estabilidade e parcimônia.

Tabela 13 – Métricas de desempenho específicas da bacia de São Simão (média  $\pm$  desvio padrão) para todos os modelos avaliados. O melhor valor de cada métrica é destacado em negrito.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
WMA	5,70 $\pm$ 5,69	-2,30 $\pm$ 5,94	6,93 $\pm$ 6,76	0,178 $\pm$ 0,400	-	-
Naive	2,88 $\pm$ 2,82	-0,93 $\pm$ 2,41	3,52 $\pm$ 3,31	0,757 $\pm$ 0,145	-	-
SMAP/ONS	20,90 $\pm$ 14,31	-14,21 $\pm$ 22,54	21,94 $\pm$ 14,50	-22,407 $\pm$ 38,590	138,65 $\pm$ 3,20	-
FIG-FTS	10,06 $\pm$ 3,89	2,52 $\pm$ 7,47	12,02 $\pm$ 4,93	-13,988 $\pm$ 28,518	7,40 $\pm$ 3,59	-
LSTM	4,71 $\pm$ 1,58	0,68 $\pm$ 3,63	6,30 $\pm$ 2,12	-3,343 $\pm$ 6,972	34,81 $\pm$ 12,66	-
eMG	2,15 $\pm$ 1,69	-0,45 $\pm$ 1,59	2,66 $\pm$ 2,05	0,753 $\pm$ 0,270	0,19 $\pm$ 0,08	<b>2,9 <math>\pm</math> 0,4</b>
VS-eMG	2,17 $\pm$ 1,37	-0,12 $\pm$ 1,00	2,57 $\pm$ 1,59	0,763 $\pm$ 0,181	1,25 $\pm$ 0,61	5,3 $\pm$ 0,8
VSA-eMG	2,54 $\pm$ 1,44	<b>0,04 <math>\pm</math> 1,83</b>	2,97 $\pm$ 1,72	0,654 $\pm$ 0,287	0,25 $\pm$ 0,10	5,0 $\pm$ 1,0
MVSA-eMG	2,04 $\pm$ 1,36	-0,08 $\pm$ 0,90	2,51 $\pm$ 1,63	0,748 $\pm$ 0,318	0,35 $\pm$ 0,15	5,4 $\pm$ 0,8
MVS-eMG	<b>1,89 <math>\pm</math> 1,35</b>	-0,28 $\pm$ 0,76	<b>2,35 <math>\pm</math> 1,74</b>	<b>0,829 <math>\pm</math> 0,161</b>	<b>0,11 <math>\pm</math> 0,05</b>	3,3 $\pm$ 0,5

O modelo MVSA-eMG apresentou o segundo melhor resultado, com valor médio de NSE ligeiramente inferior (0,748). O VSA-eMG, por sua vez, apresentou NSE médio de 0,654 com o menor viés (0,04%). Além disso, o eMG padrão permaneceu competitivo (NSE=0,753), enquanto o VS-eMG apresentou melhoria marginal ao custo de maior complexidade (5,3 regras). O FIG-FTS alcançou seu melhor desempenho nesta bacia, embora ainda significativamente abaixo dos modelos evolutivos.

Como observado na Figura 11(d), os dois primeiros folds mostraram maiores discrepâncias, contudo, todos os modelos evolutivos adaptaram-se efetivamente, destacando a robustez de seus mecanismos de aprendizado adaptativo em uma bacia de grande volume e altamente variável.

#### 4.8 ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA

Embora as métricas de desempenho apresentadas nas seções anteriores indiquem diferenças relevantes no desempenho preditivo entre os modelos avaliados, a verificação estatística é necessária para determinar se tais diferenças são estatisticamente significativas.

Para esse fim, foram empregados dois testes estatísticos, utilizados de maneira complementar: o teste de Morgan–Granger–Newbold (MGN), um teste paramétrico adequado à comparação de erros de previsão correlacionados, e o teste não paramétrico *Wilcoxon Signed-Rank*.

A Tabela 14 apresenta os  $p$ -valores obtidos nos dois testes para todas as comparações pareadas entre os modelos, considerando as quatro bacias avaliadas. A rejeição da hipótese nula (indicada pelos valores em negrito, quando  $p < 0,05$  em cada um dos testes estatísticos) comprova a existência de diferença estatisticamente significativa entre os desempenhos preditivos dos pares analisados. Os resultados estão organizados em blocos por bacia hidrográfica, sendo cada bloco subdividido em comparações entre os três modelos propostos e cada um dos benchmarks orientados a dados considerados neste estudo, e, por fim, a última subdivisão apresenta as comparações entre os próprios modelos propostos.

Tabela 14 – Análise de significância estatística comparativa para o Estudo de Caso 1. Os testes de Morgan–Granger–Newbold (MGN) e *Wilcoxon Signed-Rank* foram aplicados aos resíduos de previsão concatenados dos sete períodos de teste ( $n = 98$  amostras por bacia). A coluna Evidência indica, quando aplicável, o modelo com menor erro médio (MAPE), classificando o resultado como Forte (ambos os testes com  $p < 0,05$ ), Parcial (apenas um teste com  $p < 0,05$ ) ou Sem Evidência (ambos os testes com  $p \geq 0,05$ ). Valores em negrito nos  $p$ -valores denotam rejeição da hipótese nula.

Modelo 1 vs. Modelo 2	MGN $p$ -valor	Wilcoxon $p$ -valor	Evidência (Melhor Modelo)
<b>Bacia: Furnas</b>			
VSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	0,095	< <b>0,001</b>	Parcial (MVS-eMG)
VSA-eMG vs. eMG	0,503	< <b>0,001</b>	Parcial (VSA-eMG)
MVSA-eMG vs. eMG	0,660	<b>0,001</b>	Parcial (MVSA-eMG)
MVS-eMG vs. eMG	< <b>0,001</b>	<b>0,010</b>	Forte (MVS-eMG)
VSA-eMG vs. VS-eMG	< <b>0,001</b>	0,325	Parcial (VS-eMG)
MVSA-eMG vs. VS-eMG	< <b>0,001</b>	<b>0,002</b>	Forte (VS-eMG)
MVS-eMG vs. VS-eMG	<b>0,010</b>	<b>0,027</b>	Forte (VS-eMG)
MVSA-eMG vs. VSA-eMG	0,386	0,377	Sem Evidência
MVS-eMG vs. VSA-eMG	< <b>0,001</b>	0,482	Parcial (MVS-eMG)
MVS-eMG vs. MVSA-eMG	< <b>0,001</b>	0,460	Parcial (MVS-eMG)
<b>Bacia: Itaipu</b>			
VSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	<b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	<b>0,003</b>	<b>0,003</b>	Forte (VSA-eMG)
MVSA-eMG vs. eMG	0,208	<b>0,030</b>	Parcial (MVSA-eMG)
MVS-eMG vs. eMG	0,430	0,104	Sem Evidência
VSA-eMG vs. VS-eMG	< <b>0,001</b>	0,230	Parcial (VSA-eMG)
MVSA-eMG vs. VS-eMG	0,180	<b>0,032</b>	Parcial (MVSA-eMG)
MVS-eMG vs. VS-eMG	0,209	0,541	Sem Evidência

Continua na próxima página.

Tabela 14 – Resultados estatísticos para o Estudo de Caso 1 (continuação).

<b>Modelo 1 vs. Modelo 2</b>	<b>MGN <i>p</i>-valor</b>	<b>Wilcoxon <i>p</i>-valor</b>	<b>Evidência (Melhor Modelo)</b>
MVSA-eMG vs. VSA-eMG	<b>0,027</b>	0,125	Parcial (VSA-eMG)
MVS-eMG vs. VSA-eMG	< <b>0,001</b>	0,398	Parcial (VSA-eMG)
MVS-eMG vs. MVSA-eMG	0,069	0,543	Sem Evidência
<b>Bacia: Itumbiara</b>			
VSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. LSTM	0,864	< <b>0,001</b>	Parcial (VSA-eMG)
MVSA-eMG vs. LSTM	0,474	< <b>0,001</b>	Parcial (MVSA-eMG)
MVS-eMG vs. LSTM	0,127	< <b>0,001</b>	Parcial (MVS-eMG)
VSA-eMG vs. eMG	< <b>0,001</b>	<b>0,002</b>	Forte (VSA-eMG)
MVSA-eMG vs. eMG	< <b>0,001</b>	<b>0,008</b>	Forte (MVSA-eMG)
MVS-eMG vs. eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. VS-eMG	0,402	<b>0,020</b>	Parcial (VSA-eMG)
MVSA-eMG vs. VS-eMG	<b>0,043</b>	0,141	Parcial (MVSA-eMG)
MVS-eMG vs. VS-eMG	<b>0,008</b>	< <b>0,001</b>	Forte (MVS-eMG)
MVSA-eMG vs. VSA-eMG	<b>0,026</b>	0,525	Parcial (MVSA-eMG)
MVS-eMG vs. VSA-eMG	<b>0,003</b>	< <b>0,001</b>	Forte (MVS-eMG)
MVS-eMG vs. MVSA-eMG	0,290	< <b>0,001</b>	Parcial (MVS-eMG)
<b>Bacia: São Simão</b>			
VSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. SMAP/ONS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. FIG-FTS	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. LSTM	<b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	0,089	<b>0,010</b>	Parcial (eMG)
MVSA-eMG vs. eMG	0,429	0,473	Sem Evidência
MVS-eMG vs. eMG	<b>0,016</b>	0,456	Parcial (MVS-eMG)
VSA-eMG vs. VS-eMG	<b>0,003</b>	0,574	Parcial (VS-eMG)
MVSA-eMG vs. VS-eMG	0,272	0,079	Sem Evidência
MVS-eMG vs. VS-eMG	0,775	<b>0,036</b>	Parcial (MVS-eMG)
MVSA-eMG vs. VSA-eMG	0,098	<b>0,004</b>	Parcial (MVSA-eMG)
MVS-eMG vs. VSA-eMG	<b>0,002</b>	<b>0,003</b>	Forte (MVS-eMG)
MVS-eMG vs. MVSA-eMG	<b>0,028</b>	0,624	Parcial (MVS-eMG)

Em resumo, para cada comparação, a análise incorpora quatro elementos: o  $p$ -valor obtido no teste MGN, o  $p$ -valor obtido no teste de Wilcoxon, o MAPE médio do Modelo 1 e o MAPE médio do Modelo 2. A evidência estatística resultante é classificada em três categorias: Evidência Forte, quando ambos os testes apresentam  $p < 0,05$ ; Evidência Parcial, quando apenas um dos testes apresenta  $p < 0,05$ ; ou Sem Evidência, quando ambos os testes apresentam  $p \geq 0,05$ . Em todos os casos, a indicação do melhor modelo baseia-se na comparação direta entre os valores médios de MAPE associados aos modelos avaliados, desde que haja ao menos uma evidência estatística de diferença significativa ( $p < 0,05$ ).

A análise dos resultados estatísticos apresentados na Tabela 14 inicia-se com as comparações entre os três modelos propostos (VSA-eMG, MVSA-eMG e MVS-eMG) e os modelos de benchmark não evolutivos (SMAP/ONS, FIG-FTS e LSTM), considerando as quatro bacias avaliadas. Os resultados indicam que os modelos propostos apresentaram evidência estatística forte em 100% das comparações com o SMAP/ONS e o FIG-FTS. Tal comportamento era esperado, dadas as diferenças substanciais de desempenho previamente observadas nas métricas de avaliação global (Seção 4.3).

Essa evidência confirma uma superioridade estatística consistente dos modelos propostos em relação ao SMAP/ONS em todos os cenários avaliados, o que é particularmente relevante no contexto deste estudo, considerando que o SMAP/ONS foi selecionado por ser um dos modelos de referência operacional utilizados no setor elétrico brasileiro.

Em relação à comparação com a rede LSTM, os modelos propostos também apresentaram desempenho estatisticamente superior na maioria dos casos, obtendo evidência forte ou parcial em 100% das comparações. Esses resultados novamente refletem o que foi observado na comparação global dos resultados. Destaca-se, adicionalmente, que a LSTM apresentou desempenho significativamente superior ao SMAP/ONS e ao FIG-FTS, corroborando seu caráter de método de estado da arte e justificando sua inclusão como referência competitiva nas comparações realizadas.

Em contraste, as comparações entre os modelos propostos e os outros dois modelos evolutivos da literatura (eMG e VS-eMG) exibiram resultados mais heterogêneos. A análise conjunta indicou evidência forte ou parcial de diferença estatística em 20 dos 24 cenários (83,3%).

Contudo, diferentemente do observado nas comparações com os benchmarks não evolutivos, a direção dessa diferença variou conforme o cenário avaliado. Enquanto em bacias como Itumbiara observou-se uma predominância de superioridade dos modelos propostos, em cenários como Furnas os modelos da literatura, em especial o VS-eMG, apresentaram evidências, fortes ou parciais, favoráveis ao seu desempenho. Os quatro casos restantes (16,7%) foram classificados como sem evidência estatística, indicando equivalência estatística entre as abordagens nesses cenários específicos.

É importante esclarecer que a ocorrência de  $p$ -valores não significativos ( $p \geq 0,05$ ) em pelo menos um dos testes pode ser atribuída principalmente a dois fatores: (a) equivalência estatística genuína decorrente de desempenhos muito próximos, como observado na comparação MVS-eMG vs. VS-eMG para Itaipu, em que os valores médios de MAPE foram muito próximos (1,96% e 1,88%, respectivamente); e/ou (b) alta variabilidade entre os folds, que pode mascarar potenciais diferenças médias nos testes.

Este segundo caso é ilustrado pela comparação VSA-eMG vs. eMG para Furnas: embora os valores médios de MAPE difiram (3,38% vs. 4,66%), os elevados desvios padrão ( $\pm 2,81$  e  $\pm 3,21$ ) indicam inconsistência ao longo dos folds de validação, resultando em um  $p$ -valor de 0,503 no teste MGN, ainda que o teste de Wilcoxon tenha detectado diferença significativa.

Sob uma perspectiva hidrológica, essa variabilidade entre folds pode refletir dificuldades de generalização ao longo da validação cruzada, possivelmente associadas a mudanças nos regimes de vazão ou à sensibilidade da relação entrada-saída da bacia.

Uma ilustração visual dessa variabilidade pode ser observada no primeiro fold da bacia de Furnas (Figura 11(a)): durante um evento de variação abrupta de vazão (caracterizado por uma rápida elevação seguida de queda em um intervalo de poucos dias), os modelos apresentaram uma aderência ligeiramente inferior aos dados observados quando comparados a outros períodos de maior regularidade hidrológica.

É importante destacar que, mesmo nos casos em que ocorreram resultados estatísticos não significativos, o desempenho dos modelos propostos manteve-se, em geral, numericamente próximo ao dos modelos evolutivos de melhor desempenho (como o eMG ou VS-eMG) em cada bacia. Esse comportamento indica que tais oscilações pontuais não comprometeram a competitividade global das abordagens propostas dentro da família de modelos eMG.

Finalmente, a comparação estatística direta entre os três modelos propostos revelou diferenças significativas na maioria dos cenários analisados, com vantagem consistente para o modelo MVS-eMG, que apresentou o melhor desempenho global. Essa análise é relevante não apenas sob a ótica quantitativa, mas também qualitativa, uma vez que o objetivo não é estabelecer uma hierarquia rígida entre os modelos, mas sim demonstrar que os diferentes mecanismos adaptativos incorporados ao eMG resultam em comportamentos de previsão distintos, validando estatisticamente a particularidade de cada abordagem.

Esses resultados reforçam que, no escopo deste estudo de caso, todas as estratégias adaptativas propostas contribuíram para a melhoria do desempenho preditivo em relação aos benchmarks considerados, destacando o MVS-eMG como a alternativa mais consistente entre as bacias avaliadas.

## 4.9 DISCUSSÃO

Embora os modelos não evolutivos (SMAP/ONS, FIG-FTS e LSTM) tenham apresentado menor acurácia preditiva em comparação aos modelos evolutivos, seus resultados permanecem consistentes e relevantes dentro da estrutura experimental adotada. Esses modelos constituem referências consolidadas na literatura e, no contexto desta avaliação experimental, seu desempenho limitado não denota inadequação intrínseca, mas evidencia os desafios enfrentados por arquiteturas de estrutura fixa ao lidar com regimes hidrológicos dinâmicos.

