



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

BRUNA FORESTIERI BOLONHEZ

**MODELAGEM HÍBRIDA COM REDES NEURAIIS POR  
*ENSEMBLE* PARA PREDIÇÃO DE PRECIPITAÇÃO  
DECENDIAL**

---

Londrina  
2025

BRUNA FORESTIERI BOLONHEZ

**MODELAGEM HÍBRIDA COM REDES NEURAIIS POR  
*ENSEMBLE* PARA PREDIÇÃO DE PRECIPITAÇÃO  
DECENDIAL**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia e Urbanismo da Universidade Estadual de Londrina, como requisito para obtenção do título de Doutora em Engenharia Civil.

Orientador: Prof. Dr. Hemerson Pinheiro Donizete

Londrina  
2025

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

Bolonhez, Bruna Forestieri.

Modelagem híbrida com redes neurais por ensemble para predição de precipitação decendial / Bruna Forestieri Bolonhez. - Londrina, 2025.  
157 f. : il.

Orientador: Hemerson Donizete Pinheiro.

Tese (Doutorado em Engenharia Civil) - Universidade Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em Engenharia Civil, 2025.

Inclui bibliografia.

1. Hidrologia - Tese. 2. Aprendizado de máquina - Tese. 3. Meteorologia - Tese. 4. Séries Temporais - Tese. I. Pinheiro, Hemerson Donizete. II. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo. Programa de Pós-Graduação em Engenharia Civil. III. Título.

CDU 62

BRUNA FORESTIERI BOLONHEZ

**MODELAGEM HÍBRIDA COM REDES NEURAIS POR  
*ENSEMBLE* PARA PREDIÇÃO DE PRECIPITAÇÃO  
DECENDIAL**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia e Urbanismo da Universidade Estadual de Londrina, como requisito para obtenção do título de Doutora em Engenharia Civil.

**BANCA EXAMINADORA**

---

Prof. Dr. Hemerson Donizete Pinheiro  
Universidade Estadual de Londrina - UEL

---

Prof. Dr. Marcelo Augusto de Aguiar e Silva  
Universidade Estadual de Londrina - UEL

---

Prof. Dr. Dante Alves Medeiros Filho  
Universidade Estadual de Maringá - UEM

---

Prof. Dr. Jorge Alberto Martins  
Universidade Tecnológica Federal do Paraná  
- UTFPR

---

Prof. Dr. Jorge Antonio Silva Centeno  
Universidade Federal do Paraná - UFPR

Londrina, 09 de junho de 2025.

## **AGRADECIMENTO**

A Deus, pela graça e pelas oportunidades que me concedeu ao longo da vida.

À minha família, em especial aos meus pais, Lurdes e Moises, e à minha irmã, Jaqueline, pelo amor incondicional. Vocês são o meu mundo.

Ao Prof. Dr. Hemerson Donizete Pinheiro, pela orientação, atenção, compreensão ao longo desta aventura chamada "Doutorado".

Aos professores que integraram a banca de avaliação deste trabalho, pelo tempo dedicado e pelas propostas e sugestões que contribuíram significativamente para o aprimoramento desta pesquisa.

Ao corpo docente e discente da Pós-Graduação em Engenharia Civil da Universidade Estadual de Londrina, cujo apoio, ajuda e infraestrutura foram indispensáveis para a realização deste trabalho.

Ao Departamento de Engenharia Civil da Universidade Estadual de Maringá, em especial a todos os colegas da Sala 202, pela amizade, incentivo e colaboração ao longo da minha trajetória acadêmica.

A todos que, de alguma forma, ajudaram e participaram do meu desenvolvimento como engenheira, pesquisadora e, principalmente, como pessoa.

## RESUMO

BOLONHEZ, Bruna Forestieri. **Modelagem híbrida com redes neurais por ensemble para predição de precipitação decendial**. 2025. 157 f. Tese (Doutorado em Engenharia Civil) – Centro de Tecnologia, Universidade Estadual de Londrina, Londrina, 2025.

A predição das precipitações, suas intensidades e durações é fundamental para a gestão dos recursos hídricos e mitigação de riscos para as obras de engenharia civil e as infraestruturas urbanas. Com os avanços das técnicas de aprendizado de máquina, surgiram novas possibilidades para aprimorar a modelagem de séries hidrológicas, incluindo o uso de métodos de associação (*ensembles*) entre os modelos. Esta pesquisa avaliou o desempenho de estratégias de associação aplicadas a predição da precipitação decendial (10 dias), combinando a decomposição da série pelo método STL (*Seasonal-Trend Decomposition using LOESS*) e o uso de múltiplas arquiteturas de redes neurais recorrentes (RNN, LSTM e GRU). Foram desenvolvidos cinco modelos híbridos com associação (H1 a H5) e múltiplos modelos comparativos baseados em redes isoladas (B1 a B3) e na recomposição direta das componentes (R1 a R4). As avaliações, realizadas para duas estações pluviométricas do Paraná (Maringá e Colônia Vitória), indicaram que as estratégias de associação não proporcionaram ganhos relevantes frente aos modelos individuais ou à recomposição direta das componentes. Em Maringá, o melhor modelo híbrido (H3) apresentou  $R^2$  inferior ao modelo GRU direto (B3), e as séries previstas apresentaram perda de variabilidade e compressão dos extremos. Já para a Estação Colônia Vitória, o desempenho dos modelos foi ainda mais limitado, com  $R^2$  negativos na maioria dos casos. Durante as modelagens, as estratégias com decomposição e associação demandaram tempos de processamento significativamente superior, sem reflexo positivo no desempenho preditivo. Os resultados reforçam que a eficácia das associações depende fortemente das características da série e da qualidade dos modelos-base, sendo que, para o contexto avaliado, a hipótese de ganhos com a associação não se confirmou.

**Palavras-chave:** aprendizado profundo; *ensemble*; decomposição; RNA.

## ABSTRACT

BOLONHEZ, Bruna Forestieri. **Hybrid modeling with neural networks and ensemble methods for 10-day rainfall forecasting**. 2025. 157 p. Thesis (Doctorate in Civil Engineering) – Technology Center, State University of Londrina, Londrina, 2025.

Forecasting rainfall, its intensities, and durations are fundamental for the management of water resources and the risk mitigation for civil engineering works and urban infrastructures. With the advances in machine learning techniques, new possibilities have emerged to improve the modeling of hydrological time series, including the use of ensemble methods. This research evaluated the performance of ensemble strategies for forecasting 10-day precipitation, combining the decomposition of the series using the STL method (Seasonal-Trend Decomposition using LOESS) and the use of multiple recurrent neural network architectures (RNN, LSTM, and GRU). Five hybrid models with ensemble strategies (H1 to H5) and multiple comparative models based on isolated networks (B1 to B3) and on the direct recomposition of components (R1 to R4) were developed. The evaluations conducted for two rainfall stations in Paraná State (Maringá and Colônia Vitória), indicated that the ensemble strategies did not provide significant gains compared to the individual models or to the direct recomposition of components. In Maringá, the best hybrid model (H3) presented an  $R^2$  lower than the direct GRU model (B3), and the predicted series showed a decrease in variability and compression of extremes. The Colônia Vitória station's performance was even more limited, with negative  $R^2$  values in most cases. During the modeling process, the strategies involving decomposition and ensemble required significantly higher processing times without comparable improvements in predictive performance. The results reinforce that the effectiveness of ensemble strategies strongly depends on the characteristics of the time series and the quality of the base models. For the evaluated context, the hypothesis of performance gains through ensemble association was not confirmed.

**Keywords:** deep learning; ensemble; decomposition; ANN.

## LISTA DE FIGURAS

Figura 1 – Simulação da mudança de temperatura e precipitação média anual em relação ao período pré-industrial em três cenários .....	23
Figura 2 – Relação entre tempo de antecedência da previsão, suas incertezas e seu nível de suporte à tomada de decisão.....	31
Figura 3 – Predição uma série temporal $f_{x_m}$ com base nos dados da série $x$ .....	34
Figura 4 – Representação de uma série temporal e suas componentes .....	35
Figura 5 – Neurônio <i>perceptron</i> .....	41
Figura 6 – <i>Perceptron</i> Multicamada .....	43
Figura 7 – Célula recorrente.....	46
Figura 8 – Célula recorrente LSTM .....	48
Figura 9 – Célula recorrente GRU.....	51
Figura 10 – Estrutura de modelos de aprendizado por (A) Bagging e (B) Boosting ..	54
Figura 11 – Estrutura de um modelo de aprendizado do tipo <i>Stacking</i> .....	55
Figura 12 – Estrutura de um modelo de aprendizado do tipo <i>Stacking</i> com múltiplas variáveis exploratórias.....	56
Figura 13 – Estrutura de um modelo de aprendizado do tipo <i>Stacking</i> com múltiplos níveis.....	57
Figura 14 – Processo de busca de forma sistemática .....	58
Figura 15 – Total de publicações por ano .....	59
Figura 16 – Total de estudos por variáveis previstas .....	59
Figura 17 – Total de análises por escala temporal.....	60
Figura 18 – Total de aplicações por método de decomposição .....	61
Figura 19 – Total de aplicações por modelo preditivo .....	62
Figura 20 – Número de publicações segundo a faixa percentual de calibração/validação.....	65
Figura 21 – Número de publicações que empregaram a referente métrica de performance .....	66
Figura 22 – Fluxograma dos procedimentos de agregação, normalização e decomposição da série de precipitações decendiais .....	70
Figura 23 – Estrutura do modelo híbrido H1 .....	74
Figura 24 – Estrutura do modelo híbrido H2 .....	75
Figura 25 – Estrutura dos modelo híbrido H3.....	75

Figura 26 – Estrutura do modelo híbrido H4 .....	76
Figura 27 – Estrutura do modelo híbrido H5 .....	76
Figura 28 – Estruturas dos (A) Modelo B1 (RNN), (B) Modelo B2 (LSTM) e (C) Modelo B3 (GRU).....	77
Figura 29 – Estruturas dos (A) Modelo R1 (RNN), (B) Modelo R2 (LSTM), (B) Modelo R3 (GRU), (D) Modelo R4 (Híbrido) .....	78
Figura 30 – Estações filtradas para o estado do Paraná.....	82
Figura 31 – Série de precipitação decendial e suas componentes segundo o processo em etapas e completo – Estação Maringá (02351013) .....	85
Figura 32 – Série de precipitação decendial e as componentes das decomposições STL – Estação Colônia Vitória (02551008) .....	86
Figura 33 – Predição para as componentes da série de precipitação decendial – Validação – Estação Maringá (02351013) .....	89
Figura 34 – Predição para as componentes da série de precipitação decendial – Validação – Estação Colônia Vitória (02551008) .....	90
Figura 35 – Predição dos modelos H1 a H5 – Validação – Estação Maringá (02351013) .....	95
Figura 36 – Predição dos modelos H1 a H5 – Validação – Estação Colônia Vitória (02551008).....	96
Figura 37 – Predição dos modelos B1, B2 e B3 – Validação – Estação Maringá (02351013).....	100
Figura 38 – Predição dos modelos B1, B2 e B3 – Validação – Estação Colônia Vitória (02551008).....	101
Figura 39 – Predição dos modelos R1 a R4 – Validação – Estação Maringá (02351013) .....	103
Figura 40 – Predição dos modelos R1 a R4 – Validação – Estação Colônia Vitória (02551008).....	104
Figura 41 – Predição dos modelos do CPTEC e ECMWF – Validação – Estação Maringá (02351013) .....	106
Figura 42 – Predição dos modelos do CPTEC e ECMWF – Validação – Estação Colônia Vitória (02551008).....	106
Figura 43 – Coeficiente de determinação ( $R^2$ ) dos modelos – Validação.....	108
Figura 44 – Distribuição das predições dos modelos para a Estação Maringá (02351013).....	109

Figura 45 – Distribuição das previsões dos modelos para a Estação Colônia Vitória (02551008).....	109
Figura 46 – Coeficiente de determinação ( $R^2$ ) dos modelos por estação do ano – Validação – Estação Maringá (02351013) .....	110
Figura 47 – Coeficiente de determinação ( $R^2$ ) dos modelos por estação do ano – Validação – Estação Colônia Vitória (02551008) .....	111
Figura 48 – Tempo de calibração, simulação e total para os modelos.....	113
Figura 49 – Relação entre coeficiente de determinação $R^2$ e os tempos de A) Calibração, B) Simulação e C) Total dos modelos .....	115
Figura 50 – Comparação entre as métricas calculadas para os modelos elaborados pelo presente e outros estudos semelhantes .....	117

## LISTA DE QUADROS

Quadro 1 – Exemplos de escalas temporais e de tempo de antecedência da previsão meteorológica em função da aplicação .....	32
Quadro 2 – Critérios de classificação dos dados das séries de precipitação .....	69
Quadro 3 – Valores propostos para os hiper parâmetros das redes neurais .....	72

## LISTA DE TABELAS

Tabela 1 – Análise descritiva das componentes derivadas da decomposição completa e em etapas – Estação Maringá (02351013).....	85
Tabela 2 – Análise descritiva das componentes derivadas da decomposição completa e em etapas – Estação Colônia Vitória (02551008) .....	86
Tabela 3 – Métricas de performance dos modelos de predição das componentes da série de precipitação decendial – Estação Maringá (02351013).....	89
Tabela 4 – Métricas de performance dos modelos de predição das componentes da série de precipitação decendial – Estação Colônia Vitória (02551008)...	90
Tabela 5 – Comparação das métricas $R^2$ e RMSE (mm) das componentes entre as estações - Validação .....	92
Tabela 6 – Métricas de performance dos modelos H1 a H5 .....	94
Tabela 7 – Métricas de performance para os modelos B1, B2 e B3 .....	100
Tabela 8 – Métricas de performance para os modelos R1 a R4 .....	103
Tabela 9 – Métricas de performance para os modelos CPTEC e ECMWF - Validação .....	106
Tabela 10 – Média das métricas de performance para os modelos elaborados por esse e outros estudos semelhantes.....	118

## LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Networks</i> ou redes neurais artificiais
ARIMA	<i>AutoRegressive Integrated Moving Average</i> ou modelo autorregressivo integrado de médias móveis
BPRNA	Rede neural artificial de retropropagação
CEEMD	Decomposição empírica conjugada modificada
CEEMDAN)	Decomposição empírica por conjunto com ruído adaptativo
Conv1D	<i>1D Convolutional Layer</i>
EEMD	Decomposição em modos empíricos por conjunto
EMD	<i>Empirical mode decomposition</i> ou decomposição de modo empírico
GEP	<i>Gene expression programming</i> ou Programação de expressão genética
GMDH	<i>Group method of data handling</i> ou método de grupo de manipulação de dados
GRU	<i>Gated recurrent unit</i> ou unidade recorrente fechada
IMFs	<i>Intrinsic mode functions</i> ou funções de modo intrínseco
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
KNN	<i>K-Nearest Neighbors</i> ou K-vizinhos mais próximos
LOESS	<i>Locally estimated scatterplot smoothing</i>
NOOA	Administração Nacional Oceânica e Atmosférica dos Estados Unidos
NWP	<i>Numerical Weather Prediction</i> ou previsões numéricas do tempo
RNN	<i>Recurrent neural networks</i> ou redes neurais recorrentes
SARIMA	<i>Seasonal Autorregressive Integrated Moving Average</i> ou modelos AutoRegressivos integrados de médias móveis com sazonalidade
STL	<i>Seasonal and Trend decomposition using Loess</i>
LeakyReLU	<i>Leaky Rectified Linear Unit</i>
LSTM	<i>Long short-term memory</i> ou Memória longa de curto prazo
MAE	Erro Médio Absoluto
MAPE	Erro Percentual Absoluto Médio
MDR	Ministério da Integração e do Desenvolvimento Regional
MLP	<i>Multilayer perceptron</i> ou perceptron multicamada
MSE	Erro quadrático médio
NSE	Coefficiente de Nash-Sutcliffe

PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>
ReLU	<i>Rectified linear unit</i> ou unidade linear retificada
RMSE	Raíz quadrada do erro quadrático médio
SGB	<i>Stochastic gradient boosting</i>
SVM	<i>Support Vector Machine</i> ou máquina de vetores de suporte
XGBoost	<i>Extreme Gradient Boosting</i>

## LISTA DE SIMBOLOS

### Letras Minúsculas

$a$	Número de componentes das série $\mathbf{x}$ a serem empregadas na previsão
$\mathbf{b}$	Vetor viés
$\mathbf{b}_{h,t}$	Vetor de vieses para a determinação do estado oculto atual ( $\mathbf{h}_t$ ).
$\mathbf{b}_{y,t}$	Vetor de vieses para a determinação da saída ( $\mathbf{y}_t$ )
$\mathbf{b}_j^{(i)}$	Vetor viés associado ao neurônio $j$ na camada oculta $i$
$d$	Número de componentes a serem previstos, que compõem $f(\mathbf{x}_a)$
$f(\mathbf{x}_a)$	Função de predição
$\mathbf{h}_i$	$i$ -ésimo vetor do estado oculto
$\mathbf{h}_j^i$	Vetor de ativação do neurônio $j$ na camada oculta $i$
$m$	Número de neurônios na primeira camada.
$n$	Número de componentes na série original $\mathbf{x}$
$p_i$	$i$ -ésima componente da série de dados $\mathbf{p}$
$\mathbf{p}$	Vetor da série de dados de precipitação
$\mathbf{p}_i$	Subconjunto do vetor de precipitação, contendo as componentes de 1 a $i$
$q$	Dimensão da janela de vizinhança
$r_i^j$	$i$ -ésima componente do resíduo da série de dados $\mathbf{p}$ , avaliada na iteração $j$
$\mathbf{r}$	Vetor do resíduo ou resíduo da série de dados $\mathbf{p}$
$\mathbf{r}^0$	Vetor de estimativa inicial do resíduo da série $\mathbf{p}$
$s_i^j$	$i$ -ésima componente da sazonalidade da série de dados $\mathbf{p}$ , avaliada na iteração $j$
$\mathbf{s}$	Vetor da sazonalidade da série de dados $\mathbf{p}$
$\mathbf{s}^0$	Vetor de estimativa inicial da sazonalidade da série $\mathbf{p}$
$t_i^j$	$i$ -ésima componente da tendência da série de dados $\mathbf{p}$ , avaliada na iteração $j$
$\mathbf{t}$	Vetor da tendência da série de dados $\mathbf{p}$
$\mathbf{t}^0$	Vetor de estimativa inicial da tendência da série $\mathbf{p}$
$u$	Distância normalizada entre o ponto central $p_i$ e os demais pontos $p$ na janela de vizinhança.