Consequentemente, esses benchmarks cumprem o papel de modelos de referência robustos, permitindo que os modelos propostos sejam avaliados não apenas pela busca de um preditor universalmente ótimo, mas por meio de uma estrutura metodológica que evidencia os benefícios da adaptabilidade no desempenho de previsão em cenários reais.

A eficácia dos mecanismos adaptativos propostos é corroborada pela melhoria significativa de desempenho em relação ao eMG original e pela distinção estatística entre as variantes. O modelo MVS-eMG emprega uma estratégia que redefine prontamente o nível de significância ( $\lambda$ ) para seu limite inferior quando o erro de previsão é reduzido, permitindo que o modelo mantenha estabilidade preditiva máxima e minimize o esforço computacional.

Em contrapartida, as abordagens VSA-eMG e MVSA-eMG fundamentam-se em ajustes mais suaves e graduais, o que tende a preservar estruturas passadas por mais tempo, resultando em maior complexidade. A robustez superior do MVS-eMG reflete sua habilidade de lidar efetivamente com mudanças agudas na vazão, como aquelas observadas nas bacias testadas, priorizando a estabilização rápida e a responsividade imediata ao erro. Isso indica que a capacidade aprimorada de generalização do modelo deriva de seu design adaptativo, que equilibra eficientemente a parcimônia estrutural com a reatividade necessária durante mudanças de regime.

Esta discussão encerra o Estudo de Caso 1, que constituiu o principal eixo de avaliação dos modelos propostos neste trabalho. Uma vez demonstrada a eficácia dos mecanismos adaptativos e sua superioridade estatística frente aos benchmarks nas quatro bacias analisadas, os resultados obtidos estabelecem uma base consistente para a avaliação da capacidade de generalização dessas arquiteturas. Os Estudos de Caso 2 e 3 têm por objetivo corroborar a consistência desses achados em cenários distintos e sob diferentes configurações experimentais, reforçando a aplicabilidade e a robustez das abordagens evolutivas desenvolvidas.

## 5 ESTUDO DE CASO 2: AVALIAÇÃO DE ROBUSTEZ SOB ESTRESSE HÍDRICO

Enquanto o Estudo de Caso 1 teve como objetivo principal avaliar o desempenho preditivo dos modelos sob condições hidrológicas típicas e representativas, o Estudo de Caso 2 é dedicado à análise de robustez das abordagens propostas em um cenário caracterizado por estresse hídrico severo.

A análise contempla as mesmas quatro bacias previamente investigadas (Furnas, Itaipu, Itumbiara e São Simão), assegurando consistência comparativa. O conjunto de dados empregado neste estudo de caso compreende o período aproximado de 2019–2021. Esse período foi contextualizado na introdução deste trabalho, sendo caracterizado por vazões persistentemente abaixo das médias históricas, redução crítica dos volumes armazenados e alterações na dinâmica chuva–vazão em bacias estratégicas do SIN (Ministério de Minas e Energia (MME), 2021; Serviço Geológico do Brasil (SGB/CPRM), 2021). Tais condições impõem desafios adicionais aos modelos de previsão, uma vez que violam pressupostos implícitos de estabilidade estatística frequentemente assumidos por abordagens tradicionais de calibração e modelagem.

Neste contexto, o Estudo de Caso 2 foi concebido como um teste de estresse metodológico multifacetado. Essa abordagem permite organizar a avaliação de robustez em três aspectos complementares. O primeiro aspecto refere-se à generalização temporal, avaliando a capacidade dos modelos de sustentar o desempenho preditivo em períodos futuros, distintos daqueles utilizados para o treinamento e para a definição das regras iniciais.

O segundo aspecto está relacionado à resiliência ao estresse hídrico, verificando a estabilidade das arquiteturas propostas quando submetidas a regimes de vazão e precipitação estatisticamente distintos da série histórica média, característicos do período de estresse analisado. Por fim, o terceiro aspecto diz respeito à estabilidade da parametrização, investigando a viabilidade operacional de manter fixos os hiperparâmetros otimizados em cenários anteriores, avaliando se a solução obtida no Estudo de Caso 1 é suficientemente robusta para acomodar novos regimes hidrológicos sem a necessidade de recalibragem contínua.

Essa estratégia reflete situações operacionais reais nas quais a reotimização contínua de modelos não é viável diante de eventos extremos, exigindo que a adaptação ocorra predominantemente por meio da dinâmica evolutiva das arquiteturas, e não apenas pela atualização de parâmetros externos.

A metodologia experimental adotada segue rigorosamente o protocolo estabelecido no Estudo de Caso 1, assegurando consistência na definição das variáveis de entrada, no esquema de validação cruzada e nas métricas de avaliação. Embora a estrutura de validação cruzada permaneça idêntica, os intervalos temporais são ajustados ao novo

período de análise, possibilitando a avaliação robusta dos modelos no cenário de estresse hídrico considerado.

Dessa forma, este estudo de caso permite investigar não apenas a acurácia pontual dos modelos, mas, principalmente, sua confiabilidade e robustez estrutural diante de cenários críticos, aspecto fundamental para aplicações operacionais em sistemas de suporte à decisão no setor energético.

## 5.1 CENÁRIO EXPERIMENTAL

O recorte temporal empregado neste estudo de caso possui a mesma origem descrita na Seção **3.6.1**. O período considerado neste segundo estudo de caso compreende aproximadamente dois anos e quatro meses, de 31 de agosto de 2019 a 31 de dezembro de 2021, totalizando 853 amostras diárias por bacia. Este conjunto de dados é o mesmo utilizado em Alves (2024). Embora mais curto que o intervalo utilizado no Estudo de Caso 1, o período considerado é suficiente para avaliar o comportamento dos modelos em um contexto hidrológico distinto, caracterizado por períodos com vazões e índices de precipitação inferiores às médias históricas em várias regiões do país.

De forma semelhante ao procedimento empregado no estudo de caso anterior, os intervalos de teste foram definidos a priori, sem inspeção prévia dos dados específicos de cada bacia, garantindo a ausência de viés na seleção. A escolha das datas foi orientada pelos padrões sazonais típicos do Brasil, de modo a contemplar períodos de cheias, secas e de transição dentro da série considerada.

As séries temporais completas para cada bacia são apresentadas na Figura 12. O esquema de validação cruzada com janelas expandidas inclui novamente sete folds de validação, com um período inicial de aproximadamente um ano destinado à adaptação estrutural dos modelos à nova dinâmica hidrológica, cobrindo diferentes regimes hidrológicos ao longo de 2020 e 2021.

Os períodos de teste incluem sete intervalos ao longo das séries históricas, organizados cronologicamente e seguidos do período climático correspondente: 01 a 14 de setembro de 2020 (fold 1, seca); 01 a 14 de dezembro de 2020 (fold 2, cheia); 01 a 14 de fevereiro de 2021 (fold 3, cheia); 01 a 14 de abril de 2021 (fold 4, transição); 01 a 14 de junho de 2021 (fold 5, transição); 01 a 14 de setembro de 2021 (fold 6, seca); e 01 a 14 de dezembro de 2021 (fold 7, cheia).

A ilustração do esquema de validação empregado especificamente para este estudo de caso é apresentada na Figura 13. Esses intervalos permitem que os modelos sejam avaliados sob condições hidrológicas contrastantes, possibilitando uma análise abrangente de sua robustez e capacidade de generalização em cenários distintos daqueles observados no Estudo de Caso 1.

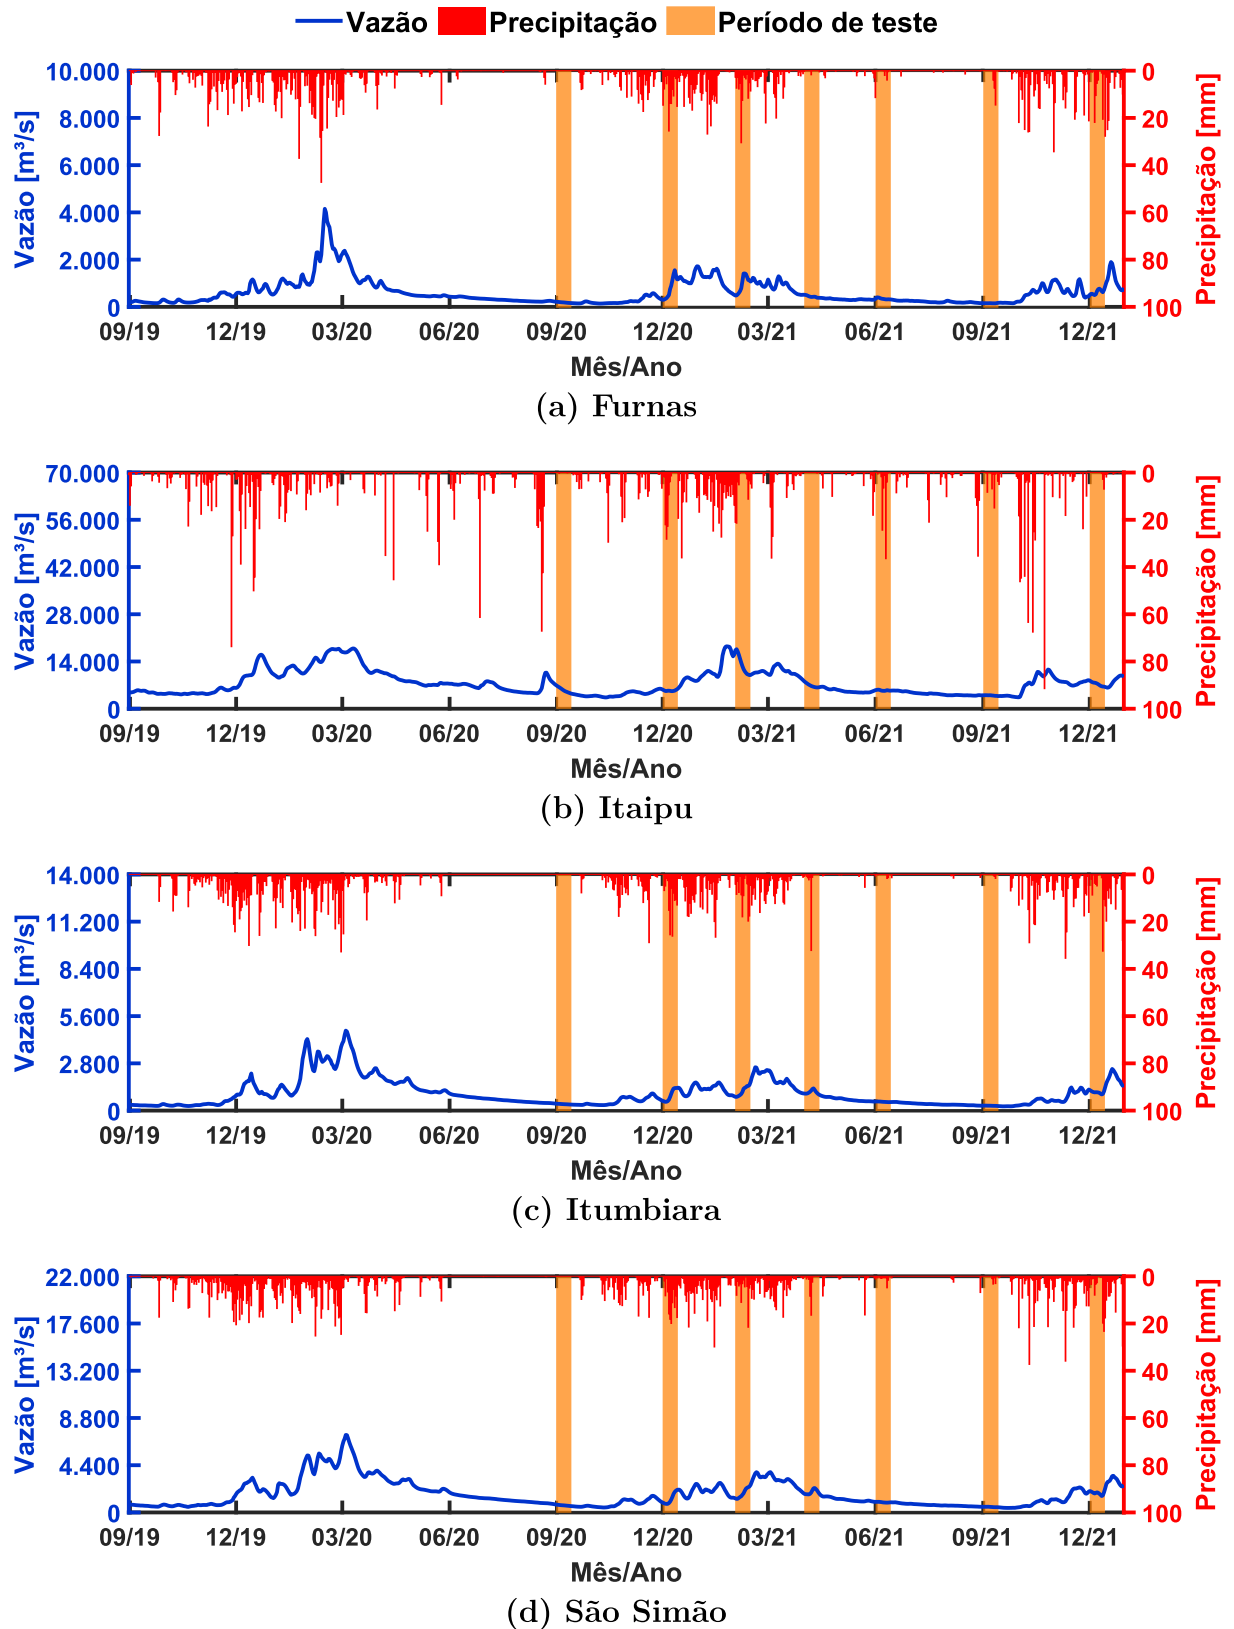


Figura 12 – Séries temporais diárias de vazão (linha azul) e precipitação (barras vermelhas) nas bacias de (a) Furnas, (b) Itaipu, (c) Itumbiara e (d) São Simão no período de 2019–2021. As faixas verticais (laranja) indicam os sete períodos de teste de 14 dias utilizados para a validação dos modelos.

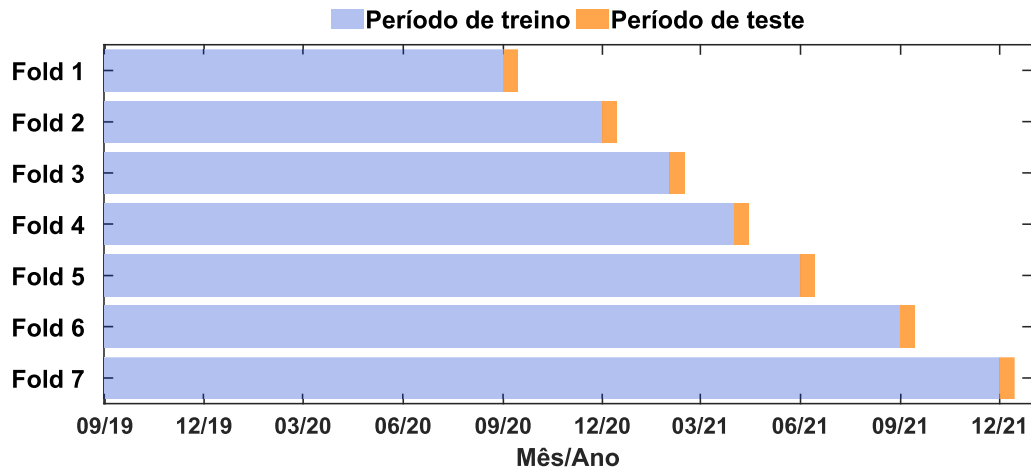


Figura 13 – Esquema de validação cruzada com janelas expandidas empregado no Estudo de Caso 2. De maneira análoga ao Estudo de Caso 1, o conjunto de treinamento (azul) cresce progressivamente, enquanto os períodos de teste (laranja) avaliam o modelo em janelas independentes de 14 dias cobrindo diferentes regimes hidrológicos.

### 5.1.1 Caracterização do Cenário de Estresse Hídrico

A Tabela 15 apresenta as estatísticas descritivas básicas das séries de vazão afluyente no período de 2019–2021, correspondente ao intervalo analisado no Estudo de Caso 2. Os valores sintetizam a escala e a variabilidade hidrológica observadas nas quatro bacias durante um período marcado por condições mais restritivas de disponibilidade hídrica.

Tabela 15 – Estatísticas descritivas das séries de vazão ( $\text{m}^3/\text{s}$ ) e precipitação (mm) no período de 2019–2021, incluindo mínimo, máximo e média  $\pm$  desvio padrão.

Bacia	Variável	Mínimo	Máximo	Média
Furnas	Vazão	139	4151	602,4 $\pm$ 538,2
	Precipitação	0	48	3,3 $\pm$ 6,1
Itaipu	Vazão	3343	18476	7570,2 $\pm$ 3593,1
	Precipitação	0	92	3,9 $\pm$ 9,3
Itumbiara	Vazão	251	4740	1000,0 $\pm$ 800,5
	Precipitação	0	36	3,5 $\pm$ 6,0
São Simão	Vazão	422	7224	1673,5 $\pm$ 1223,0
	Precipitação	0	38	3,3 $\pm$ 5,4

Ao contrastar as estatísticas descritivas do Estudo de Caso 2 (Tabela 15) com o período histórico avaliado no Estudo de Caso 1 (Tabela 7), evidencia-se uma mudança substancial no regime hidrológico observado nas bacias consideradas da RH do Paraná. O período de 2019 a 2021 foi marcado por uma severa escassez hídrica, refletindo-se em uma redução generalizada das vazões médias. O impacto foi particularmente expressivo na bacia de Itaipu, que registrou uma redução de 34,2% na vazão média.

Contudo, a principal diferenciação entre os cenários reside na forte redução dos eventos extremos de cheia e na alteração da distribuição observada das vazões. Verifica-se um colapso dos valores máximos em todas as bacias analisadas, com reduções de 45,3% em Itaipu, 31,3% em São Simão e 30,1% em Itumbiara. Em contraste, as médias de precipitação permaneceram relativamente estáveis entre os dois períodos. Esse comportamento sugere modificações relevantes na resposta hidrológica das bacias, consistentes com as condições de estiagem prolongada observadas durante o período analisado.

Essas características reforçam o enquadramento do Estudo de Caso 2 como um cenário de estresse hídrico, corroborado por notas técnicas emitidas no período (Serviço Geológico do Brasil (SGB/CPRM), 2021). As alterações na escala e na variabilidade das séries impõem desafios adicionais aos modelos de previsão, sobretudo no que se refere à generalização temporal e à adaptação a regimes não estacionários.

### 5.1.2 Configuração dos Modelos de Previsão

Com o objetivo de garantir uma comparação metodologicamente consistente, este estudo de caso avalia o desempenho dos três modelos propostos aplicados ao novo cenário experimental apresentado. Adicionalmente, são considerados os três modelos de melhor desempenho no estudo de caso anterior, a saber: eMG, VS-eMG e LSTM. A exclusão dos modelos de menor desempenho (SMAP/ONS e FIG-FTS) fundamenta-se não apenas nos resultados observados no Estudo de Caso 1, mas também em evidências da literatura.

Alves (2024), ao avaliar o desempenho do modelo SMAP/ONS e do FIG-FTS nas mesmas bacias e no mesmo período de análise (2019–2021), ainda que sob um esquema de validação distinto e menos rigoroso, reportou valores de MAPE situados entre 14% e 35% para o SMAP/ONS e entre 11% e 23% para o FIG-FTS. A magnitude desses erros evidencia limitações estruturais dessas abordagens em cenários de forte variabilidade hidrológica, justificando a concentração da análise nos modelos mencionados.

Os modelos da família eMG são aplicados utilizando exatamente os mesmos hiperparâmetros otimizados para o Estudo de Caso 1 (Tabela 8), de modo a preservar a equidade da comparação e avaliar sua capacidade de generalização temporal e robustez sob condições hidrológicas adversas. Dessa forma, os cinco modelos evolutivos foram executados seguindo exatamente a metodologia geral previamente adotada, porém empregando os dados e os períodos de avaliação descritos na seção anterior.

No caso da rede LSTM, foi utilizada a mesma topologia aplicada no estudo de caso anterior. O modelo é treinado em batch utilizando exclusivamente os dados do período correspondente ao Estudo de Caso 2, isto é, sem qualquer influência dos dados empregados no Estudo de Caso 1. Tal escolha é justificada pela natureza intrínseca das redes neurais, cujo processo de treinamento requer necessariamente dados representativos do regime atual para manter desempenho competitivo, bem como para garantir a adequação ao método de

validação proposto.

Cabe destacar que essa configuração impõe um desafio adicional aos modelos evolutivos, uma vez que estes são avaliados sem reotimização ou recalibragem específica, simulando um cenário operacional realista onde ajustes manuais frequentes de parâmetros nem sempre são viáveis.

## 5.2 ANÁLISE INTEGRADA DE DESEMPENHO E ROBUSTEZ

Os resultados obtidos no Estudo de Caso 2 permitem avaliar a robustez dos modelos sob um regime hidrológico significativamente mais adverso do que aquele considerado no Estudo de Caso 1, para o qual os hiperparâmetros foram otimizados. Nesse contexto, a avaliação de robustez concentra-se na capacidade das arquiteturas propostas de se adaptar a mudanças severas no regime hidrológico, mantendo um comportamento preditivo consistente mesmo sob condições operacionais distintas daquelas observadas durante a calibração (otimização dos hiperparâmetros). Os resultados das simulações nas quatro bacias são apresentados nas Tabelas 16 a 19.

Em contraste com a abordagem multibacia adotada no Estudo de Caso 1, optou-se aqui pela avaliação individualizada dos resultados por bacia. Essa decisão metodológica fundamenta-se na necessidade de diagnosticar a robustez local sob estresse hídrico, já que uma análise agregada tenderia a mascarar comportamentos divergentes e dificuldades específicas de bacias com diferentes características hidrológicas.

É importante destacar que, embora as bacias analisadas sejam as mesmas do Estudo de Caso 1, não se espera uma correlação direta entre o estresse hídrico e a piora do desempenho preditivo. Isso ocorre porque a avaliação proposta baseia-se em um novo conjunto de dados (menor, em função do recorte temporal associado ao cenário de estresse) bem como em um novo conjunto de períodos de teste, selecionados sem análise prévia dos dados, de modo a evitar viés de escolha.

Assim, os resultados obtidos constituem um novo cenário de análise, no qual os modelos aprendem a partir das dinâmicas específicas desse período, sem influência direta dos intervalos considerados no estudo anterior. Ressalta-se que a única herança mantida entre os estudos de caso refere-se aos hiperparâmetros dos modelos evolutivos, preservados deliberadamente para permitir a avaliação da capacidade de adaptação dos modelos em um contexto reconhecidamente mais desafiador.

Tabela 16 – Métricas de desempenho específicas da bacia de Furnas (média  $\pm$  desvio padrão) para todos os modelos avaliados no Estudo de Caso 2. O melhor valor de cada métrica é destacado em negrito.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	6,02 $\pm$ 2,79	2,18 $\pm$ 5,31	7,60 $\pm$ 3,94	-3,211 $\pm$ 10,532	12,51 $\pm$ 6,83	-
eMG	9,63 $\pm$ 6,55	2,78 $\pm$ 6,03	10,92 $\pm$ 6,91	0,047 $\pm$ 0,981	0,21 $\pm$ 0,14	<b>4,0 <math>\pm</math> 0,0</b>
VS-eMG	<b>4,91 <math>\pm</math> 3,27</b>	<b>0,18 <math>\pm</math> 1,77</b>	<b>6,02 <math>\pm</math> 4,12</b>	<b>0,762 <math>\pm</math> 0,255</b>	1,24 $\pm$ 0,69	8,0 $\pm$ 0,0
VSA-eMG	9,52 $\pm$ 11,31	4,33 $\pm$ 11,50	11,03 $\pm$ 12,76	0,171 $\pm$ 1,508	0,37 $\pm$ 0,17	8,1 $\pm$ 0,4
MVSA-eMG	9,52 $\pm$ 11,31	4,33 $\pm$ 11,50	11,03 $\pm$ 12,76	0,171 $\pm$ 1,508	0,21 $\pm$ 0,05	7,1 $\pm$ 0,4
MVS-eMG	9,53 $\pm$ 11,32	4,34 $\pm$ 11,51	11,04 $\pm$ 12,77	0,170 $\pm$ 1,511	<b>0,18 <math>\pm</math> 0,05</b>	5,1 $\pm$ 0,4

Tabela 17 – Métricas de desempenho específicas da bacia de Itaipu para todos os modelos avaliados no Estudo de Caso 2.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	3,43 $\pm$ 1,25	2,24 $\pm$ 2,82	3,77 $\pm$ 1,29	0,114 $\pm$ 1,170	17,69 $\pm$ 4,13	-
eMG	1,81 $\pm$ 1,81	0,79 $\pm$ 2,03	2,22 $\pm$ 2,34	<b>0,866 <math>\pm</math> 0,140</b>	0,10 $\pm$ 0,04	<b>2,4 <math>\pm</math> 0,5</b>
VS-eMG	2,27 $\pm$ 2,52	0,67 $\pm$ 2,72	2,66 $\pm$ 3,02	0,814 $\pm$ 0,227	0,26 $\pm$ 0,12	5,4 $\pm$ 1,0
VSA-eMG	1,53 $\pm$ 0,95	<b>-0,01 <math>\pm</math> 1,45</b>	1,84 $\pm$ 1,16	0,853 $\pm$ 0,205	0,20 $\pm$ 0,07	3,9 $\pm$ 0,4
MVSA-eMG	<b>1,49 <math>\pm</math> 0,84</b>	-0,04 $\pm$ 1,35	<b>1,82 <math>\pm</math> 1,06</b>	0,841 $\pm$ 0,233	0,11 $\pm$ 0,03	4,0 $\pm$ 0,0
MVS-eMG	2,13 $\pm$ 0,61	1,13 $\pm$ 1,34	2,46 $\pm$ 0,72	0,512 $\pm$ 0,816	<b>0,09 <math>\pm</math> 0,04</b>	4,7 $\pm$ 1,0

Tabela 18 – Métricas de desempenho específicas da bacia de Itumbiara para todos os modelos avaliados no Estudo de Caso 2.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	5,33 $\pm$ 2,52	2,26 $\pm$ 6,09	6,11 $\pm$ 2,92	-0,669 $\pm$ 2,008	17,84 $\pm$ 4,00	-
eMG	2,39 $\pm$ 1,24	<b>0,10 <math>\pm</math> 1,54</b>	3,16 $\pm$ 1,78	0,819 $\pm$ 0,166	0,27 $\pm$ 0,10	<b>4,0 <math>\pm</math> 0,0</b>
VS-eMG	2,38 $\pm$ 1,22	0,13 $\pm$ 1,50	3,14 $\pm$ 1,75	0,819 $\pm$ 0,166	0,42 $\pm$ 0,15	8,0 $\pm$ 0,0
VSA-eMG	2,95 $\pm$ 1,91	0,23 $\pm$ 2,06	3,76 $\pm$ 2,44	0,744 $\pm$ 0,315	0,29 $\pm$ 0,15	8,0 $\pm$ 0,0
MVSA-eMG	2,91 $\pm$ 1,88	0,19 $\pm$ 1,99	3,72 $\pm$ 2,44	0,760 $\pm$ 0,277	0,19 $\pm$ 0,06	8,0 $\pm$ 0,0
MVS-eMG	<b>2,24 <math>\pm</math> 1,25</b>	0,18 $\pm$ 1,23	<b>2,99 <math>\pm</math> 1,80</b>	<b>0,846 <math>\pm</math> 0,163</b>	<b>0,14 <math>\pm</math> 0,03</b>	6,0 $\pm$ 0,0

Tabela 19 – Métricas de desempenho específicas da bacia de São Simão para todos os modelos avaliados no Estudo de Caso 2.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	3,52 $\pm$ 1,11	1,22 $\pm$ 2,22	4,17 $\pm$ 1,52	0,459 $\pm$ 0,679	17,86 $\pm$ 4,03	-
eMG	2,12 $\pm$ 1,40	<b>-0,08 <math>\pm</math> 0,83</b>	2,73 $\pm$ 1,85	0,880 $\pm$ 0,189	0,18 $\pm$ 0,03	<b>4,0 <math>\pm</math> 0,0</b>
VS-eMG	2,38 $\pm$ 1,54	-0,37 $\pm$ 1,52	3,05 $\pm$ 2,09	<b>0,886 <math>\pm</math> 0,146</b>	0,26 $\pm$ 0,14	6,0 $\pm$ 0,0
VSA-eMG	2,48 $\pm$ 1,55	-0,45 $\pm$ 1,98	3,22 $\pm$ 2,16	0,879 $\pm$ 0,131	0,21 $\pm$ 0,09	7,0 $\pm$ 0,0
MVSA-eMG	2,48 $\pm$ 1,55	-0,45 $\pm$ 1,98	3,22 $\pm$ 2,16	0,879 $\pm$ 0,131	0,11 $\pm$ 0,04	7,0 $\pm$ 0,0
MVS-eMG	<b>2,08 <math>\pm</math> 1,43</b>	-0,24 $\pm$ 0,71	<b>2,63 <math>\pm</math> 1,89</b>	0,886 $\pm$ 0,185	<b>0,08 <math>\pm</math> 0,03</b>	5,0 $\pm$ 0,0

A análise dos resultados revela uma heterogeneidade de desempenho entre os modelos considerados, em especial os propostos. Destaca-se a bacia de Furnas, onde foi observado um aumento mais expressivo das métricas de erro em comparação com o Estudo de Caso 1 (por exemplo, o modelo MVS-eMG apresentou MAPE médio de 9,53% frente a 3,35% no estudo anterior). Nessa bacia, todos os modelos evolutivos apresentaram redução da acurácia, com desempenhos relativamente próximos entre si.

Esses resultados reforçam a análise de que a bacia de Furnas constitui um dos casos mais complexos sob o ponto de vista da modelagem hidrológica neste estudo. Esse comportamento pode ser associado às características hidrológicas de Furnas, que apresenta a menor área de drenagem, os menores índices médios de vazão e variações significativas entre os folds de validação, conforme evidenciado no estudo anterior. Apesar do aumento perceptível nos erros, os valores obtidos permanecem dentro de um limiar considerado aceitável (por exemplo, MAPE médio inferior a 10% e valores de NSE positivos), especialmente quando comparados aos erros médios do modelo operacional SMAP/ONS, utilizado como referência no Estudo de Caso 1 (MAPE = 15,14%).

O modelo VS-eMG foi o que apresentou o melhor desempenho na bacia de Furnas, reforçando sua relevância como benchmark na avaliação das arquiteturas propostas. A LSTM também apresentou desempenho satisfatório, alcançando o segundo melhor resultado geral nessa bacia, o que também reforça sua aplicação como benchmark do estado da arte em modelos de estrutura fixa no geral, bem como sua utilização no presente estudo de caso. Para complementar a análise das tabelas, a Figura 14 apresenta as séries temporais das vazões previstas e observadas concatenadas para os sete folds de validação das quatro bacias consideradas neste estudo.