$\mathbf{w}$	Vetor peso
$\mathbf{w}_{i,j}^{(k)}$	Vetor peso que conecta a entrada $i$ ao neurônio $j$ na camada oculta $k$
$\mathbf{w}_{xh,t}$	Vetor peso para a determinação do estado oculto atual ( $\mathbf{h}_t$ ).
$\mathbf{w}_{y,t}$	Vetor de pesos sobre o estado oculto atual ( $\mathbf{h}_t$ ) para a determinação da saída ( $\mathbf{y}_t$ )
$x_i$	Componente da série $\mathbf{x}$
$\mathbf{x}$	Vetor de entrada da série de dados
$\mathbf{x}_i$	$i$ -ésimo vetor de entrada da série de dados
$y$	Valor real observado
$\hat{y}$	Valor previsto para a variável segundo um modelo
$\bar{y}$	Valor médio observado
$\mathbf{y}$	Vetor de saída do neurônio

### Letras Maiúsculas

$\mathbf{B}_n^{(i)}$	Matriz de vetores vieses do tipo $\mathbf{b}_{h,t}$ na camada $i$
$\mathbf{C}_t^{(i)}$	Matriz do estado das células no tempo $t$ na camada $i$
$\tilde{\mathbf{C}}_t^{(i)}$	Matriz com os novos candidatos ao estado de célula na camada $i$
$\mathbf{F}_t^{(i)}$	Matriz de com os vetores de esquecimento do estado oculto anterior na camada $i$
$\mathbf{H}_t^{(i)}$	Matriz de vetores do estado oculto atual ( $\mathbf{h}_t$ ) na camada $i$
$\tilde{\mathbf{H}}_t^{(i)}$	Matriz de valores candidatos ao estado oculto ( $\mathbf{H}_t$ ) na camada $i$
$\mathbf{I}_t^{(i)}$	Matriz com as modificações para o cálculo dos novos estados de célula na camada $i$
$\mathbf{IMF}_i$	$i$ -ésima função de modo intrínseca da série de dados $\mathbf{p}$
$R^2$	Coefficiente de Determinação
$\mathbf{R}_t^{(i)}$	Matriz de valores de redefinição
$W(u)$	Função de peso baseada na distância normalizada $u$ , utilizada para ponderar os pontos na janela de vizinhança
$\mathbf{W}_{hy}^{(i)}$	Matriz de vetores de peso do tipo $\mathbf{w}_{hy,t}$ na camada $i$
$\mathbf{X}_t^{(i)}$	Matriz de vetores de entrada ( $\mathbf{x}_t$ ) na camada $i$
$\mathbf{Y}_t^{(i)}$	Matriz com os vetores de saída da rede neural na camada $i$
$\mathbf{Z}_t^{(i)}$	Matriz com vetores de atualização na camada $i$

## Letras Gregas

$\phi$	Função de ativação do neurônio de saída
$\lambda_q(p_i)$	Distância máxima dentro da janela de vizinhança.
$\ell$	Número da camada oculta
$\sigma$	Função de ativação da camada oculta

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>20</b>
1.1	CONTEXTUALIZAÇÃO .....	20
1.2	JUSTIFICATIVA .....	22
1.2.1	Relevância do Tema .....	22
1.2.2	Lacuna do Conhecimento e Aspecto de Ineditismo .....	25
1.3	HIPÓTESE DA PESQUISA .....	25
1.4	QUESTÃO DE PESQUISA.....	26
1.5	OBJETIVOS.....	26
1.5.1	Objetivos Específicos .....	26
1.6	DELIMITAÇÃO DA PESQUISA .....	27
1.7	DEFINIÇÃO DOS PRINCIPAIS TERMOS.....	27
1.8	ESTRUTURA DA TESE .....	28
<b>2</b>	<b>REVISÃO DE LITERATURA .....</b>	<b>30</b>
2.1	PRECIPITAÇÕES.....	30
2.2	MODELAGEM DE SÉRIES TEMPORAIS.....	33
2.2.1	Técnicas de decomposição de séries temporais.....	37
2.3	MODELOS DE APRENDIZADO PROFUNDO .....	40
2.3.1	Aprendizado Profundo.....	42
2.3.2	Redes neurais recorrentes .....	46
2.3.3	Redes neurais de memória longa de curto prazo.....	48
2.3.4	Unidade recorrente fechada .....	50
2.4	MODELOS DE APRENDIZADO POR CONJUNTO .....	52
2.5	ESTADO DA ARTE .....	57
<b>3</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>68</b>
3.1	TRATAMENTO E DECOMPOSIÇÃO DA SÉRIE TEMPORAL .....	68
3.2	CONFIGURAÇÃO E TREINAMENTO DAS REDES NEURAIS .....	71
3.3	DESENVOLVIMENTO DOS MODELOS HÍBRIDOS .....	73
3.4	MODELOS COMPARATIVOS PARA AVALIAÇÃO DE DESEMPENHO .....	77
3.5	ANÁLISE DA EFICIÊNCIA DOS MODELOS .....	80
3.6	LOCAL DE ESTUDO .....	81

<b>4</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>84</b>
4.1	ESTRUTURAÇÃO E DECOMPOSIÇÃO DAS SÉRIES DE PRECIPITAÇÃO DECENDIAL ..	84
4.2	MODELAGEM DAS COMPONENTES.....	88
4.3	MODELAGEM DA PRECIPITAÇÃO DECENDIAL.....	94
4.3.1	Desempenho frente aos modelos comparativos .....	99
4.3.2	Desempenho por estação do ano .....	110
4.3.3	Tempo de Processamento e Execução.....	112
4.3.4	Comparação com o Estado da Arte .....	116
4.4	DISCUSSÃO GERAL .....	119
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>123</b>
5.1	LIMITAÇÕES DA PESQUISA E PROPOSTAS PARA TRABALHOS FUTUROS.....	123
	<b>REFERÊNCIAS.....</b>	<b>125</b>
	<b>APÊNDICE A.....</b>	<b>137</b>
	<b>APÊNDICE B .....</b>	<b>142</b>
	<b>APÊNDICE C .....</b>	<b>144</b>
	<b>APÊNDICE D.....</b>	<b>148</b>
	<b>APENDICE E .....</b>	<b>151</b>
	<b>ANEXO A .....</b>	<b>154</b>

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO

A precipitação é uma das componentes principais do ciclo hidrológico e a sua previsão é indispensável para a elaboração de projetos hidráulicos, análise de riscos e o gerenciamento dos recursos hídricos. O conhecimento e a estimativa das intensidades e totais precipitados em curtos e longos períodos possibilita a identificação dos possíveis riscos e danos associados aos eventos de chuva, colaborando para a sua minimização ou prevenção. Em conjunto, nas ocasiões de escassez, tais informações poderão agilizar o planejamento por fontes alternativas de água ou favorecer uma melhor operação dos reservatórios existentes (Golding *et al.*, 2019; Sit *et al.*, 2020)

A ocorrência e a intensidade das precipitações podem ser influenciadas por uma variedade de parâmetros e condições atmosféricas, como temperatura, umidade, velocidade do vento, entre outros. Dessa forma, a modelagem física desse fenômeno é complexa e demanda um grande volume de dados, dependendo da caracterização ambiental, da circulação do ar e suas interações (Bauer; Thorpe; Brunet, 2015; Chen *et al.*, 2023). Além disso, ainda há incertezas numéricas associadas a resolução das equações de conservação de massa e quantidade de movimento, que regem os fenômenos atmosféricos. Tais incertezas decorrem da natureza aberta do sistema atmosférico e da sua extensa escala espacial, o que impõe limitações ao uso de abordagens puramente físicas para previsão de eventos hidrológicos extremos (Wen *et al.*, 2019; Zounemat-Kermani *et al.*, 2021).

Uma alternativa aos modelos atmosféricos é a aplicação de modelos estatísticos e baseados em dados para a predição de eventos futuros (Gao *et al.*, 2021). Dentre esses, cita-se o aprendizado de máquina ou *machine learning* como uma opção aos métodos tradicionais de predição de eventos hidrológicos (Chen *et al.*, 2023; Sit *et al.*, 2020). Esse é um ramo de estudo de inteligência artificial e tem como objetivo o desenvolvimento de algoritmos que permitam aos computadores aprenderem padrões e tendências a partir de uma grande quantidade de dados.

Os avanços no âmbito da tecnologia e nos algoritmos vem expandindo o uso da inteligência artificial, reduzindo o tempo necessário para o processamento dos dados e permitindo o estudo de padrões e séries cada vez mais complexas. No

entanto, ainda é comum as aplicações empregarem uma única estrutura de aprendizado, o que limita a predição de séries extensas e com muitos influenciadores (Parviz; Rasouli; Haghighi, 2023).

Para superar essa limitação, novas pesquisas estão analisando as vantagens do uso de modelos híbridos. Estes combinam diferentes arquiteturas de aprendizado com o objetivo de melhorar a capacidade preditiva (Gupta *et al.*, 2024; Thottungal Harilal; Dixit; Quattrone, 2024). Em estudos de séries temporais, esse processo é iniciado com a decomposição da série temporal original, desconstruindo-a em novas séries com características próprias. Em seguida, diferentes métodos de aprendizado de máquina são utilizados para prever cada uma dessas novas componentes. Ao final, as predições individuais de cada série são sobrepostas ou somadas, formando a predição final do modelo (He; Zhang; Chew, 2022). Exemplos podem ser encontrados nos trabalhos de Li *et al* (2019), Parviz; Rasouli e Haghighi (2023) e Chen *et al* (2023).