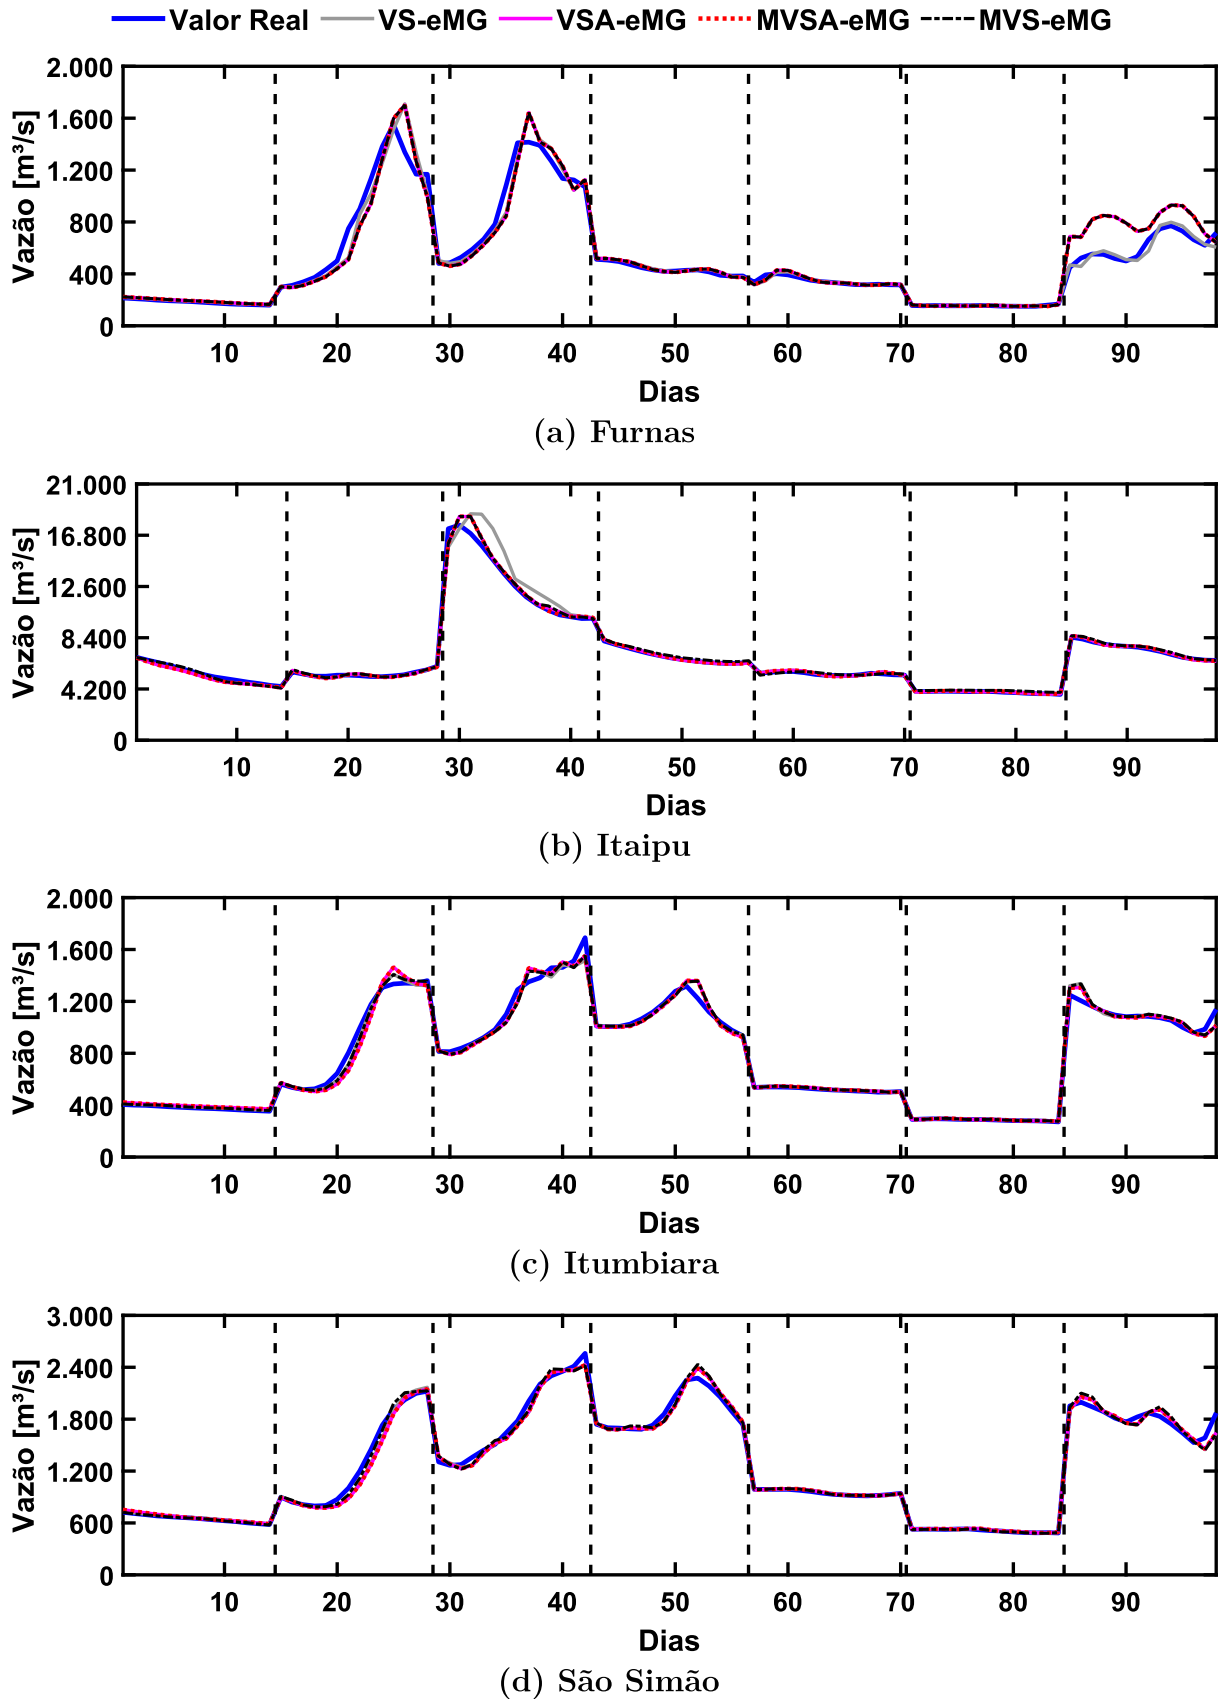


Figura 14 – Séries temporais das vazões previstas e observadas concatenadas para os sete folds de validação. Cada painel mostra a vazão observada (azul) e as previsões dos modelos (identificados na legenda superior) para as bacias de (a) Furnas, (b) Itaipu, (c) Itumbiara e (d) São Simão. As linhas verticais tracejadas indicam a separação temporal entre os folds independentes de validação.

Destaque para o painel (a) da Figura 14, relativo à bacia de Furnas, que mostra que os folds 2, 3 e 7 apresentam variações acentuadas na vazão observada, resultando em menor aderência e, conseqüentemente, em desempenho inferior nesses casos. Apesar dessas dificuldades, os modelos propostos mantiveram índices de erro relativamente baixos, demonstrando robustez mesmo em cenários hidrológicos mais complexos.

Em contrapartida, na bacia de Itaipu, os modelos VSA-eMG e MVSA-eMG apresentaram redução nas métricas de erro em comparação ao estudo anterior. Esse resultado evidencia um desempenho consistente sob estresse, mesmo em um sistema de grande porte, com ganho adicional de acurácia, sem comprometer a eficiência estrutural, mantendo estáveis o número de regras finais e o baixo tempo de execução.

Cabe destacar o desempenho do MVS-eMG, que apresentou as menores médias de MAPE nas bacias de Itumbiara e São Simão. Em suma, o comportamento geral dos modelos propostos, observado na maioria das bacias, foi de um ligeiro incremento nas métricas de erro (em relação ao Estudo de Caso 1), sem comprometer a acurácia média em relação aos benchmarks. Por exemplo, os três modelos propostos superaram a LSTM na grande maioria dos casos (9 em 12).

Ocorreram também casos pontuais em que alguns dos modelos propostos apresentaram desempenho ligeiramente inferior ao dos modelos evolutivos de referência (eMG e VS-eMG). Esse comportamento é esperado em decorrência da mudança do cenário experimental, que induz dinâmicas de adaptação distintas em cada arquitetura, conduzindo o processo evolutivo a trajetórias diferentes no espaço de soluções.

Em cenários reais, onde o retreinamento contínuo a cada mudança climática é inviável, a natureza adaptativa dos modelos propostos se destaca. Ao considerar uma situação de estresse hídrico com baixas vazões, as abordagens propostas mostraram-se robustas, fornecendo previsões acuradas mesmo sem nova otimização. O fato de os resultados manterem consistência em uma base de dados inteiramente nova e mais desafiadora reforça a qualidade da otimização realizada no estudo anterior, ao mesmo tempo em que afasta a hipótese de sobreajuste (overfitting) dos hiperparâmetros a um cenário específico.

### 5.3 ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA

Para corroborar as análises de desempenho apresentadas, aplicou-se o mesmo protocolo de verificação estatística adotado no Estudo de Caso 1. Foram aplicados os testes de Morgan–Granger–Newbold (MGN) e Wilcoxon para determinar a significância das diferenças observadas entre os modelos no cenário de estresse hídrico. A Tabela 20 sumariza os  $p$ -valores obtidos para as comparações pareadas nas quatro bacias.

Tabela 20 – Análise de significância estatística comparativa para o Estudo de Caso 2. Os testes de Morgan–Granger–Newbold (MGN) e *Wilcoxon Signed-Rank* foram aplicados aos resíduos de previsão concatenados dos sete períodos de teste ( $n = 98$  amostras por bacia). A coluna Evidência indica, quando aplicável, o modelo com menor erro médio (MAPE), classificando o resultado como Forte (ambos os testes com  $p < 0,05$ ), Parcial (apenas um teste com  $p < 0,05$ ) ou Sem Evidência (ambos os testes com  $p \geq 0,05$ ). Valores em negrito nos  $p$ -valores denotam rejeição da hipótese nula.

Modelo 1 vs. Modelo 2	MGN $p$ -valor	Wilcoxon $p$ -valor	Evidência (Melhor Modelo)
<b>Bacia: Furnas</b>			
VSA-eMG vs. LSTM	< <b>0,001</b>	0,100	Parcial (LSTM)
MVSA-eMG vs. LSTM	< <b>0,001</b>	0,103	Parcial (LSTM)
MVS-eMG vs. LSTM	< <b>0,001</b>	0,100	Parcial (LSTM)
VSA-eMG vs. eMG	0,353	<b>0,005</b>	Parcial (VSA-eMG)
MVSA-eMG vs. eMG	0,353	<b>0,005</b>	Parcial (MVSA-eMG)
MVS-eMG vs. eMG	0,355	<b>0,005</b>	Parcial (MVS-eMG)
VSA-eMG vs. VS-eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (VS-eMG)
MVSA-eMG vs. VS-eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (VS-eMG)
MVS-eMG vs. VS-eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (VS-eMG)
MVSA-eMG vs. VSA-eMG	0,538	0,150	Sem Evidência
MVS-eMG vs. VSA-eMG	< <b>0,001</b>	0,115	Parcial (VSA-eMG)
MVS-eMG vs. MVSA-eMG	<b>0,001</b>	0,247	Parcial (MVSA-eMG)
<b>Bacia: Itaipu</b>			
VSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	< <b>0,001</b>	0,532	Parcial (VSA-eMG)
MVSA-eMG vs. eMG	< <b>0,001</b>	0,473	Parcial (MVSA-eMG)
MVS-eMG vs. eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (eMG)
VSA-eMG vs. VS-eMG	< <b>0,001</b>	0,084	Parcial (VSA-eMG)
MVSA-eMG vs. VS-eMG	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. VS-eMG	< <b>0,001</b>	0,095	Parcial (MVS-eMG)
MVSA-eMG vs. VSA-eMG	0,397	0,543	Sem Evidência
MVS-eMG vs. VSA-eMG	0,928	< <b>0,001</b>	Parcial (VSA-eMG)
MVS-eMG vs. MVSA-eMG	0,840	< <b>0,001</b>	Parcial (MVSA-eMG)
<b>Bacia: Itumbiara</b>			
VSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	<b>0,038</b>	<b>0,031</b>	Forte (eMG)
MVSA-eMG vs. eMG	<b>0,038</b>	<b>0,029</b>	Forte (eMG)
MVS-eMG vs. eMG	< <b>0,001</b>	<b>0,047</b>	Forte (MVS-eMG)
VSA-eMG vs. VS-eMG	<b>0,007</b>	<b>0,023</b>	Forte (VS-eMG)
MVSA-eMG vs. VS-eMG	<b>0,007</b>	<b>0,024</b>	Forte (VS-eMG)

Continua na próxima página.

Tabela 20 – Resultados estatísticos para o Estudo de Caso 2 (continuação).

<b>Modelo 1 vs. Modelo 2</b>	<b>MGN <i>p</i>-valor</b>	<b>Wilcoxon <i>p</i>-valor</b>	<b>Evidência (Melhor Modelo)</b>
MVS-eMG vs. VS-eMG	<b>0,011</b>	<b>0,038</b>	Forte (MVS-eMG)
MVSA-eMG vs. VSA-eMG	0,688	0,473	Sem Evidência
MVS-eMG vs. VSA-eMG	<b>&lt; 0,001</b>	<b>&lt; 0,001</b>	Forte (MVS-eMG)
MVS-eMG vs. MVSA-eMG	<b>&lt; 0,001</b>	<b>&lt; 0,001</b>	Forte (MVS-eMG)
<b>Bacia: São Simão</b>			
VSA-eMG vs. LSTM	<b>0,034</b>	<b>&lt; 0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	<b>0,034</b>	<b>&lt; 0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	<b>0,008</b>	<b>&lt; 0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	0,719	0,198	Sem Evidência
MVSA-eMG vs. eMG	0,719	0,198	Sem Evidência
MVS-eMG vs. eMG	<b>0,011</b>	0,367	Parcial (MVS-eMG)
VSA-eMG vs. VS-eMG	0,406	0,685	Sem Evidência
MVSA-eMG vs. VS-eMG	0,406	0,685	Sem Evidência
MVS-eMG vs. VS-eMG	0,397	0,133	Sem Evidência
MVSA-eMG vs. VSA-eMG	1,000	1,000	Sem Evidência
MVS-eMG vs. VSA-eMG	0,331	0,130	Sem Evidência
MVS-eMG vs. MVSA-eMG	0,331	0,130	Sem Evidência

A análise da Tabela 20 revela resultados mais heterogêneos quanto à significância estatística das comparações, refletindo o maior nível de dificuldade imposto pelo cenário de estresse hídrico. Um caso ilustrativo ocorre na bacia de Furnas, onde as comparações entre os modelos propostos e a LSTM resultaram predominantemente em evidência parcial, com indicação de menor erro médio para o modelo de benchmark segundo o teste MGN, embora sem confirmação consistente pelo teste de Wilcoxon.

Situações de competitividade dos benchmarks também foram observadas pontualmente em comparações envolvendo o VS-eMG. Ainda assim, considerando o conjunto das bacias, observa-se uma quantidade substancial de resultados com evidência estatística (forte ou parcial) favorável aos modelos propostos, com destaque para a consistência do MVS-eMG, em concordância com as métricas de erro apresentadas na seção anterior.

Ressalta-se, portanto, que a significância estatística complementa a análise das métricas de desempenho, permitindo explorar o comportamento dos modelos sob condições consideravelmente mais exigentes. Neste cenário, este estudo confirmou o funcionamento e a estabilidade dos modelos propostos sob mudanças severas no regime, evidenciando sua capacidade de adaptação em condições adversas, mesmo na ausência de reotimização. Esses resultados reforçam a relevância de abordagens adaptativas em cenários reais, nos quais a dinâmica do sistema pode se alterar de forma abrupta e imprevisível.

## 6 ESTUDO DE CASO 3: GENERALIZAÇÃO ESPACIAL E ADAPTAÇÃO A REGIMES HIDROLÓGICOS DISTINTOS

Enquanto o Estudo de Caso 1 teve como objetivo avaliar o desempenho preditivo dos modelos sob condições hidrológicas representativas na Região Hidrográfica do Paraná, e o Estudo de Caso 2 investigou a robustez em um cenário de estresse hídrico, o Estudo de Caso 3 é dedicado à análise da capacidade de generalização espacial dos modelos propostos quando aplicados a bacias com características geográficas e climáticas distintas daquelas consideradas no processo de otimização inicial dos modelos.

A análise considera duas bacias estratégicas para o Sistema Interligado Nacional, nas duas regiões hidrográficas complementares apresentadas na Seção **3.5.2**: Três Marias, na Região Hidrográfica do São Francisco, e Tucuruí, na Região Hidrográfica do Tocantins–Araguaia, assegurando diversidade hidrológica no contexto da geração hidrelétrica brasileira. O período avaliado é o mesmo intervalo de longo prazo utilizado no Estudo de Caso 1 (2011–2019), permitindo uma análise robusta sob diferentes padrões sazonais.

Esta análise permite investigar se a configuração ajustada para a RH do Paraná é suficientemente robusta para generalizar para regimes hidrológicos distintos, como os observados nas bacias do São Francisco e do Tocantins–Araguaia, associadas predominantemente aos climas tropical de savana (Aw) e tropical de monção (Am), respectivamente, sem a necessidade de recalibração específica.

Essa estratégia reflete cenários operacionais reais, nos quais a reotimização de modelos para cada nova bacia pode ser inviável ou custosa, sendo preferencial a adoção de mecanismos de adaptação que não dependam de recalibração frequente.

### 6.1 CENÁRIO EXPERIMENTAL

Os dados utilizados neste estudo compreendem as séries históricas das bacias de Três Marias e Tucuruí, seguindo a mesma estrutura de base de dados descrita na Seção **3.6.1**. O período considerado corresponde ao intervalo de 01 de janeiro de 2011 a 31 de dezembro de 2019, garantindo a mesma janela temporal adotada no Estudo de Caso 1.

Os períodos que compreendem os folds do processo de validação cruzada são mantidos inalterados. O esquema de validação empregado é o mesmo previamente apresentado, descrito na Seção **3.6.3** e ilustrado na Figura 8. As séries temporais completas para cada bacia são apresentadas na Figura 15.

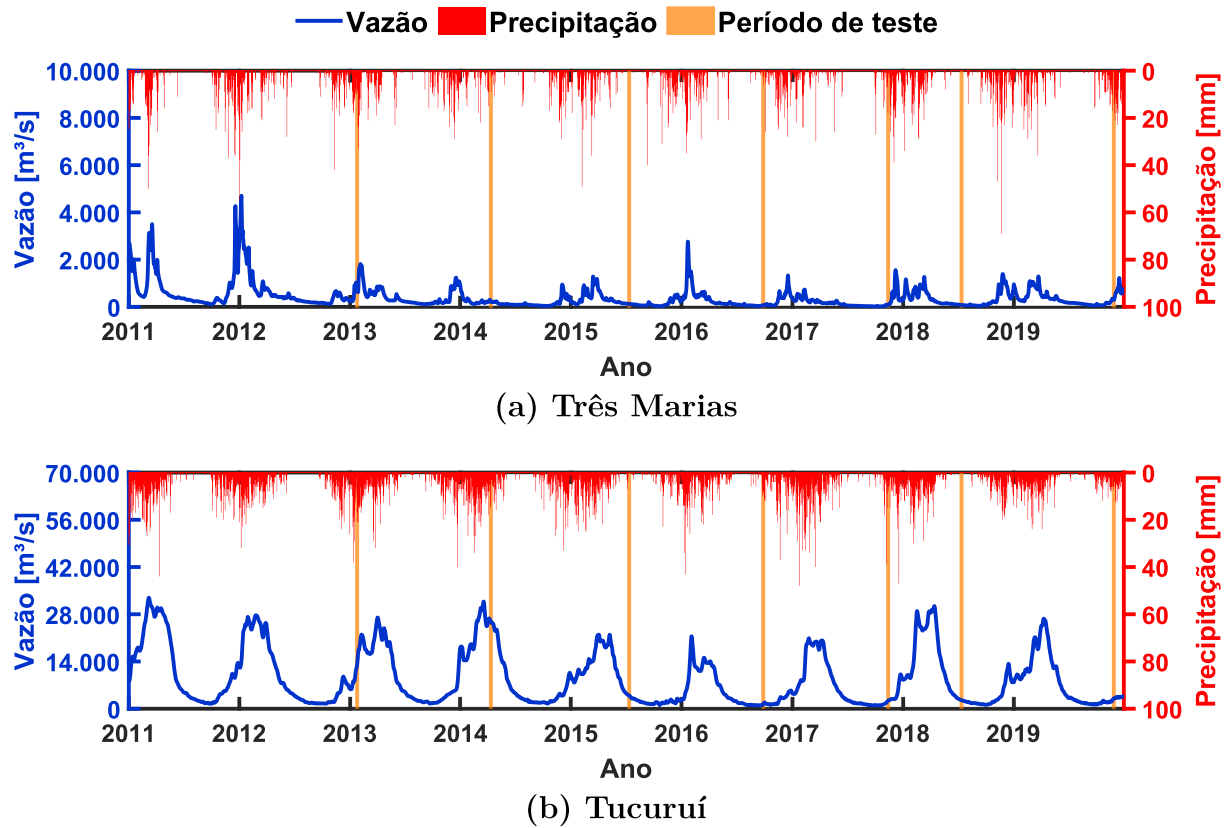


Figura 15 – Séries temporais diárias de vazão (linha azul) e precipitação (barras vermelhas) nas bacias de (a) Três Marias e (b) Tucuruí no período de 2011–2019. As faixas verticais (laranja) indicam os sete períodos de teste de 14 dias utilizados para a validação dos modelos.

A Tabela 21 apresenta as estatísticas descritivas básicas das séries de vazão utilizadas no Estudo de Caso 3, no período de 2011 a 2019, para as duas bacias complementares analisadas. Observa-se uma diferença expressiva de magnitude entre as séries de vazão das duas bacias analisadas. Essas discrepâncias reforçam o desafio imposto aos modelos no contexto de generalização espacial, uma vez que envolvem não apenas diferenças de regime hidrológico, mas também de escala.

Tabela 21 – Estatísticas descritivas das séries de vazão ( $\text{m}^3/\text{s}$ ) e precipitação (mm) das bacias de generalização no período de 2011–2019, incluindo mínimo, máximo e média  $\pm$  desvio padrão.

Bacia	Variável	Mínimo	Máximo	Média
Três Marias	Vazão	21	4707	$395,8 \pm 492,3$
	Precipitação	0	69	$2,9 \pm 6,0$
Tucuruí	Vazão	949	32906	$8985,4 \pm 8356,3$
	Precipitação	0	48	$4,3 \pm 5,8$

### 6.1.1 Configuração dos Modelos de Previsão

A configuração experimental segue integralmente o protocolo definido no Estudo de Caso 1, não sendo realizada qualquer etapa adicional de reotimização. Foram aplicados os três modelos propostos (VSA-eMG, MVSA-eMG e MVS-eMG), bem como os modelos de referência (eMG e VS-eMG), cujos hiperparâmetros correspondem exatamente àqueles definidos no Estudo de Caso 1 (Tabela 8).

Além dos cinco modelos evolutivos, também é avaliado o desempenho da rede LSTM, de modo análogo à utilização proposta no estudo anterior. O treinamento foi realizado exclusivamente com os dados das bacias consideradas no presente estudo de caso, sem a utilização de informações provenientes dos estudos anteriores, permitindo uma comparação direta sob o mesmo cenário experimental.

O modelo SMAP/ONS não foi considerado no Estudo de Caso 3 por incompatibilidade metodológica com o objetivo de avaliar a generalização espacial sem recalibração. Diferentemente dos modelos orientados a dados, o SMAP/ONS depende de parâmetros físicos específicos de cada bacia, exigindo calibração local para sua aplicação, o que inviabilizaria uma comparação metodologicamente consistente com os modelos avaliados. Além disso, o modelo FIG-FTS também não foi incluído nesta análise, uma vez que apresentou desempenho consistentemente inferior nos estudos anteriores, o que limita sua relevância no contexto específico de avaliação da capacidade de generalização espacial.

## 6.2 ANÁLISE INTEGRADA DE DESEMPENHO E GENERALIZAÇÃO ESPACIAL

Os resultados obtidos no Estudo de Caso 3 permitem avaliar os modelos propostos sob dois aspectos de grande relevância para a previsão hidrológica: a capacidade de generalização espacial e a adaptação a regimes hidrológicos distintos. De forma análoga ao estudo anterior, a análise concentra-se na investigação do comportamento dos modelos de maneira individualizada por bacia, em cenários inéditos e geograficamente distantes daqueles nos quais foi realizada a etapa de otimização dos hiperparâmetros. Nesse contexto, os resultados das simulações conduzidas nas duas bacias de generalização consideradas são apresentados nas Tabelas 22 e 23.

Tabela 22 – Métricas de desempenho específicas da bacia de Três Marias (média  $\pm$  desvio padrão) para todos os modelos avaliados no Estudo de Caso 3. O melhor valor de cada métrica é destacado em negrito.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	12,82 $\pm$ 4,16	4,09 $\pm$ 13,11	13,97 $\pm$ 4,25	-0,723 $\pm$ 2,108	22,11 $\pm$ 14,71	-
eMG	5,34 $\pm$ 3,91	1,11 $\pm$ 1,27	6,23 $\pm$ 4,69	0,803 $\pm$ 0,232	0,65 $\pm$ 0,14	<b>3,9 <math>\pm</math> 0,4</b>
VS-eMG	6,20 $\pm$ 5,11	3,23 $\pm$ 3,80	7,27 $\pm$ 5,87	0,620 $\pm$ 0,534	1,72 $\pm$ 0,65	4,0 $\pm$ 0,6
VSA-eMG	<b>4,83 <math>\pm</math> 3,05</b>	0,53 $\pm$ 1,11	<b>5,79 <math>\pm</math> 3,80</b>	<b>0,832 <math>\pm</math> 0,157</b>	0,81 $\pm$ 0,17	8,4 $\pm$ 0,5
MVSA-eMG	5,30 $\pm$ 3,70	<b>0,12 <math>\pm</math> 1,84</b>	6,16 $\pm$ 4,39	0,803 $\pm$ 0,204	0,69 $\pm$ 0,25	8,9 $\pm$ 0,4
MVS-eMG	8,26 $\pm$ 11,42	4,62 $\pm$ 8,18	11,00 $\pm$ 16,29	0,027 $\pm$ 2,281	<b>0,42 <math>\pm</math> 0,13</b>	6,4 $\pm$ 0,8

Tabela 23 – Métricas de desempenho específicas da bacia de Tucuruí para todos os modelos avaliados no Estudo de Caso 3.

Modelo	MAPE [%]	PBIAS [%]	RMSPE [%]	NSE	Tempo [s]	Regras Finais
LSTM	7,60 ± 4,50	6,12 ± 5,54	8,51 ± 5,13	-0,641 ± 3,156	43,13 ± 24,19	-
eMG	3,20 ± 3,82	-1,47 ± 4,70	3,76 ± 4,39	0,809 ± 0,255	0,41 ± 0,13	3,1 ± 0,4
VS-eMG	1,91 ± 1,50	-0,39 ± 0,94	2,30 ± 1,85	0,821 ± 0,340	0,99 ± 0,38	3,6 ± 0,5
VSA-eMG	2,20 ± 1,66	<b>0,37 ± 1,22</b>	2,57 ± 1,88	0,872 ± 0,202	0,34 ± 0,07	3,4 ± 1,0
MVSA-eMG	1,89 ± 1,47	-0,93 ± 1,61	2,38 ± 1,92	<b>0,899 ± 0,175</b>	0,30 ± 0,09	4,9 ± 0,4
MVS-eMG	<b>1,85 ± 1,19</b>	0,44 ± 1,31	<b>2,21 ± 1,46</b>	0,818 ± 0,321	<b>0,23 ± 0,11</b>	<b>3,0 ± 1,4</b>

De maneira geral, os modelos propostos apresentaram desempenho consistente nas bacias de generalização avaliadas. Dos seis cenários analisados (três modelos aplicados a duas bacias), cinco registraram valores médios de NSE superiores a 0,80, indicando uma promissora capacidade de generalização espacial. Adicionalmente, observou-se a manutenção dos patamares de tempo médio de execução e do número final de regras em relação aos estudos anteriores, evidenciando que a eficácia preditiva foi alcançada sem incremento significativo de custo computacional ou complexidade estrutural.

A bacia de Três Marias, caracterizada por menores valores médios de vazão e pela menor área de drenagem entre as bacias consideradas neste estudo, mostrou-se a mais desafiadora entre os cenários de generalização avaliados. Para essa bacia, o modelo VSA-eMG apresentou o melhor desempenho geral, registrando os menores valores médios de MAPE (4,83%), bem como o maior valor médio de NSE (0,832). O modelo MVSA-eMG também se destacou ao apresentar desempenho competitivo, alcançando o segundo menor MAPE (5,30%) e um viés percentual próximo de zero (0,12%).

Em contrapartida, o modelo MVS-eMG apresentou desempenho inferior (MAPE de 8,26%), bem como elevada variabilidade entre os folds, apesar de manter o menor tempo médio de execução. Entre os modelos de referência, a rede LSTM registrou o pior desempenho geral para essa bacia (NSE = -0,723), além do maior tempo médio. Esse resultado, mesmo não tendo quaisquer influências de outras bacias, sugere limitações do modelo de estrutura fixa em gerar previsões acuradas sem uma otimização específica para a bacia em questão. Ainda assim, os modelos evolutivos, de maneira geral, apresentaram desempenho competitivo e capacidade de generalização, com destaque para a consistência do eMG original.

Para complementar a análise das tabelas, a Figura 16 apresenta as séries temporais das vazões previstas e observadas concatenadas para os sete folds de validação. O painel (a), relativo à bacia de Três Marias, evidencia que o primeiro fold foi marcado por variação brusca na vazão observada, refletindo maior dificuldade preditiva e menor aderência das previsões, especialmente o MVS-eMG. Apesar dessa instabilidade inicial, observa-se elevada aderência das curvas previstas nos folds subsequentes, indicando que os modelos evolutivos capturaram adequadamente a dinâmica do processo.

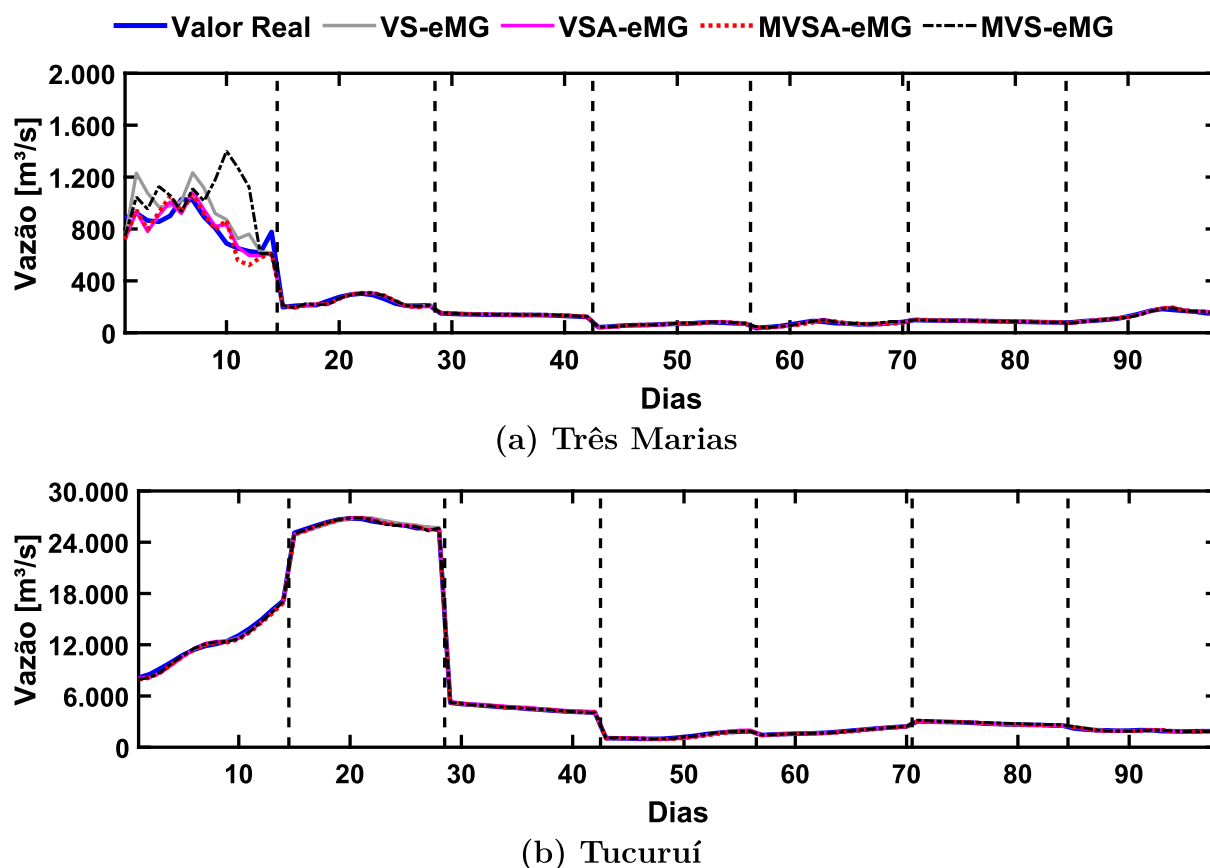


Figura 16 – Séries temporais das vazões previstas e observadas concatenadas para os sete folds de validação. Cada painel mostra a vazão observada (azul) e as previsões dos modelos (identificados na legenda superior) para as bacias de (a) Três Marias e (b) Tucuruí. As linhas verticais tracejadas indicam a separação temporal entre os períodos independentes de validação.