Outra abordagem para a construção de modelos híbridos é o uso de métodos de aprendizado por conjunto ou *ensemble* (Zounemat-Kermani *et al.*, 2021). Estas técnicas de aprendizado de máquina propõem uma análise linear ou não-linear para a combinação de múltiplos modelos base ou arquiteturas (*base learners* ou *weak learners*) para a criação de um melhor modelo preditivo (Cha Zhang; Ma, 2012; Ganaie *et al.*, 2022). Os *base learners* podem ser selecionados a partir de uma variedade de modelos de predição, que vão desde técnicas de regressão linear até abordagens mais sofisticadas, como as redes neurais.

Os métodos de aprendizado por conjunto mais utilizados são os do tipo *Bagging*, *Stacking*, *Boosting* e *Dagging*. A grande vantagem da adoção de técnicas de *ensemble* está no processo de busca das possíveis soluções de forma paralela, avaliando a qualidade dos modelos individuais antes de combiná-los para a produção de um modelo preditivo. Dessa forma, o aprendizado por conjunto produziria um modelo combinado de melhor qualidade e mais robusto, com menor variação entre as predições e que alcançaria melhor desempenho do que a adoção de um modelo individual (Zounemat-Kermani *et al.*, 2021, Ganaie *et al.*, 2022; Amini; Dolatshahi; Kerachian, 2022).

Em comparação com a abordagem padrão para a construção de modelos híbridos, o uso de métodos *ensemble* em análises de séries temporais permitiria a utilização de múltiplas arquiteturas para a predição de cada subcomponente da decomposição. Assim, perante a problemática da predição das precipitações e sua

modelagem, junto ao atual desenvolvimento e crescimento de técnicas de *machine learning* e *ensembles*, questiona-se: o uso das técnicas de *ensemble* para a elaboração de modelos híbridos com redes neurais poderia promover a produção de melhores estimativas de precipitações decendiais? O período definido de 10 dias para as predições das precipitações é particularmente útil para o processo de tomada de decisão de médio prazo, favorecendo a adoção de medidas de resposta (National Oceanic and Atmospheric Administration, 2023).

Considerando o potencial das associações entre técnicas de aprendizado de máquina, esta pesquisa avaliou o efeito do emprego do aprendizado por conjunto de redes neurais aplicadas a séries decompostas de precipitação decendial. Para isso, realizou-se a modelagem dos dados de duas estações pluviométricas localizadas no estado do Paraná, selecionadas por apresentarem padrões de climáticos e de precipitações distintos. Tal escolha visou não apenas testar o desempenho do modelo híbrido em diferentes condições climáticas, mas também permitir uma avaliação mais abrangente da generalização da metodologia. Os resultados obtidos foram comparados com os de modelos únicos, de forma a verificar os ganhos decorrentes da estratégia de associação.

## 1.2 JUSTIFICATIVA


### 1.2.1 Relevância do Tema

Chuvas intensas em curtos períodos causam impactos significativos na sociedade e no ambiente, com o risco de perdas de vidas, danos estruturais e econômicos (He; Zhang; Chew, 2022). A falta de planejamento para eventos extremos aumenta os riscos e danos causados por desastres naturais relacionados às chuvas, como enchentes e deslizamentos de terra.

O Atlas Digital de Desastres no Brasil, disponibilizado pelo Ministério da Integração e do Desenvolvimento Regional (MDR) (2024), traz um resumo dos registros de desastres no país e suas unidades da federação. Segundo as informações do relatório digital, os desastres hidrológicos nos municípios brasileiros totalizaram 25,93 mil registros dentre 1991 e 2023. Esses totalizaram 4286 óbitos e danos materiais totais aproximados de 120 bilhões de reais e de prejuízos públicos e privados somados de 150,19 bilhões de reais.

Com as mudanças climáticas, esperam-se alterações na frequência, intensidade e/ou duração de eventos climáticos extremos (Ku wajima *et al.*, 2019; Silva; Costa, 2018). Segundo o infográfico do relatório pelo Painel Intergovernamental sobre Mudanças Climáticas (IPCC) (2023), apresentado na Figura 1, a variação da temperatura global, impulsionado pela urbanização, irá ocasionar o aumento da temperatura do dia mais quente e da precipitação do dia mais chuvoso. Em especial, verifica-se um potencial de aumentos de temperatura e precipitação para a região sul do Brasil.

**Figura 1** – Simulação da mudança de temperatura e precipitação média anual em relação ao período pré-industrial em três cenários



Fonte: adaptada de IPCC (2023)

Assim, a aplicação de modelos para as previsões das precipitações torna-se fundamental na engenharia, colaborando para planejamento de obras quanto para a gestão dos recursos hídricos. Os modelos permitem estimar com maior precisão a

quantidade e intensidade das chuvas esperadas em determinada região, facilitando o estudo de cenários e na adoção de medidas de redução e mitigação de danos (Ridwan *et al.*, 2020; Chen *et al.*, 2023). Além disso, previsões mais confiáveis desempenham papel estratégico em ações de adaptação e preparação da sociedade frente a eventos extremos, uma vez que favorecem o ajuste de sistemas urbanos, produtivos e ambientais às novas condições impostas pelas mudanças climáticas.

No campo da engenharia civil, compreender e prever os volumes de chuva é essencial para garantir o bom funcionamento e a segurança de diversas infraestruturas. O dimensionamento de sistemas de drenagem, por exemplo, depende diretamente da estimativa da intensidade, duração e frequência das precipitações. Essas informações influenciam projetos como redes pluviais, bueiros, galerias, canais, pavimentações, muros de contenção, vertedouros e barragens. Além disso, a previsão de chuvas também orienta o planejamento de edificações, pontes e transportes (terrestres, aéreos e marítimos) (Ridwan *et al.*, 2020; Sene, 2010).

Devido à complexidade dos fenômenos atmosféricos e suas inter-relações, ainda há muitas incertezas na elaboração de modelos físicos para a previsão climatológica. Logo, o desenvolvimento de modelos de predição de chuva com base em modelos estatísticos agiliza a tomada de decisão e reduz os riscos e impactos derivados das chuvas intensas. Como vantagens dos modelos estatísticos, esses permitem o processamento de grandes volumes de dados e reduzem a necessidade da caracterização detalhada do ambiente atmosférico (Bauer; Thorpe; Brunet, 2015; Chen *et al.*, 2023; Wen *et al.*, 2019; Zounemat-Kermani *et al.*, 2021).

Dentro do contexto da modelagem, o uso de métodos de *machine learning* e *deep learning* torna-se relevante devido a sua capacidade de processar grandes séries de dados contínuos e devido a sua adaptabilidade. A programação e otimização dos algoritmos permitem o ágil treinamento para novas séries, facilitando a atualização dos modelos frente a novos dados ou ainda a modelagem para outras localidades (Gao *et al.*, 2021). Em conjunto, tem-se também os modelos híbridos, como os que se utilizam de técnicas de aprendizado por conjunto. Esses são considerados mais flexíveis, visto integrarem a capacidade de múltiplos modelos individuais, favorecendo a modelagem de problemas de alta complexidade (Kyriakides; Margaritis, 2019).

### 1.2.2 Lacuna do Conhecimento e Aspecto de Ineditismo

Para definir a lacuna do conhecimento e o aspecto de ineditismo da proposta, realizou-se uma revisão de forma sistemática. Maiores detalhes sobre o processo e resultados obtidos estão apresentados na seção 2.5 - Estado da Arte.

Na análise realizada, observou-se que o emprego de técnicas de associação por conjunto em modelos de aprendizado profundo aplicado a séries decompostas de precipitações é recente. Foram identificados 46 artigos relevantes ao tema, publicados a partir de 2016. Destes, apenas três apresentaram aplicações com modelos híbridos que combinam múltiplas arquiteturas de predição por meio de estratégias de ensemble. Nesses estudos, os resultados quanto à eficácia das associações foram divergentes (Garai *et al.*, 2024; Khairudin *et al.*, 2024; Parviz; Rasouli; Haghghi, 2023).

Considerando o limitado número de estudos sobre o tema e visando o aspecto do ineditismo, buscou-se avaliar a alteração na capacidade preditiva gerada pelo uso de técnicas de associação por conjunto em múltiplos níveis em séries decompostas de precipitações decendiais (10 dias). A abordagem visou aproveitar-se de diferentes modelos de redes neurais para a predição de cada subcomponente da série decomposta, em contraste com a estratégia convencional de selecionar apenas o modelo com a melhor métrica de desempenho.

### 1.3 HIPÓTESE DA PESQUISA

Frente a lacuna de pesquisa identificada e à revisão de forma sistemática realizada, fixou-se como hipótese principal para pesquisa que o uso de técnicas de associação do tipo *Stacking* de redes neurais favorece a predição das precipitações decendiais. Em conjunto, também se avaliou os pressupostos: (a) a decomposição das séries históricas melhora os modelos de predição; (b) as arquiteturas de aprendizado podem ser associadas em diferentes níveis para a predição de precipitações decendiais (c) as associações do tipo *Stacking* contribuem para o ganho de desempenho preditivo (d) os ganhos obtidos justificam o aumento do tempo e processamento associados ao uso de técnicas de associação e aprendizado profundo.