Na bacia de Tucuruí, que contrasta significativamente com a de Três Marias por representar um sistema de grande magnitude hidrológica, observou-se um comportamento mais estável dos modelos avaliados. De forma geral, os três modelos propostos apresentaram desempenho consistente, com baixos níveis de erro e viés, além da manutenção de tempos médios de execução reduzidos e baixo número médio de regras finais, evidenciando elevada parcimônia estrutural mesmo em um regime hidrológico distinto.

Nesse cenário, o modelo MVS-eMG apresentou o melhor desempenho global, registrando quatro das seis melhores métricas avaliadas. Destaca-se, em particular, o fato de esse modelo ter alcançado um número médio de regras finais (3,0) inferior ao do eMG original (3,1), resultado que não havia sido observado nos estudos anteriores, demonstrando não apenas parcimônia, mas também a possibilidade de redução efetiva do indicador de complexidade estrutural. Os modelos MVSA-eMG e VSA-eMG também apresentaram desempenho competitivo, com destaque para o MVSA-eMG, que obteve o maior valor médio de NSE (0,899). Entre os modelos de referência, a rede LSTM novamente não figurou entre os melhores desempenhos, assim como o eMG original.

De maneira geral, os modelos evolutivos demonstraram capacidade consistente de generalização espacial nas duas bacias analisadas, com maior MAPE médio de 8,26%. Esses resultados reforçam a aplicabilidade dos modelos propostos, em especial VSA-eMG, MVSA-eMG e MVS-eMG, para cenários geograficamente distintos daqueles utilizados na otimização inicial. O desempenho observado evidencia a eficácia do aprendizado online e a adaptação a diferentes regimes hidrológicos, destacando a robustez estrutural e a parcimônia dos modelos, sem aumento significativo do custo computacional.

### 6.3 ANÁLISE DE SIGNIFICÂNCIA ESTATÍSTICA

Para avaliar a significância estatística das diferenças de desempenho entre os modelos de previsão empregados no Estudo de Caso 3, aplicou-se o mesmo protocolo adotado nos Estudos de Caso 1 e 2, onde foram utilizados os testes de Morgan–Granger–Newbold (MGN) e Wilcoxon. A Tabela 24 apresenta os  $p$ -valores obtidos para as comparações pareadas nas duas bacias de generalização espacial.

Os resultados estatísticos presentes na Tabela 24 apresentam uma dinâmica similar aos observados no Estudo de Caso 2. Considerando a heterogeneidade dos resultados de desempenho, os testes estatísticos novamente atuam como ferramenta complementar de avaliação de desempenho, e não como identificador isolado de um modelo ótimo global.

Para as comparações com a rede LSTM, verificou-se evidência estatística favorável aos modelos propostos em praticamente todos os cenários, com destaque para o MVS-eMG, que apresentou evidência forte ou parcial em 100% dos casos, refletindo sua robustez preditiva. Nos testes envolvendo o modelo eMG, os resultados indicam competitividade mais variada: algumas comparações apontam vantagem para os modelos evolutivos propostos, enquanto outras mostram evidência parcial ou ausência de evidência, refletindo o desempenho específico em cada bacia.

As comparações com o VS-eMG revelam nuances semelhantes, com predominância de evidência parcial a favor dos modelos propostos e dois casos sem evidência, reforçando diferenças sutis nos desempenhos em cada cenário. De modo geral, os modelos MVS-eMG e VSA-eMG se destacam por maior consistência e capacidade de generalização nos cenários avaliados, seguidos pelo MVSA-eMG, que mantém desempenho competitivo, porém com menor predominância estatística.

A análise indica que, mesmo em bacias de generalização com características muito divergentes e distâncias geográficas significativas, os modelos propostos mantêm robustez e consistência, apresentando baixos índices de erro e significância estatística sobre seus concorrentes na maioria dos casos, configurando-se como ferramentas promissoras para previsão em cenários hidrológicos diversos, mesmo sem reotimização local.

Tabela 24 – Análise de significância estatística comparativa para o Estudo de Caso 3. Os testes de Morgan–Granger–Newbold (MGN) e *Wilcoxon Signed-Rank* foram aplicados aos resíduos de previsão concatenados dos sete períodos de teste ( $n = 98$  amostras por bacia). A coluna Evidência indica, quando aplicável, o modelo com menor erro médio (MAPE), classificando o resultado como Forte (ambos os testes com  $p < 0,05$ ), Parcial (apenas um teste com  $p < 0,05$ ) ou Sem Evidência (ambos os testes com  $p \geq 0,05$ ). Valores em negrito nos  $p$ -valores denotam rejeição da hipótese nula.

Modelo 1 vs. Modelo 2	MGN $p$ -valor	Wilcoxon $p$ -valor	Evidência (Melhor Modelo)
<b>Bacia: Três Marias</b>			
VSA-eMG vs. LSTM	0,531	< <b>0,001</b>	Parcial (VSA-eMG)
MVSA-eMG vs. LSTM	0,520	< <b>0,001</b>	Parcial (MVSA-eMG)
MVS-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	<b>0,039</b>	0,654	Parcial (VSA-eMG)
MVSA-eMG vs. eMG	0,579	0,920	Sem Evidência
MVS-eMG vs. eMG	< <b>0,001</b>	0,693	Parcial (eMG)
VSA-eMG vs. VS-eMG	< <b>0,001</b>	0,070	Parcial (VSA-eMG)
MVSA-eMG vs. VS-eMG	< <b>0,001</b>	0,400	Parcial (MVSA-eMG)
MVS-eMG vs. VS-eMG	< <b>0,001</b>	0,060	Parcial (VS-eMG)
MVSA-eMG vs. VSA-eMG	<b>0,003</b>	0,495	Parcial (VSA-eMG)
MVS-eMG vs. VSA-eMG	< <b>0,001</b>	0,770	Parcial (VSA-eMG)
MVS-eMG vs. MVSA-eMG	< <b>0,001</b>	0,473	Parcial (MVSA-eMG)
<b>Bacia: Tucuruí</b>			
VSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (VSA-eMG)
MVSA-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVSA-eMG)
MVS-eMG vs. LSTM	< <b>0,001</b>	< <b>0,001</b>	Forte (MVS-eMG)
VSA-eMG vs. eMG	< <b>0,001</b>	<b>0,033</b>	Forte (VSA-eMG)
MVSA-eMG vs. eMG	< <b>0,001</b>	<b>0,004</b>	Forte (MVSA-eMG)
MVS-eMG vs. eMG	< <b>0,001</b>	0,072	Parcial (MVS-eMG)
VSA-eMG vs. VS-eMG	0,714	0,375	Sem Evidência
MVSA-eMG vs. VS-eMG	0,197	0,298	Sem Evidência
MVS-eMG vs. VS-eMG	<b>0,021</b>	0,193	Parcial (MVS-eMG)
MVSA-eMG vs. VSA-eMG	0,305	0,128	Sem Evidência
MVS-eMG vs. VSA-eMG	<b>0,008</b>	<b>0,035</b>	Forte (MVS-eMG)
MVS-eMG vs. MVSA-eMG	<b>0,037</b>	0,759	Parcial (MVS-eMG)

## 7 DISCUSSÃO INTEGRADA E LIMITAÇÕES

A concepção dos três estudos de caso apresentados teve como premissa fundamental a avaliação da robustez dos modelos sob um espectro diversificado de condições hidrológicas, com o objetivo de examinar a consistência do desempenho preditivo em cenários progressivamente mais desafiadores.

Nesse contexto, destaca-se a elevada heterogeneidade dos cenários de teste considerados, contemplando: (a) dispersão geográfica, com seis bacias hidrográficas situadas em três regiões hidrográficas distintas; (b) heterogeneidade estrutural, com diferenças expressivas entre as bacias em termos de escala física e capacidade instalada na respectiva usina, variando desde sistemas de menor porte, como Furnas e Três Marias, até bacias de grande porte, como Itaipu e Tucuruí; (c) variabilidade temporal, contrapondo longas séries históricas representativas a períodos caracterizados por estresse hídrico agudo; e (d) diversidade dinâmica dos regimes hidrológicos, abrangendo períodos de cheia, seca e transição ao longo de mais de uma década de dados hidrológicos.

Embora a seleção dos períodos de teste tenha sido conduzida sem análise prévia dos dados em todos os estudos, com o intuito de evitar vieses de escolha, os folds obtidos mostraram-se representativos e caracterizados por variações bem definidas entre os diferentes regimes hidrológicos (cheia, seca e transição). Destacam-se, em particular, as transições abruptas em curtos intervalos de tempo, que impuseram desafios significativos a todos os modelos de previsão avaliados, aumentando o rigor da avaliação e exigindo elevada capacidade de adaptação aliada à estabilidade preditiva.

É importante ressaltar que, embora o protocolo experimental proposto tenha sido concebido para ser o mais abrangente possível, as combinações potenciais entre bacias, regiões hidrográficas, recortes temporais e configurações estruturais das simulações (tais como número de folds, lags de entrada, horizontes de previsão e parâmetros de otimização) são, em essência, ilimitadas. Assim, buscou-se definir um protocolo experimental representativo, metodologicamente consistente e devidamente fundamentado na literatura especializada, de modo a sustentar a relevância e a robustez das análises realizadas no contexto da previsão de vazão de curto prazo em bacias integrantes do SIN.

A eficácia dos mecanismos adaptativos introduzidos é confirmada pela melhoria significativa no desempenho em relação ao eMG original na expressiva maioria dos cenários testados. O modelo MVS-eMG destaca-se por empregar uma estratégia de adaptação altamente responsiva ao erro: o mecanismo MVS promove um incremento acentuado no nível de significância ( $\lambda$ ) quando o erro de previsão na  $k$ -ésima amostra supera o limiar de sensibilidade ( $\bar{\gamma}$ ), e redefine  $\lambda$  imediatamente para seu limite inferior (zero) em situações de erro reduzido. Essa dinâmica permite que o modelo apresente alta responsividade em cenários instáveis, ao mesmo tempo em que maximiza a estabilidade preditiva em regimes

estacionários, minimizando o esforço computacional.

Esse comportamento revelou-se profícuo, resultando nos menores índices de erro na maioria dos cenários propostos. A análise integrada dos três estudos de caso demonstra que essa estratégia produziu resultados consistentes (baixo erro e baixo viés), com desempenho maximizado particularmente nos períodos de comportamento estacionário ou próximos a estacionários (isto é, regimes representativos).

Contudo, diante de cenários de grandes variações em bacias menores (como observado em Furnas e Três Marias), o modelo enfrentou maiores dificuldades (comportamento também observado, de modo geral, nos demais modelos), apresentando menor acurácia na previsão nesses casos (folds) específicos. Ainda assim, o MVS-eMG manteve métricas de desempenho em patamares operacionalmente robustos ( $MAPE < 10\%$ ) e apresentou resiliência ao adaptar sua estrutura e melhorar a previsão nos folds subsequentes.

Adicionalmente, um benefício notável desta abordagem foi o ganho em velocidade de processamento, refletido nos menores tempos médios de execução entre todas as abordagens, inclusive em relação ao eMG original. Este resultado endereça o clássico trade-off dos modelos evolutivos entre complexidade estrutural e acurácia preditiva. Ao regular a evolução com base no erro, o MVS-eMG otimizou a trajetória de aprendizado: o modelo evitou atualizações estruturais desnecessárias em momentos de estabilidade, convergindo para uma estrutura final mais ajustada aos dados (parcimônia) e reduzindo o custo computacional associado à gestão de regras redundantes.

Os modelos VSA-eMG e MVSA-eMG, por sua vez, compartilham características quanto à forma de atualização do nível de significância, baseada em acréscimos graduais quando o erro de previsão na  $k$ -ésima amostra supera o limiar estabelecido. Esses mecanismos aumentam a plasticidade dos modelos em situações em que o erro é maior que o limiar preestabelecido.

No entanto, os modelos apresentam comportamentos distintos quando esse erro é reduzido: enquanto o VSA-eMG promove um decréscimo gradual de  $\lambda$ , restringindo progressivamente a criação de novas regras, o MVSA-eMG redefine  $\lambda$  diretamente para zero, impondo uma contenção mais imediata da evolução estrutural. Estas duas abordagens tornam os modelos mais parcimoniosos na questão do ajuste estrutural, cada um segundo sua dinâmica específica.

Em termos de desempenho, os resultados de ambos os modelos mostraram-se competitivos entre si na maioria dos cenários, figurando consistentemente entre os melhores preditores. O MVSA-eMG destacou-se na análise global do Estudo de Caso 1, apresentando o segundo melhor desempenho agregado, o que sugere uma vantagem em regimes mais regulares. Por outro lado, no Estudo de Caso 3, o VSA-eMG obteve o melhor desempenho individual na bacia de Três Marias (identificada como uma das mais desafiadoras do estudo), evidenciando sua robustez e capacidade de generalização espacial.

Devido à natureza mais suave e gradual do ajuste adotado por ambos os modelos, seu desempenho tende a ser favorecido em situações mais complexas (como observado nos casos de Itaipu e Três Marias), ao possibilitar adaptações mais sutis e diferentes trajetórias de aprendizado. Por outro lado, essa mesma característica reflete-se em maiores tempos médios de execução e em um número médio de regras finais mais elevado. Ainda assim, ambos os modelos superaram consistentemente o eMG original na maioria dos cenários avaliados, evidenciando um aspecto distinto do trade-off entre complexidade estrutural e ganho preditivo.

Os três modelos propostos (VSA-eMG, MVSA-eMG e MVS-eMG) foram submetidos de maneira sistemática ao protocolo experimental estabelecido e validados nos três estudos de caso. Em todos os cenários, apresentaram desempenho consistente e robusto, evidenciando a eficácia de seus mecanismos adaptativos. Esses resultados indicam que a capacidade aprimorada de generalização dos modelos decorre de seu design adaptativo, que equilibra, cada um à sua maneira, estabilidade preditiva e ajuste estrutural durante mudanças de regime. Assim, os modelos demonstram resultados promissores para a tarefa de previsão de vazão de curto prazo em bacias integrantes do SIN.

Nesse contexto, os ganhos de acurácia observados reforçam o potencial impacto prático dos modelos propostos. Conforme discutido na literatura, melhorias no desempenho preditivo estão diretamente associadas à redução de custos operacionais e à maior eficiência na alocação de recursos hídricos, indicando que os avanços apresentados neste trabalho têm potencial para contribuir para decisões mais econômicas no planejamento energético nacional.

Entre as principais limitações dos modelos propostos, destacam-se a quantidade de hiperparâmetros (tais como  $\alpha$ ,  $\lambda$ ,  $\bar{\gamma}$  e  $\beta$ ) e a sensibilidade às suas configurações iniciais. Na literatura de modelos evolutivos, os hiperparâmetros são frequentemente definidos de forma empírica ou baseados em experiência prévia. Para mitigar essa dependência e evitar escolhas arbitrárias, este trabalho empregou um processo de otimização via busca em grade, tomando como referências valores utilizados na literatura. Vale ressaltar que esse esforço de calibração é exigido, tipicamente, apenas uma vez na fase de implantação do modelo em uma nova bacia. A partir daí, o mecanismo evolutivo interno gerencia a adaptação estrutural subsequente.

Outro desafio inerente aos sistemas evolutivos online é a ausência de um controle rígido sobre o crescimento da estrutura. Em cenários de alto ruído ou dados atípicos, os modelos correm o risco de criar regras excessivas (overfitting) ou seguirem trajetórias de aprendizado subótimas. Os mecanismos de adaptação de hiperparâmetros utilizados nos modelos propostos, colaboram para evitar esses cenários através de ajuste com base no erro. Ainda assim, situações extremas podem levar a aumento excessivo da complexidade ou a desvios na trajetória de aprendizado.

A estabilidade frente a mudanças abruptas de regime é uma preocupação constante em sistemas de previsão. O Estudo de Caso 2 avaliou essa limitação ao submeter os modelos a um período de estresse hídrico (2019–2021). Os resultados mostraram que, embora os modelos propostos mantenham a viabilidade operacional, o desempenho pode sofrer degradações pontuais em bacias menores e mais voláteis (como observado em Furnas), indicando que, mesmo com mecanismos adaptativos, o desempenho permanece sensível a cenários hidrológicos extremos.

Em contrapartida, os modelos propostos demonstraram boa capacidade de adaptação em bacias de grande porte (por exemplo, Itaipu), onde os erros permaneceram substancialmente baixos. Sob a perspectiva do planejamento energético, esse comportamento é particularmente relevante, pois um mesmo erro percentual em usinas de grande porte representa volumes absolutos significativamente maiores e, portanto, maior impacto potencial sobre a operação do sistema do que em bacias de menor escala.

A capacidade de generalização espacial também representa um fator importante. O Estudo de Caso 3 foi desenhado especificamente para investigar esse aspecto, testando se hiperparâmetros otimizados para uma região hidrográfica (Paraná) seriam eficazes em outras regiões hidrográficas com características distintas (São Francisco e Tocantins–Araguaia). Embora os resultados tenham confirmado robustez satisfatória nas bacias de generalização, é importante pontuar que essa transferibilidade não é irrestrita. Bacias com regimes hidrológicos e/ou características geográficas radicalmente distintos podem exigir, inevitavelmente, uma recalibração dos hiperparâmetros iniciais para assegurar desempenho adequado.

Finalmente, a viabilidade operacional dos modelos propostos é apoiada pelo seu equilíbrio (trade-off) entre desempenho, complexidade e custo computacional. Os resultados apresentaram alta acurácia enquanto mantiveram baixa complexidade estrutural e execução relativamente rápida entre os modelos evolutivos. Diferentemente dos modelos de benchmark, que dependem de treinamento em lote ou de recalibração periódica, os sistemas fuzzy evolutivos adaptam-se online, amostra por amostra. Esta combinação de acurácia preditiva, parcimônia estrutural e eficiência computacional sugere que os modelos propostos podem ser candidatos adequados para aplicações de previsão de vazão de curto prazo operacionais reais.

## 8 CONCLUSÃO

Este trabalho teve como objetivo principal o desenvolvimento e a avaliação de três novos modelos fuzzy evolutivos denominados: *Variable Step-Size Adaptive evolving Multivariable Gaussian* (VSA-eMG), *Modified Variable Step-Size Adaptive evolving Multivariable Gaussian* (MVSA-eMG) e *Modified Variable Step-Size evolving Multivariable Gaussian* (MVS-eMG). Esses modelos foram construídos a partir da incorporação de diferentes mecanismos adaptativos de atualização de hiperparâmetros ao modelo *evolving Multivariable Gaussian* (eMG). A motivação central consistiu em investigar se esses mecanismos seriam capazes de aprimorar o desempenho de modelos de previsão de vazões de curto prazo em bacias hidrográficas do Sistema Interligado Nacional (SIN), mantendo simultaneamente características desejáveis para aplicações operacionais, como adaptação online, parcimônia estrutural e baixo custo computacional.

Para verificar essa hipótese, as abordagens propostas foram avaliadas de forma sistemática e comparadas tanto ao eMG original quanto a diferentes modelos de referência amplamente utilizados na literatura e na prática operacional. Entre esses benchmarks destacam-se o modelo físico SMAP/ONS, atualmente empregado pelo Operador Nacional do Sistema Elétrico, arquiteturas baseadas em LSTM e outros modelos fuzzy, como FIG-FTS e VS-eMG. A validação experimental foi conduzida com dados reais de vazão e precipitação estimada via satélite, cobrindo um período de onze anos (2011–2021) e abrangendo seis bacias estratégicas do SIN: Furnas, Itaipu, Itumbiara, São Simão, Três Marias e Tucuruí, o que permitiu avaliar o comportamento dos modelos em diferentes regimes hidrológicos e escalas operacionais.

No Estudo de Caso 1, que constitui o principal eixo experimental desta tese, os modelos propostos foram avaliados sob condições hidrológicas típicas, permitindo uma análise abrangente de desempenho e comparação direta com os modelos de referência. Os resultados indicaram que os modelos desenvolvidos apresentaram desempenho superior aos demais na maioria dos cenários analisados, com reduções consistentes nos erros de previsão e no viés, especialmente em relação ao modelo operacional SMAP/ONS, ao eMG original, à rede LSTM e ao modelo FIG-FTS. Essas melhorias estão diretamente associadas à introdução dos mecanismos adaptativos à estrutura do eMG, o que contribuiu para melhorar a capacidade adaptativa dos modelos às dinâmicas hidrológicas ao longo do tempo.

No Estudo de Caso 2, foram analisados cenários críticos associados a períodos de estresse hídrico mais severo, caracterizados por menores índices de vazões diárias e pela intensificação de efeitos associados à variabilidade climática. Os resultados mostraram que, embora possam ocorrer degradações pontuais de desempenho (especialmente em bacias de pequeno porte e em ocorrências de variações abruptas nos registros históricos), os modelos

propostos mantiveram desempenho altamente competitivo e viabilidade operacional. Esses achados indicam que, mesmo com a incorporação de mecanismos adaptativos, existem limites físicos inerentes à previsibilidade dos processos hidrológicos, particularmente em condições extremas.

No Estudo de Caso 3, a capacidade de generalização espacial foi investigada por meio da aplicação dos modelos a bacias com características hidrológicas distintas daquelas utilizadas na etapa de otimização dos hiperparâmetros. Os resultados demonstraram uma generalização altamente satisfatória, evidenciando a robustez das abordagens propostas. Ainda assim, observou-se que a transferência direta de hiperparâmetros não é irrestrita, sendo recomendável, em alguns casos, uma recalibração inicial para assegurar níveis de desempenho adequados em bacias com regimes hidrológicos ou características geográficas significativamente diferentes.

O comportamento dos modelos mostrou associação com características físicas das bacias analisadas. Observou-se maior estabilidade de desempenho naquelas de grande porte, nas quais a resposta hidrológica tende a ocorrer de forma mais gradual devido ao efeito de armazenamento e à maior memória do sistema. Em contrapartida, bacias menores, sujeitas a variações abruptas, apresentaram maior sensibilidade e degradações pontuais, evidenciando o desafio de representar respostas hidrológicas rápidas e flutuações súbitas de precipitação. Esse cenário sugere que os mecanismos adaptativos incorporados contribuíram para acompanhar diferentes escalas temporais e dinâmicas hidrológicas dos sistemas avaliados.

As análises estatísticas realizadas ao longo dos três estudos de caso indicaram que as melhorias observadas são, em grande parte, estatisticamente significativas, reforçando a confiabilidade dos resultados nos cenários avaliados. Ainda assim, reconhecem-se como limitações principais tanto a sensibilidade à escolha dos períodos de avaliação, uma vez que diferentes seleções de janelas temporais podem levar a variações nos desempenhos observados, quanto o aumento da probabilidade de ocorrência de resultados estatisticamente significativos por efeito do acaso, em função do elevado número de comparações realizadas. Apesar disso, o desenho experimental adotado, baseado em três estudos de caso que cobrem aspectos distintos, aliado ao uso de testes estatísticos complementares (MGN e Wilcoxon), contribui para uma avaliação mais robusta e consistente das evidências obtidas.

Outro aspecto importante, associado à modelagem de sistemas fuzzy evolutivos, foi a constatação de que o aumento de acurácia apresentado pelos modelos propostos em relação ao eMG original não ocorreu à custa de aumentos significativos na complexidade estrutural ou no custo computacional. Pelo contrário, os modelos mantiveram estruturas relativamente compactas, com número reduzido de regras finais e tempos de processamento compatíveis com aplicações em tempo real (adaptação online), evidenciando um equilíbrio favorável entre desempenho preditivo, parcimônia e eficiência computacional.

Sob a perspectiva prática, os modelos desenvolvidos neste trabalho apresentam características particularmente atrativas para aplicações operacionais. A capacidade de adaptação online, amostra por amostra, aliada ao baixo custo computacional e à ausência de necessidade de retreinamentos frequentes em lote, sugere que os modelos propostos são promissores como ferramentas complementares robustas e eficientes no apoio à decisão na gestão de reservatórios e no planejamento da operação hidrotérmica do sistema elétrico brasileiro. Essas abordagens apresentam potencial para contribuir para maior eficiência na alocação de recursos hídricos e para decisões mais econômicas no planejamento energético nacional, especialmente em um contexto de crescente variabilidade climática.

## 8.1 TRABALHOS FUTUROS

Por fim, os resultados obtidos apontam caminhos naturais para trabalhos futuros. Destacam-se as seguintes oportunidades de expansão:

- Investigar o uso de técnicas automáticas de otimização de hiperparâmetros, incluindo abordagens como neuro-fuzzy e meta-heurísticas, com o objetivo de reduzir a dependência da definição manual de parâmetros e do conhecimento empírico do usuário, tornando mais estruturado o processo de busca por configurações adequadas a diferentes cenários hidrológicos, incluindo a possibilidade de mecanismos de controle de crescimento das regras fuzzy.
- Avaliar o desempenho dos modelos propostos em diferentes horizontes de previsão, analisando a evolução do erro, da estabilidade e da capacidade de resposta à medida que o horizonte temporal é ampliado, de modo a compreender os efeitos da propagação de incertezas sobre a qualidade das previsões em aplicações de curto e médio prazo.
- Estender a validação dos modelos para bacias hidrográficas com características distintas daquelas consideradas neste estudo, com o intuito de avaliar os limites de generalização e estabilidade em cenários ainda mais desafiadores.
- Explorar a incorporação de variáveis exógenas relevantes e de informações oriundas do conhecimento hidrológico especializado ao processo de modelagem, aproveitando a flexibilidade dos modelos fuzzy para integrar informações adicionais que representem características específicas de bacias de interesse.
- Investigar o trade-off entre ganho preditivo e custo computacional por meio de métricas quantitativas independentes de hardware (como a contagem de parâmetros ajustáveis ou operações de ponto flutuante). Visando analisar rigorosamente a parcimônia estrutural das arquiteturas evolutivas frente aos modelos de referência, validando a sua eficiência para implementações de larga escala.

- Investigar o desenvolvimento de ferramentas de suporte à decisão voltadas ao uso contínuo dos modelos em operações reais, visando à manutenção do desempenho preditivo por meio da incorporação de etapas de análise e pré-processamento dos dados de entrada, mecanismos de acompanhamento sistemático do desempenho e critérios orientados por métricas de erro para ajustes adaptativos dos hiperparâmetros.

Essas investigações podem ampliar a eficiência, a aplicabilidade e a escalabilidade das técnicas propostas, fortalecendo seu potencial como ferramentas de apoio à decisão no contexto de previsão de vazão em bacias hidrográficas do SIN.

Por fim, os modelos fuzzy evolutivos propostos se apresentam como alternativas robustas e promissoras para complementar o planejamento operacional no âmbito do Sistema Interligado Nacional, contribuindo para o avanço dessa classe de modelos aplicados à previsão hidrológica em um contexto de cenários cada vez mais desafiadores, associados às mudanças climáticas e à variabilidade dos regimes hidrológicos.

## REFERÊNCIAS

- Agência Nacional de Águas e Saneamento Básico (ANA). *As Regiões Hidrográficas*. 2025. Disponível em: <<https://www.gov.br/ana/pt-br/assuntos/gestao-das-aguas/panorama-das-aguas/regioes-hidrograficas>>. Acesso em: 10 dez. 2025.
- Agência Nacional de Águas e Saneamento Básico (ANA). *Conjuntura dos Recursos Hídricos no Brasil: regiões hidrográficas brasileiras*. 2025. Disponível em: <<http://www.snirh.gov.br/portal/snirh/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/regioeshidrograficas2014.pdf>>. Acesso em: 10 dez. 2025.
- ALGARVIO, H.; LOPES, F.; SANTANA, J. Strategic operation of hydroelectric power plants in energy markets: A model and a study on the hydro-wind balance. *Fluids*, MDPI, v. 5, n. 4, p. 209, 2020.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, Stuttgart, v. 22, n. 6, p. 711–728, 2013.
- ALVES, K. S. T. R. et al. An enhanced set-membership evolving participatory learning with kernel recursive least squares applied to thermal modeling of power transformers. *Electric Power Systems Research*, v. 184, p. 106334, 2020.
- ALVES, T. R. *Previsão de vazão com séries temporais nebulosas para bacias do sistema interligado nacional*. 2024. Universidade Federal de Juiz de Fora, Juiz de Fora.
- ALVES, T. R.; SILVA JUNIOR, I. C.; HONÓRIO, L. M. *Previsão de Vazão com Séries Temporais Nebulosas para Bacias do Sistema Interligado Nacional*. 2023. Anais do Congresso Brasileiro de Inteligência Computacional (CBIC).
- ANGELOV, P. P. Fuzzily connected multimodel systems evolving autonomously from data streams. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 41, n. 4, p. 898–910, 2011.
- ANGELOV, P. P.; FILEV, D. P. On-line design of Takagi-Sugeno models. In: *International Fuzzy Systems Association World Congress*. [S.l.: s.n.], 2003. p. 576–584.
- ANGELOV, P. P.; FILEV, D. P. An approach to online identification of Takagi-Sugeno fuzzy models. *IEEE Transactions on Systems, Man, and Cybernetics, Part B - Cybernetics*, v. 34, n. 1, p. 484–498, 2004.
- ANGELOV, P. P.; FILEV, D. P. SimpleTS: A simplified method for learning evolving Takagi-Sugeno fuzzy models. In: *The 14th IEEE International Conference on Fuzzy Systems, 2005*. [S.l.: s.n.], 2005. p. 1068–1073.
- ANGELOV, P. P.; FILEV, D. P.; KASABOV, N. *Evolving intelligent systems: methodology and applications*. [S.l.]: John Wiley & Sons, 2010. v. 12.
- ANGELOV, P. P.; ZHOU, X. Evolving fuzzy-rule-based classifiers from data streams. *IEEE Transactions on Fuzzy Systems*, v. 16, n. 6, p. 1462–1475, 2008.
- ASHRAFI, M.; CHUA, L. H.; QUEK, C. The applicability of generic self-evolving Takagi-Sugeno-Kang neuro-fuzzy model in modeling rainfall–runoff and river routing. *Hydrology Research*, IWA Publishing, v. 50, n. 4, p. 991–1001, 2019.