## 1.4 QUESTÃO DE PESQUISA

Perante a problemática da previsão das precipitações decendiais e sua modelagem, e junto ao atual desenvolvimento e crescimento de técnicas de aprendizado de máquina, questiona-se: O uso da decomposição pode favorecer a construção desses modelos? Como as estruturas dos modelos afetam a sua capacidade preditiva? Seria possível associar diferentes modelos de aprendizado profundo para melhorar as previsões? Qual nível de associação dos modelos produziria as melhores previsões?

A partir da construção do pensamento realizado, delimitou-se como questão principal de pesquisa: a associação entre diferentes arquiteturas de redes neurais artificiais pode contribuir para aprimorar a acurácia da previsão de precipitações decendiais?

## 1.5 OBJETIVOS

O objetivo da pesquisa foi avaliar a capacidade preditiva da associação de modelos de redes neurais aplicados às séries decompostas de precipitação decendial.

### 1.5.1 Objetivos Específicos

Para atingir esse objetivo principal, estabeleceram-se os seguintes objetivos específicos:

- i) Avaliar o potencial da decomposição da série temporal como estratégia para melhorar a representação da precipitação decendial em modelos de redes neurais.
- ii) Compreender a influência da arquitetura e da estratégia de recomposição sobre a capacidade de previsão de redes neurais aplicadas às componentes da série de precipitação.
- iii) Analisar os efeitos das estratégias por associação (*ensembles*) sobre o desempenho preditivo dos modelos, considerando diferentes níveis de combinação.
- iv) Identificar variações no desempenho preditivo dos modelos ao longo das estações do ano na previsão da precipitação decendial.

- v) Examinar a relação entre o desempenho desses modelos e o tempo de processamento necessário à sua execução.

## 1.6 DELIMITAÇÃO DA PESQUISA

Tendo em vista os diversos modelos de aprendizado de máquina existentes e em constante desenvolvimento, esta pesquisa foi limitada ao uso de rede neurais recorrentes e a técnicas de aprendizado por conjuntos heterogêneos do tipo *Stacking*. Essa escolha foi fundamentada na revisão de forma sistemática realizada (2.5 - Estado da Arte), a qual se identificou uma lacuna na aplicação conjunta dessas abordagens à modelagem da precipitação em escala decenal, especialmente em séries previamente decompostas.

Devido à natureza do fenômeno físico estudado, também se considerou o impacto do clima local no processo de modelagem e eficiência de cada modelo. Assim, foi delimitado o uso de dados climáticos da região sul do Brasil, em específico do estado do Paraná.

## 1.7 DEFINIÇÃO DOS PRINCIPAIS TERMOS

Para essa pesquisa, as precipitações são consideradas os produtos líquidos da condensação do vapor de água que caem das nuvens, na forma de chuva. Esse conceito é uma adaptação do proposto pela Organização Mundial de Meteorologia (2008), visto as chuvas serem o principal tipo de precipitação no Brasil. A quantidade total de precipitação que atinge o solo em um período discreto será expressa em termos de altura vertical da coluna de água, a qual cobriria uma projeção horizontal da superfície. A unidade de medida da precipitação é a profundidade linear, em milímetros (volume/área).

A decomposição das séries temporais refere-se a uma técnica de pré-processamento, com a aplicação de filtros para decompor a série ou sinal original em subcomponentes intrínsecos. Estas novas componentes são mais lineares e apresentam diferentes características de frequência. As séries originais podem ser decompostas em padrões de sazonalidade, tendência e resíduo, ou em funções de modo intrínseco (IMFs) (Tebong *et al.*, 2023; Wen *et al.*, 2019).

Aprendizado de máquina ou *machine learning* é um ramo de estudo de

inteligência artificial. Essa objetiva o desenvolvimento de algoritmos e aplicação de técnicas que permitam aos computadores aprenderem padrões e tendências a partir de uma grande quantidade de dados

As redes neurais artificiais ou *Artificial Neural Networks* (ANN) são redes baseadas na transmissão de informações entre neurônios biológicos. Essas são compostas por diversos neurônios distribuídos em camadas (Pouyanfar *et al.*, 2018). A depender dos dados de entrada, os neurônios serão ativados ou desativados, realizando a análise de classificação ou regressão proposta. Ao longo do aprendizado, os pesos desses neurônios são calibrados, aumentando a acurácia das análises (Sit *et al.*, 2020).

*Deep learning*, ou aprendizado profundo, é um subcampo do aprendizado de máquina. Ele se baseia na utilização de arquiteturas compostas por múltiplas camadas de processamento, organizadas de forma hierárquica (Sit *et al.*, 2020).

As redes neurais recorrentes ou *Recurrent Neural Networks* (RNN) são redes neurais com mais de três camadas, apresentando uma camada recorrente. A saída (*output*) de um neurônio pode ser transmitida tanto para neurônios de outras camadas quanto para a mesma camada oculta em instantes subsequentes, caracterizando a recorrência temporal. Logo, conseguem transportar informações aprendidas de um momento para o próximo, mantendo uma memória interna (Pouyanfar *et al.*, 2018; Shrestha; Mahmood, 2019). As redes neurais recorrentes são consideradas arquiteturas de aprendizado profundo pois processam informações em múltiplas etapas, sendo organizadas com múltiplas camadas ocultas. Assim, aprendendo padrões complexos e a dependência temporal dos dados sequenciais.

Os métodos de aprendizado *ensemble* ou de associação por conjunto são técnicas de aprendizado de máquina para a combinação linear ou não linear de múltiplos modelos ou predições (*base learners*). Tem a finalidade de otimizar e criar melhores modelos híbridos, também sendo nomeados como métodos por agrupamento (Cha Zhang; Ma, 2012).

## 1.8 ESTRUTURA DA TESE

A tese está estruturada em cinco capítulos. No Capítulo 1 apresenta a contextualização do tema investigado, incluindo o cenário atual em que está inserido, sua relevância e o problema de pesquisa a ser respondido. Também são expostos os

objetivos gerais e específicos do estudo.

O Capítulo 2 consiste em uma revisão da literatura relacionada ao tema, abrangendo os fundamentos sobre precipitação, modelagem de séries temporais, redes neurais profundas, técnicas de aprendizado por conjunto, além de um levantamento de forma sistemática do estado da arte.

O Capítulo 3 descreve os procedimentos metodológicos adotados e os locais de estudo. São detalhadas e justificadas as escolhas metodológicas, as hipóteses formuladas e processos executados: a) tratamento e processo de decomposição das séries temporais; b) configuração e treinamento das redes neurais; c) construção dos modelos híbridos e modelos comparativos; d) análise da eficiência dos modelos com o uso das métricas de performance; e) locais de estudo

O Capítulo 4 apresenta e discute os resultados obtidos. São analisadas a eficácia da decomposição em etapas, a capacidade preditiva dos modelos elaborados, o desempenho conforme as estações do ano e a comparação com o estado da arte. Ao final, contrapõe-se a hipótese de pesquisa com os achados obtidos e com evidências de estudos semelhantes.

O Capítulo 5 expõe as conclusões da pesquisa, incluindo a validação ou refutação da hipótese inicialmente proposta, bem como a resposta à questão de pesquisa. São também discutidas as principais limitações, os avanços metodológicos e científicos alcançados e sugestões para investigações futuras.

## 2 REVISÃO DE LITERATURA

### 2.1 PRECIPITAÇÕES

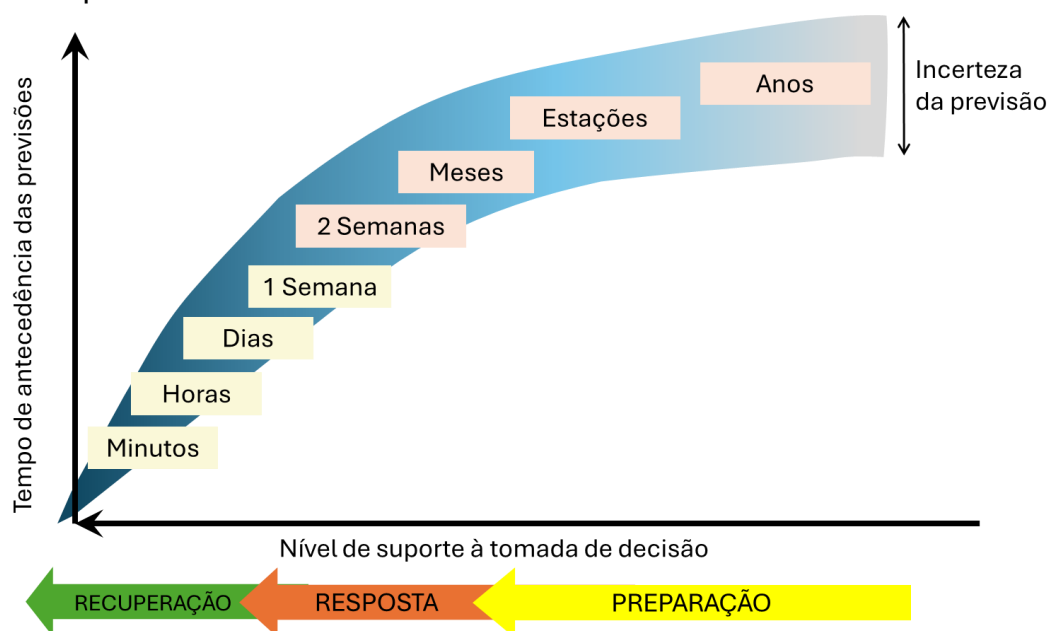
O conhecimento e a compreensão do fenômeno da precipitação são necessários para quantificar a sua magnitude e da probabilidade de ocorrência, estimar as vazões resultantes do escoamento superficial e avaliar a variação da disponibilidade hídrica de uma região (Sit *et al.*, 2020; He; Zhang; Chew, 2022). No Brasil, a chuva é o principal tipo de precipitação, exercendo impactos diretos no dimensionamento e a operação de infraestruturas, a gestão dos recursos hídricos e as atividades agrícolas.