- ÅSTRÖM, K. J.; WITTENMARK, B. *Adaptive control*. [S.l.]: Courier Corporation, 2013.
- ÁVILA, L. et al. Comparative evaluation of five hydrological models in a large-scale and tropical river basin. *Water*, MDPI, v. 14, n. 19, p. 3013, 2022.
- ÁVILA, L. et al. Seasonal streamflow forecast in the Tocantins river basin, Brazil: an evaluation of ECMWF-SEAS5 with multiple conceptual hydrological models. *Water*, v. 15, n. 9, p. 1695, 2023.
- BERGMEIR, C.; BENÍTEZ, J. M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*, Elsevier, v. 191, p. 192–213, 2012.
- BIREK, L.; PETROVIC, D.; BOYLAN, J. Water leakage forecasting: the application of a modified fuzzy evolving algorithm. *Applied Soft Computing*, v. 14, p. 305–315, 2014.
- CHANG, F. J.; CHANG, L. C.; CHEN, J. F. Artificial intelligence techniques in hydrology and water resources management. *Water*, v. 15, n. 10, p. 1846, 2023.
- DIEBOLD, F. X.; MARIANO, R. S. Comparing predictive accuracy. *Journal of Business & Economic Statistics*, v. 20, n. 1, p. 134–144, 2002.
- EVANS, J. B.; XUE, P.; LIU, B. Analysis and implementation of variable step size adaptive algorithms. *IEEE Transactions on Signal Processing*, v. 41, n. 8, p. 2517–2535, 1993.
- FRITZKE, B. Growing cell structures—a self-organizing network for unsupervised and supervised learning. *Neural Networks*, v. 7, n. 9, p. 1441–1460, 1994.
- GHORBANI, M. A. et al. A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction. *Environmental Earth Sciences*, Springer, v. 75, n. 6, p. 476, 2016.
- GIRIHAGAMA, L. et al. Streamflow modelling and forecasting for canadian watersheds using LSTM networks with attention mechanism. *Neural Computing and Applications*, v. 34, n. 22, p. 19995–20015, 2022.
- GOODARZI, M. R. et al. Assessment of machine learning models for short-term streamflow estimation: the case of Dez river in Iran. *Sustainable Water Resources Management*, Springer, v. 10, n. 1, p. 33, 2024.
- HAMLET, A. F.; HUPPERT, D.; LETTENMAIER, D. P. Economic value of long-lead streamflow forecasts for Columbia river hydropower. *Journal of Water Resources Planning and Management*, American Society of Civil Engineers, v. 128, n. 2, p. 91–101, 2002.
- HARRIS, R.; CHABRIES, D.; BISHOP, F. A variable step (VS) adaptive filter algorithm. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, v. 34, n. 2, p. 309–316, 1986.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT press, v. 9, n. 8, p. 1735–1780, 1997.
- Instituto Brasileiro de Geografia e Estatística (IBGE). *Atlas Geográfico Escolar: Recursos Hídricos*. 2024. Disponível em: <<https://atlascolar.ibge.gov.br/brasil/3024-diversidade-ambiental/3046-recursos-hidricos.html>>. Acesso em: 10 dez. 2025.

- JAHANBANI, H.; AHMED, K.; GU, B. Data-driven artificial intelligence-based streamflow forecasting, a review of methods, applications, and tools. *Journal of the American Water Resources Association (JAWRA)*, v. 60, n. 6, p. 1095–1119, 2024.
- JUANG, C. F.; LIN, C. T. An online self-constructing neural fuzzy inference network and its applications. *IEEE Transactions on Fuzzy Systems*, v. 6, n. 1, p. 12–32, 1998.
- JUANG, C. F.; LIN, C. T. A recurrent self-organizing neural fuzzy inference network. *IEEE Transactions on Neural Networks*, v. 10, n. 4, p. 828–845, 1999.
- KASABOV, N. Evolving fuzzy neural networks for supervised/unsupervised online knowledge-based learning. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, v. 31, n. 6, p. 902–918, 2001.
- KASABOV, N. K.; SONG, Q. DENFIS: dynamic evolving neural-fuzzy inference system and its application for time-series prediction. *IEEE Transactions on Fuzzy Systems*, v. 10, n. 2, p. 144–154, 2002.
- KE, H. et al. Xinanjiang-based interval forecasting model for daily streamflow considering climate change impacts. *Water Resources Management*, v. 38, n. 14, p. 5507–5522, 2024.
- KHAZAEIATHAR, M. et al. Daily streamflow time series modeling by using a periodic autoregressive model (ARMA) based on fuzzy clustering. *Water*, MDPI, v. 14, n. 23, p. 3932, 2022.
- KHOZANI, Z. S.; PRECHT, E.; IONITA, M. Weekly streamflow forecasting of Rhine river based on machine learning approaches. *Natural Hazards*, Springer, v. 121, n. 4, p. 4135–4153, 2025.
- KOMIJANI, M. et al. Introducing evolving Takagi–Sugeno method based on local least squares support vector machine models. *Evolving Systems*, v. 3, n. 2, p. 81–93, 2012.
- KWIN, C. T. et al. Rainfall-runoff modeling using dynamic evolving neural fuzzy inference system with online learning. *Procedia engineering*, Elsevier, v. 154, p. 1103–1109, 2016.
- LEMOS, A.; CAMINHAS, W.; GOMIDE, F. Multivariable gaussian evolving fuzzy modeling system. *IEEE Transactions on Fuzzy Systems*, v. 19, n. 1, p. 91–104, 2010.
- LETTENMAIER, D. P.; WOOD, E. F.; WALLIS, J. R. Hydro-climatological trends in the continental United States, 1948–88. *Journal of Climate*, v. 7, n. 4, p. 586–607, 1994.
- LIM, S. H. et al. Measuring the economic benefits of advanced technology use for river flood forecasting. *Journal of Flood Risk Management*, Wiley Online Library, v. 15, n. 2, p. e12781, 2022.
- LIMA, E. et al. Evolving fuzzy modeling using participatory learning. In: *Evolving Intelligent Systems: Methodology and Applications*. [S.l.]: Wiley Online Library, 2010. p. 67–86.
- LINHARES, L. F.; SILVA, A. M. Evolving fuzzy systems in taxi demand forecasting and classification. *Transactions on Fuzzy Sets and Systems*, v. 2, n. 1, p. 101–132, 2023.
- LIU, J. et al. Variational mode decomposition coupled LSTM with encoder-decoder framework: an efficient method for daily streamflow forecasting. *Earth Science Informatics*, Springer, v. 18, n. 1, p. 38, 2025.

- LJUNG, L. System identification. In: *Wiley Encyclopedia of Electrical and Electronics Engineering*. [S.l.]: John Wiley & Sons, 1999. p. 1–19.
- LOPES, J. E. G.; BRAGA, B. P. F.; CONEJO, J. G. L. SMAP: A simplified hydrologic model. In: *Applied Modeling in Catchment Hydrology*. [S.l.]: Water Resources Publications, 1982. p. 167–176.
- LU, M. et al. Optimizing multiple reliable forward contracts for reservoir allocation using multitime scale streamflow forecasts. *Water Resources Research*, Wiley Online Library, v. 53, n. 3, p. 2035–2050, 2017.
- LUGHOFER, E. D. FLEXFIS: A robust incremental learning approach for evolving Takagi–Sugeno fuzzy models. *IEEE Transactions on Fuzzy Systems*, v. 16, n. 6, p. 1393–1410, 2008.
- LUGHOFER, E. D. Evolving fuzzy systems—fundamentals, reliability, interpretability, useability, applications. In: *Handbook on computational intelligence: fuzzy logic, systems, artificial neural networks, and learning systems*. [S.l.]: World Scientific, 2016. v. 1, p. 67–135.
- LUNA, I. et al. Verifying the use of evolving fuzzy systems for multi-step ahead daily inflow forecasting. In: IEEE. *2009 15th International Conference on Intelligent System Applications to Power Systems*. [S.l.], 2009. p. 1–6.
- MACIEL, G. M. et al. Daily water flow forecasting via coupling between SMAP and deep learning. *IEEE Access*, v. 8, p. 204660–204675, 2020.
- MACIEL, L.; GOMIDE, F.; BALLINI, R. An enhanced approach for evolving participatory learning fuzzy modeling. In: *2012 IEEE Conference on Evolving and Adaptive Intelligent Systems*. Madrid, Spain: [s.n.], 2012. p. 23–28.
- MACIEL, L. et al. Evolving participatory learning fuzzy modeling for financial interval time series forecasting. In: *2017 Evolving and Adaptive Intelligent Systems (EAIS)*. [S.l.: s.n.], 2017. p. 1–8.
- MEI, Z.; ZHAO, T.; GU, X. A dynamic evolving fuzzy system for streaming data prediction. *IEEE Transactions on Fuzzy Systems*, v. 32, n. 8, p. 4324–4337, 2024.
- Ministério de Minas e Energia (MME). *Nota de Esclarecimento: Crise Hídrica*. 2021. Disponível em: <<https://www.gov.br/mme/pt-br/assuntos/noticias/nota-de-esclarecimento-3>>. Acesso em: 8 jul. 2025.
- MODI, P. A. et al. Understanding the relationship between streamflow forecast skill and value across the western US. *Hydrology and Earth System Sciences*, Copernicus Publications Göttingen, Germany, v. 29, n. 20, p. 5593–5623, 2025.
- MUNIZ, R. N. et al. Time series forecasting of natural inflow in hydroelectric power plants using hyper-tuned temporal fusion transformer with Hodrick–Prescott filter. *IET Generation, Transmission & Distribution*, Wiley Online Library, v. 19, n. 1, p. e70087, 2025.
- NASCIMENTO, P. H. et al. Spillage forecast models in hydroelectric power plants using information from telemetry stations and hydraulic control. *Energies*, MDPI, v. 14, n. 1, p. 184, 2021.

NETO, A. K. et al. Advancing medium-range streamflow forecasting for large hydropower reservoirs in Brazil by means of continental-scale hydrological modeling. *Water*, v. 15, n. 9, p. 1693, 2023.

Operador Nacional do Sistema Elétrico (ONS). *Aplicação do modelo SMAP/ONS para previsão de vazões no âmbito do SIN*. 2017. Disponível em: <[https://antigo.mme.gov.br/c/document\\_library/get\\_file?uuid=4737f06f-525a-223d-ee9f-04c17b11058e&groupId=36070](https://antigo.mme.gov.br/c/document_library/get_file?uuid=4737f06f-525a-223d-ee9f-04c17b11058e&groupId=36070)>. Acesso em: 10 jan. 2026.

Operador Nacional do Sistema Elétrico (ONS). *SINTEGRE - Sistema de Informações da Operação*. 2024. Disponível em: <<https://www.ons.org.br/>>. Acesso em: 8 jul. 2025.

ORELLANA, R. et al. Model error modeling for a class of multivariable systems utilizing stochastic embedding approach with gaussian mixture models. *Symmetry*, MDPI AG, v. 17, n. 3, p. 426, 2025.

PHAM, Q. B. et al. Hybrid model to improve the river streamflow forecasting utilizing multi-layer perceptron-based intelligent water drop optimization algorithm. *Soft Computing*, Springer Nature BV, v. 24, n. 23, p. 18039–18056, 2020.

PORTELE, T. C. et al. Seasonal forecasts offer economic benefit for hydrological decision making in semi-arid regions. *Scientific reports*, v. 11, n. 1, p. 10581, 2021.

QUEIROZ, E. R. C. et al. Variable step-size evolving participatory learning with kernel recursive least squares applied to gas prices forecasting in Brazil. *Evolving Systems*, Springer, v. 13, n. 2, p. 297–306, 2022.

RAMOS, F. D.; GÁMEZ, C. H. Simple and low-cost procedure for monthly and yearly streamflow forecasts during the current hydrological year. *Water*, MDPI, v. 10, n. 8, p. 1038, 2018.

ROCHA, M. V. G. et al. Power transformers thermal modeling based on the modified set-membership evolving multivariable gaussian and variable step-size evolving multivariable gaussian. *Journal of Control, Automation and Electrical Systems*, v. 33, n. 3, p. 1044–1055, 2022.

ROCHA, M. V. G. et al. Power transformers thermal modeling using an enhanced set-membership multivariable gaussian evolving fuzzy system. *Electric Power Systems Research*, v. 194, p. 107088, 2021.

RODRIGUES, F. P. S.; SILVA, A. M.; LEMOS, A. P. Evolving fuzzy predictor with multivariable gaussian participatory learning and multi-innovations recursive weighted least squares: eFMI. *Evolving Systems*, Springer, v. 13, n. 5, p. 667–686, 2022.

ROZANTE, J. R. et al. Combining TRMM and surface observations of precipitation: technique and validation over South America. *Weather and forecasting*, v. 25, n. 3, p. 885–894, 2010.

RUBIO, J. J. SOFMLS: online self-organizing fuzzy modified least-squares network. *IEEE Transactions on Fuzzy Systems*, v. 17, n. 6, p. 1296–1309, 2009.

SAMMEN, S. S. et al. A new soft computing model for daily streamflow forecasting. *Stochastic Environmental Research and Risk Assessment*, Springer, v. 35, n. 12, p. 2479–2491, 2021.

- Serviço Geológico do Brasil (SGB/CPRM). *Crise Hídrica no Brasil: o uso das águas subterrâneas como reforço no abastecimento público*. 2021. Disponível em: <<https://rigeo.cprm.gov.br/handle/doc/22711>>. Acesso em: 8 jul. 2025.
- SEVERIANO, C. A. et al. Evolving fuzzy time series for spatio-temporal forecasting in renewable energy systems. *Renewable Energy*, Elsevier, v. 171, p. 764–783, 2021.
- SHAFIEEZADEH-ABADEH, S.; KALHOR, A. Evolving Takagi–Sugeno model based on online Gustafson–Kessel algorithm and kernel recursive least square method. *Evolving Systems*, v. 7, n. 1, p. 1–14, 2016.
- SILVA, P. C. L. et al. Probabilistic forecasting with fuzzy time series. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 28, n. 8, p. 1771–1784, 2019.
- ŠKRJANC, I. et al. Evolving fuzzy and neuro-fuzzy approaches in clustering, regression, identification, and classification: A survey. *Information sciences*, Elsevier, v. 490, p. 344–368, 2019.
- SOUZA, L. et al. Thermal modeling of power transformers using evolving fuzzy systems. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 25, n. 5, p. 980–988, 2012.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, n. 1, p. 116–132, 1985.
- TASHMAN, L. J. Out-of-sample tests of forecasting accuracy: an analysis and review. *International journal of forecasting*, Elsevier, v. 16, n. 4, p. 437–450, 2000.
- TEPETIDIS, N. et al. Investigating the performance of the informer model for streamflow forecasting. *Water*, v. 16, n. 20, 2024.
- TIKHAMARINE, Y. et al. Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey wolf optimization (GWO) algorithm. *Journal of Hydrology*, Elsevier, v. 582, p. 124435, 2020.
- TOLEDO, J. F. *Modelos de aprendizado de máquina com índices climáticos de teleconexões para previsões de vazões naturais afluentes de longo prazo*. 192 p. Tese (Doutorado) — Universidade Federal do ABC, Santo André, 2023.
- TOLEDO, J. F. et al. Performance comparison of machine learning models for streamflow forecasting. In: IEEE. *2021 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. [S.l.], 2021. p. 1–6.
- TOLEDO, J. F. et al. Climate indices impact in monthly streamflow series forecasting. *IEEE Access*, IEEE, v. 11, p. 21451–21464, 2023.
- TORRES, F. L. R. et al. Integrating hydrological and machine learning models for enhanced streamflow forecasting via bayesian model averaging in a hydro-dominant power system. *Water*, MDPI, v. 16, n. 4, p. 586, 2024.
- TREISTMAN, F. et al. A framework to evaluate and compare synthetic streamflow scenario generation models. *Brazilian Journal of Water Resources*, v. 28, p. e43, 2023.

TRIPURA, J.; ROY, P.; BARBHUIYA, A. K. Simultaneous streamflow forecasting based on hybridized neuro-fuzzy method for a river system. *Neural Computing and Applications*, v. 33, p. 3221–3233, 2021.

TROIN, M. et al. Generating ensemble streamflow forecasts: A review of methods and approaches over the past 40 years. *Water Resources Research*, v. 57, n. 7, 2021.

VIEIRA, R.; GOMIDE, F.; BALLINI, R. Kernel evolving participatory fuzzy modeling for time series forecasting. In: *2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. [S.l.: s.n.], 2018. p. 1–9.

WANG, S. et al. Streamflow forecasting method with a hybrid physical process-mathematical statistic. *Stochastic Environmental Research and Risk Assessment*, Springer, v. 37, n. 12, p. 4805–4826, 2023.

WILCOXON, F. Individual comparisons by ranking methods. *Biometrics bulletin*, JSTOR, v. 1, n. 6, p. 80–83, 1945.

WOBUS, C. et al. Water allocation, return flows, and economic value in water-scarce environments: Results from a coupled natural-human system model. *Water*, MDPI, v. 14, n. 20, p. 3280, 2022.

XU, W. et al. A two stage bayesian stochastic optimization model for cascaded hydropower systems considering varying uncertainty of flow forecasts. *Water Resources Research*, Wiley Online Library, v. 50, n. 12, p. 9267–9286, 2014.

YAGER, R. R. A model of participatory learning. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, v. 20, n. 5, p. 1229–1234, 1990.

ZADEH, L. A. Fuzzy sets. *Information and control*, Elsevier, v. 8, n. 3, p. 338–353, 1965.