A medição das chuvas pode ser realizada com o uso de equipamentos *in situ*, como os pluviômetros ou pluviógrafos, ou ainda serem estimadas com o uso de algoritmos. Por padrão, realiza-se a medição das alturas totais precipitadas em intervalos discretos de tempo, permitindo assim a análise do total precipitado, sua duração e a variação das intensidades durante o fenômeno (World Meteorological Organization, 2008; Maity, 2022; Sene, 2010).

Segundo Rakhecha e Singh (2009), os modelos de previsão meteorológica são divididos em três escalas temporais: curta, média e longa previsão. Os modelos de curta previsão operam para realizar estimativas para as próximas horas ou até 3 dias futuros. Já os de médio período estimam os próximos 4 a 10 dias, sendo úteis para planejamentos e prever anomalias dos elementos climáticos em relação às médias de longo prazo. As previsões de longo período, superiores a 10 dias, apresentam maior importância para a gestão de recursos hídricos e, usualmente, focam na quantidade total de precipitação esperada em uma estação ou ano (Rakhecha; Singh, 2009).

Segundo relatório do Conselho Consultivo Científico da Administração Nacional Oceânica e Atmosférica dos Estados Unidos (NOOA, 2023), tais escalas ou tempos de antecedência das previsões influenciam na aplicabilidade dos modelos para a tomada de decisão. Na Figura 2, expõe-se um esquema sobre a relação entre ambos e, também, quanto a incerteza das previsões.

**Figura 2** – Relação entre tempo de antecedência da previsão, suas incertezas e seu nível de suporte à tomada de decisão



Fonte: adaptado de NOAA (2023)

Como representado na Figura 2, as previsões de médios e longos períodos são utilizadas para decisões em nível de resposta e preparação aos efeitos dos fenômenos climatológicos identificados. Sene (2010) complementa que não há delimitações ou regras bem definidas sobre quais escalas de tempo deverão ser utilizadas nos modelos e previsões. Segundo o autor, o período escolhido será afetado pelo objetivo do estudo e projeto. O Quadro 1 traz alguns exemplos de aplicações das previsões meteorológicas e as escalas espaciais e tempos de antecedência usuais utilizados.

Diversos métodos já são empregados para a realização de previsões meteorológicas e precipitações. As técnicas de *Nowcasting* ou previsão imediata são aquelas que preveem o tempo em uma janela de 0 a 6 horas, utilizando a extrapolação do movimento observado em radares meteorológicos ou dados de satélites sobre a intensidade da chuva. Essas podem ou não empregar resultados de *Numerical Weather Prediction* (NWP) e envolver a extrapolação manual ou automatizada de outros parâmetros meteorológicos, como névoa e temperatura do ar, e a evolução de tempestades tropicais, como furacões, ciclones e tufões (Bauer; Thorpe; Brunet, 2015; Waqas *et al.*, 2024).

**Quadro 1** – Exemplos de escalas temporais e de tempo de antecedência da previsão meteorológica em função da aplicação

Aplicação	Escala Espacial	Tempo de antecedência da previsão
Alerta de Secas	Regional, nacional ou continental	Varia com o tipo de seca, de dias a meses, possivelmente até sazonal.
Fenômenos ecológicos	Local, bacia hidrográfica ou por região costeira	De horas a dias para poluentes, meses para fenômenos maiores.
Alerta de Crise Alimentar	Regional, nacional ou continental	Sazonal, com previsão antes da safra principal.
Alerta de Cheias e Inundações	Sub-bacia, bacia hidrográfica ou regional	De minutos a horas para alagamentos, dias ou meses para rios maiores
Operações Hidrelétricas	Bacia hidrográfica ou regional	De horas para produção, até sazonal para grandes reservatórios.
Programação de Irrigação	Local, Bacia hidrográfica ou regional	De horas a dias para operações, sazonal para plantio.
Navegação	Rios, Lagos e reservatórios	Horas a dias para controle de tráfego e advertências de riscos.
Incidentes de Poluição	Sub-bacia ou bacia hidrográfica	Minutos a dias para incidentes químicos, meses para impactos ecológicos
Recursos Hídricos	Bacia hidrográfica ou regional	De horas a semanas para operações, décadas para mudanças climáticas
Abastecimento de Água	Bacia hidrográfica ou regional	De horas a meses para operações diárias e decisões de investimento
Infraestrutura de transporte	Local e regional	Horas a dias para operações e controle de tráfego, semanas para planejamento e manutenções
Planejamento urbano	Local e regional	De horas para alertas, dias para obras, meses para zoneamentos
Construção Civil	Local	De horas para a operação, a dias e semanas para o cronograma

Fonte: adaptado de Sene (2010) e complementado pela autora.

As técnicas conhecidas como Previsões Numéricas do Tempo (*Numerical Weather Prediction* - NWP) usam a modelagem tridimensional da atmosfera para prever o tempo em um período de 0 a 10 dias em modelos determinísticos ou de 0 a 15 dias ou sazonais caso sejam feitas com associações de modelos. Esse método inclui em suas análises a massa, o momento e a transferência de energia entre os continentes e oceanos.

Os modelos NWP empregam múltiplas observações, que incluem variáveis meteorológicas (temperatura, umidade, velocidade/direção do vento e pressão barométrica), da qualidade do ar (gases e aerossóis.), da superfície terrestre (relevo, tipo de solo, umidade e temperatura do solo, cobertura ou uso e ocupação do solo) e do oceano (como temperatura da superfície do mar e altura significativa de ondas) (Haupt *et al.*, 2017). Segundo Brotzge *et al.* (2023), uma etapa crítica da aplicação dos modelos NWP é a redução das escalas temporais e espaciais dos dados

observados e o ajuste estatístico dos resultados, garantindo que esse atenda as necessidades específicas do usuário.

Já os métodos estatísticos são as técnicas baseadas em regressões múltiplas, análises de correlação e outras metodologias que relacionam condições meteorológicas futuras a indicadores ou preditores, incluindo séries históricas e seus padrões. São empregados para predições em escalas de tempo semanais, mensais ou superiores (Waqas *et al.*, 2024).

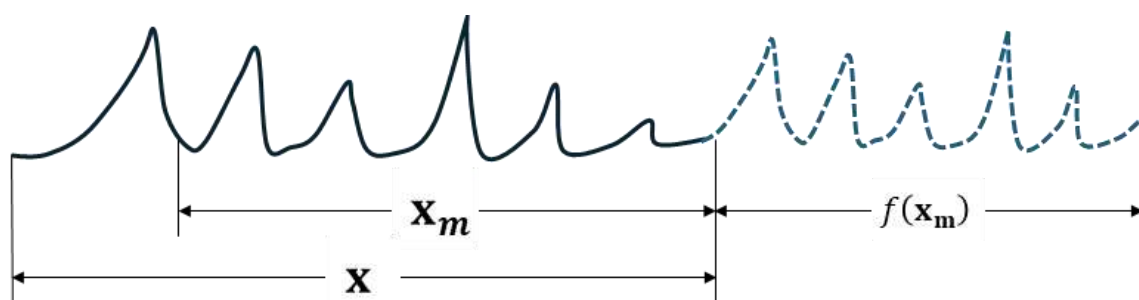
## 2.2 MODELAGEM DE SÉRIES TEMPORAIS

As séries temporais podem ser definidas como uma sequência de observações ordenadas e dependentes ao longo do tempo. A coleta contínua das informações climáticas produz séries temporais que auxiliam no entendimento da variação temporal dos fenômenos (Joseph *et al.*, 2018; Maity, 2022).

Caso as propriedades estatísticas de uma série temporal mudarem ou variarem com o tempo, ela é definida como uma série temporal não estacionária (Eatwell; Milgate; Newman, 1990; Haben; Voss; Holderbaum, 2023). Tal condição está presente na maioria das séries climatológicas, devido à natureza complexa de seus fenômenos. Essas flutuações e mudanças aleatórias ou graduais ao longo das séries dificultam a sua modelagem e predição.

Considerando uma série temporal original em  $\mathbf{x} = [x_1, x_2, \dots, x_{n-1}, x_n]$   $\mathbf{x} \in \mathbb{R}^{n \times 1}$ , o objetivo da predição de séries temporais é que, dada uma janela exploratória com  $m$  dados  $\mathbf{x}_m = [x_{n-m+1}, x_{n-m+2}, \dots, x_{n-1}, x_n]$ , seja possível prever os próximos  $d$  elementos da série como  $f(\mathbf{x}_m) = [x_{n+1}, x_{n+2}, \dots, x_{n+d}]$  (Brockwell; Davis, 2002; Chatfield, 2000). A Figura 3 apresenta uma esquemática desse objetivo, a partir da representação das séries contínuas de  $\mathbf{x}$  e sua fração  $\mathbf{x}_a$  a ser empregada para a predição da série futura  $f(\mathbf{x}_m)$ .

**Figura 3** – Predição uma série temporal  $f(x_m)$  com base nos dados da série  $x$

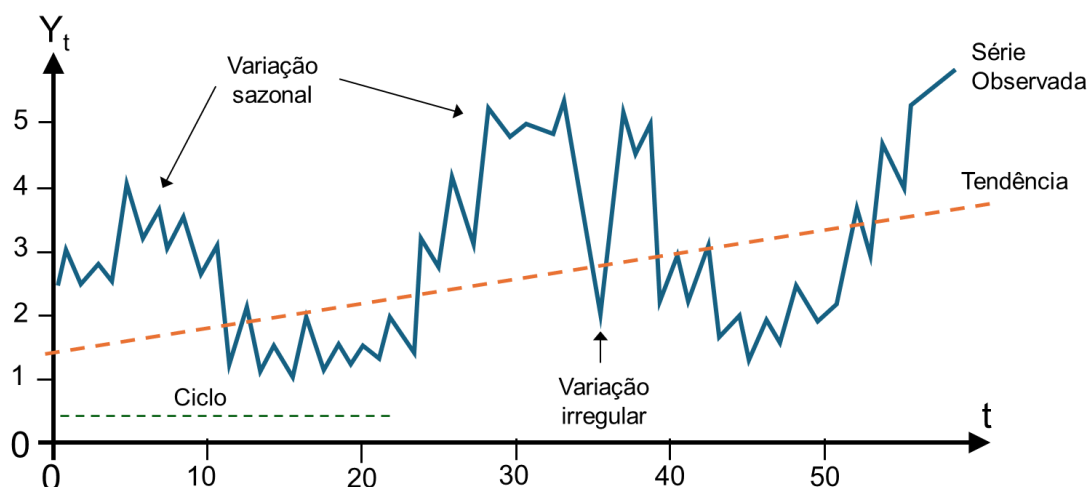


Fonte: a própria autora

Neste contexto, a função  $f(x_m)$  representa a relação entre os valores da série temporal e as variáveis preditoras ou exploratória. A seleção da função dependerá do tipo de série temporal analisada, do objetivo da modelagem e das variáveis disponíveis. Entre os diferentes modelos matemáticos existentes, citam-se os modelos estatísticos, de regressões, de autorregressão (ARIMA), e até mesmo os baseados em aprendizado de máquina (Eatwell; Milgate; Newman, 1990; Chatfield, 2000; He; Zhang; Chew, 2022). De modo a aumentar o grau de detalhamento da modelagem, processos como a decomposição das séries podem adicionados às etapas iniciais de modelagem (Sohrabbeig; Ardakanian; Musilek, 2023).

A decomposição de séries temporais refere-se ao processo analítico de desmembramento dessa em suas componentes não observáveis, cada uma representando uma frequência ou padrão de variação temporal. Tais componentes incluem tendências de longo prazo, movimentos cíclicos, sazonalidade e variações residuais (Cleveland *et al.*, 1990; Dodge, 2010; Naskar; Naskar, 2023), representados na Figura 4 e definidos posteriormente nesta seção. O objetivo da decomposição é aprimorar a compreensão dos padrões presentes nos dados, visto tais comportamentos não serem imediatamente aparentes na série original.

**Figura 4** – Representação de uma série temporal e suas componentes



**Fonte:** adaptado de Dodge (2010)

Embora certas séries temporais possam não exibir estacionaridade no sentido tradicional, a decomposição proporciona uma análise mais detalhada das variações e padrões ao longo do tempo, facilitando assim sua modelagem e previsão. Além disso, a presença das componentes pode variar dependendo da dinâmica do fenômeno em observação e da escala temporal das medições (Hyndman; Athanasopoulos, 2021).

Tradicionalmente, as componentes são assumidas como mutualmente independentes, podendo ser especificadas com o uso de um modelo de decomposição aditiva. Uma série de precipitação  $\mathbf{p}$ , portanto, poderá ser estimada a partir da soma das suas componentes de tendência, sazonalidade e ruído (Equação (1)) (Cleveland *et al.*, 1990; Dodge, 2010):

$$\mathbf{p} = \mathbf{t} + \mathbf{s} + \mathbf{r} \quad (1)$$

em que  $\mathbf{t} = [t_1, t_2, t_3, \dots, t_n]$  é a série decomposta de tendência com  $\mathbf{t} \in \mathbb{R}^{n \times 1}$ ;  $\mathbf{s} = [s_1, s_2, s_3, \dots, s_n]$  é a série decomposta de sazonalidade com  $\mathbf{s} \in \mathbb{R}^{n \times 1}$ ; e  $\mathbf{r} = [r_1, r_2, r_3, \dots, r_n]$  é a série de resíduos com  $\mathbf{r} \in \mathbb{R}^{n \times 1}$ .

A tendência ( $\mathbf{t}$ ) refere-se a mudanças graduais, porém contínuas, na média de uma série temporal (Chatfield, 2000). De modo geral, pode ser entendida como a direção geral na qual uma série temporal está se deslocando ao longo de um período, aumentando ou diminuindo de forma linear ou não linear. As causas da tendência nas séries temporais climatológicas são alterações nas condições ambientais naturais ou ainda derivadas de ações antropogênicas. A avaliação da tendência de uma série é medida com o uso de testes não paramétricos como o de Mann-Kendall (Chatfield,

2000; Gozuyilmaz; Kundakcioglu, 2021; Haben; Voss; Holderbaum, 2023)

A sazonalidade ( $s$ ) é uma propriedade de séries temporais nas quais os mesmos valores ou valores semelhantes são repetidos após um intervalo de tempo (Haben; Voss; Holderbaum, 2023; Joseph *et al.*, 2018). Tal característica é esperada em séries de precipitação de escalas mensais e anuais, ocasionadas pelas estações do ano.

O resíduo ( $r$ ) refere-se à componente restante do processo de decomposição. Esse representa as flutuações irregulares e imprevisíveis na série temporal, ou seja, as características estocásticas da série original. Tais variações aleatórias podem surgir de diversos fatores, como erros de medição, variabilidade natural ou influências externas (Dodge, 2010; Joseph *et al.*, 2018; Maity, 2022).

Em conjunto as essas três componentes, pode-se incluir a presença de movimentos cíclicos. Essas são flutuações recorrentes, sobrepostas à tendência, estando associadas a fenômenos climáticos periódicos superiores a um ano (Chatfield, 2000), como oscilações naturais, variações na atividade solar, padrões de circulação atmosférica ou oscilações oceânicas, como El Niño e La Niña. Devido à necessidade de um período extenso para sua identificação, os métodos de decomposição comumente utilizados não conseguem separar os movimentos cíclicos das componentes de tendência e sazonalidade (Joseph *et al.*, 2018; Maity, 2022).

A decomposição também pode ser realizada com o desmembramento da série original em funções de modo intrínseco (IMFs), abrangendo diferentes escalas de tempo e frequências. Nessa situação, a série original de precipitações  $p$  será decomposta como sendo a soma das componentes IMFs (Equação (2)) (Wu; Huang, 2009):

$$\mathbf{p} = \sum_{i=1}^n \mathbf{IMF}_i + \mathbf{r} \quad (2)$$

em que a  $\mathbf{IMF}_i$  é a  $i$ -ésima função de modo intrínseco da série de dados  $\mathbf{p}$ ;  $\mathbf{r}$  é o resíduo da série temporal  $\mathbf{p}$ .

A quantidade de funções IMFs a serem identificadas em uma série temporal não é fixa, variando a depender da complexidade dos padrões observados. Ao serem criadas, as IMFs são ordenadas segundo a frequência, iniciando com a componente mais oscilatória (maior frequência ou com variação de curto prazo) até as de menos oscilação (menor frequência ou variação de longo prazo). O número total de

componentes afetadas por mistura de modos será minimizado no processo de decomposição, a fim de reduzir a quantidade de componentes IMFs. Mesmo com esse processo, as decomposições em IMFs ainda não são capazes de excluir a característica estocástica da série original, gerando uma componente residual (Wu; Huang, 2009).

O uso de técnicas que decompõem as séries temporais em IMFs é comum no processamento de sinais acústicos, mas também já vem sendo aplicado para estudos climatológicos (Ali *et al.*, 2020; Barge; Sharif, 2016; Peng *et al.*, 2021). Dentre as técnicas mais utilizadas está a decomposição em modos empíricos (*Empirical Mode Decomposition* - EMD) e suas adaptações. No entanto, sua aplicação em modelos híbridos é dificultada pela variabilidade no número de IMFs geradas, que muda conforme cada série temporal (Barge; Sharif, 2016; Yu; Zhang; Singh, 2018), aumentando a complexidade para a criação de algoritmos capazes de se adaptar a essas condições.

Embora alternativas, como a Transformada *Wavelet* também possam ser utilizadas para decompor séries em múltiplas escalas temporais, o número de componentes obtidos depende do nível de decomposição adotado e do tamanho da série, não sendo fixo por definição (Guo *et al.*, 2023; Li; Wang; Qiu, 2019). Assim, apesar de mais controlável, essa abordagem também pode apresentar desafios na padronização da estrutura de entrada para modelos preditivos baseados na associação de técnicas e com o aprendizado de máquina.

### 2.2.1 Técnicas de decomposição de séries temporais

Considerando uma série temporal original  $\mathbf{p} = [p_1, p_2, \dots, p_{n-1}, p_n]$ , em que  $\mathbf{p} \in \mathbb{R}^{n \times 1}$ , esta pode ser decomposta de forma aditiva (Equação (1)) (Sohrabbeig; Ardakanian; Musilek, 2023). Para o entendimento do processo de decomposição, tem-se, portanto, que um elemento  $p_i$  poderá ser previsto como a soma das respectivas componentes nas séries de tendência, sazonalidade e resíduo, como indicada na Equação (3) (Dodge, 2010; Sohrabbeig; Ardakanian; Musilek, 2023).

$$p_i = t_i + s_i + r_i \quad (3)$$

em que  $t_i$  representa a  $i$ -ésima componente da tendência;  $s_i$  representa a  $i$ -ésima componente da sazonalidade; e  $r_i$  representa a  $i$ -ésima componente do resíduo.

Para a realização da decomposição das séries temporais, é necessário a estimativa inicial dos conjuntos  $\mathbf{t}^o$ ,  $\mathbf{s}^o$  e  $\mathbf{r}^o$ . Para a determinação da componente  $t_i^o$ , podem ser empregadas aproximações mais simples, como o uso da média dos termos do vetor, ou por métodos mais elaborados, como a suavização local da série original por meio do STL (*Seasonal-Trend decomposition using Loess* (Cleveland *et al.*, 1990; Hyndman; Athanasopoulos, 2021)).

Para o processo pode-se utilizar uma estimativa simplificada da tendência, adotando-se um único valor constante para todo o conjunto  $\mathbf{t}^o$ . Esse é estimado como sendo equivalente à média dos valores de  $p_i$  da série original, como indicado pela Equação (4) (Hyndman; Athanasopoulos, 2021):

$$t^o = \frac{\sum_{i=1}^n p_i}{n} \quad (4)$$

Outra possibilidade é a determinação da tendência ao longo da série, como com a função LOESS (*Locally Estimated Scatterplot Smoothing*). Essa é uma técnica de suavização local que visa ajustar uma curva polinomial de baixa ordem a subconjuntos dos dados, utilizando ponderações baseadas na proximidade entre os pontos. Para cada posição ao longo da série, o LOESS seleciona uma vizinhança de pontos mais próximos e, dentro dessa janela, estima uma regressão local que representa a tendência dos dados naquela região (Cleveland *et al.*, 1990).

Caso seja feita a seleção pelo uso da função LOESS, espera-se uma maior precisão na identificação das tendências e, por consequência, das sazonalidades locais. Para isso, realiza-se uma análise sobre todos os valores  $p$  do conjunto, estimando valores de  $t_i^o$  individualmente para cada elemento. Define-se, então, uma dimensão  $q$  de valores  $p$  mais próximos de  $p_i$ , formando uma janela de vizinhança. Os pontos dentro dessa janela são ponderados com base em sua distância ao ponto central  $p$  e a função de peso  $W(u)$  é estabelecida a partir da distância normalizada entre  $p$  e ponto  $p_i$ , conforme as condições descritas na Equação (5) (Cleveland *et al.*, 1990):

$$W(u) = \begin{cases} (1 - u^3)^3 & \text{para } 0 \leq u < 1 \\ 0 & \text{para } u \geq 1 \end{cases} \quad (5)$$

sendo  $W(u)$  a função de peso baseada na distância normalizada  $u$ ;  $u$  é a distância normalizada entre o ponto  $p$  e o ponto  $p_i$ , sendo equivalente a  $\frac{|p-p_i|}{\lambda_q(p_i)}$ , e  $\lambda_q(p_i)$  é a distância máxima dentro da janela de vizinhança.

O peso ponderado para qualquer valor de  $p$  em uma janela pode ser definido com o uso da Equação (6) (Cleveland *et al.*, 1990):

$$v_i(p_i) = W \left( \frac{|p - p_i|}{\lambda_q(p_i)} \right) \quad (6)$$

em que  $v_i(p_i)$  é o valor ponderado atribuído ao ponto  $p_i$ .

Dessa forma, os pontos de  $p$  próximos à  $p_i$  recebem maiores pesos. Um polinômio local é ajustado aos pontos ponderados dentro da janela, empregando os pesos  $v_i(p_i)$  para a determinação da influência de cada ponto no ajuste. O modelo local ajustado fornece a estimativa da tendência  $t_i^o$  para o  $p_i$ . Repetindo este processo para todos os pontos da série temporal, obtém-se o conjunto inicial  $\mathbf{t}^o$ .

Conhecido os valores da tendência  $\mathbf{t}^o$ , estima-se um vetor de sazonalidade  $\mathbf{s}^o$  com base em uma média ou suavização dos valores  $(p_i - t_i^o)$  dentro da janela de periodicidade  $w$ . Para a análise com base na média, pode-se utilizar a relação explícita na Equação (7) (Brockwell; Davis, 2002; Chatfield, 2000; Hyndman; Athanasopoulos, 2021):

$$s_i^o = \frac{\sum_{i=1}^w (p_i - t_i^o)}{n} \quad (7)$$

em que  $s_i^o$  representa a  $i$ -ésima componente da sazonalidade, avaliada na iteração inicial  $o$ .

O vetor de resíduo  $\mathbf{r}^o$  é determinado pela diferença entre a série original e as estimativas iniciais de tendência e sazonalidade (Equação (8)) (Brockwell; Davis, 2002; Hyndman; Athanasopoulos, 2021).

$$\mathbf{r}^o = \mathbf{p} - \mathbf{t}^o - \mathbf{s}^o \quad (8)$$

Após a estimativa das componentes iniciais, o algoritmo realiza várias iterações para refinar os vetores  $\mathbf{r}$ ,  $\mathbf{s}$  e  $\mathbf{t}$  até que a convergência seja alcançada ou um número máximo de iterações seja atingido (Hyndman; Athanasopoulos, 2021).

Para a elaboração dos modelos de previsões com base em dados anteriores, Jiao e He (2024) recomenda a utilização de um processo de decomposição em etapas. Segundo os autores, essa abordagem evita o vazamento de dados (*data leakage*) durante o processo de calibração e validação. O *data leakage* ocorre quando informações futuras são inadvertidamente incluídas nos dados de entrada do modelo. Tal ocorrência leva a uma avaliação otimista do desempenho, comprometendo a

validade dos resultados obtidos. Esse tipo de erro é particularmente comum em séries temporais, como as de precipitação, nas quais os dados apresentam forte dependência sequencial. Quando a estrutura do modelo não é adequadamente definida, há o risco de que informações futuras estejam incorporadas aos dados de entrada, seja por sobreposição entre janelas de observação e previsão ou ainda por repetições indevidas ao longo do processo de calibração e validação.

Na abordagem de decomposição por etapas, a separação entre as subcomponentes  $\mathbf{t}$ ,  $\mathbf{s}$  e  $\mathbf{r}$  são realizadas com o uso da série original  $\mathbf{p}$  somente até o elemento  $p_i$ , ou seja, utilizando o vetor  $\mathbf{p}_i$ . A inclusão de um novo elemento  $i + 1$ , desencadeará um novo processo de decomposição, que utilizará o conjunto  $\mathbf{p}_{i+1}$ , e assim continuamente (Jiao; He, 2024). Desse modo, o processo de decomposição em etapas do conjunto original  $\mathbf{p} \in \mathbb{R}^{n \times 1}$  resultará nos vetores a seguir (Equação (9) e (10)):

$$\begin{bmatrix} \mathbf{p}_1 \\ \mathbf{p}_2 \\ \vdots \\ \mathbf{p}_i \\ \vdots \\ \mathbf{p}_n \end{bmatrix} = \begin{bmatrix} \mathbf{t}_1 \\ \mathbf{t}_2 \\ \vdots \\ \mathbf{t}_i \\ \vdots \\ \mathbf{t}_n \end{bmatrix} + \begin{bmatrix} \mathbf{s}_1 \\ \mathbf{s}_2 \\ \vdots \\ \mathbf{s}_i \\ \vdots \\ \mathbf{s}_n \end{bmatrix} + \begin{bmatrix} \mathbf{r}_1 \\ \mathbf{r}_2 \\ \vdots \\ \mathbf{r}_i \\ \vdots \\ \mathbf{r}_n \end{bmatrix} \quad (9)$$

Ou seja, que

$$\begin{bmatrix} [p_1] \\ [p_1, p_2] \\ \vdots \\ [p_1, p_2, \dots, p_{i-1}, p_i] \\ \vdots \\ [p_1, p_2, \dots, p_{N-1}, p_N] \end{bmatrix} = \begin{bmatrix} [t_1^1] \\ [t_1^2, t_2^2] \\ \vdots \\ [t_1^j, t_2^j, \dots, t_{i-1}^j, t_i^j] \\ \vdots \\ [t_1^n, t_2^n, \dots, t_{n-1}^n, t_n^n] \end{bmatrix} + \begin{bmatrix} [s_1^1] \\ [s_1^2, s_2^2] \\ \vdots \\ [s_1^j, s_2^j, \dots, s_{i-1}^j, s_i^j] \\ \vdots \\ [s_1^n, s_2^n, \dots, s_{n-1}^n, s_n^n] \end{bmatrix} + \begin{bmatrix} [r_1^1] \\ [r_1^2, r_2^2] \\ \vdots \\ [r_1^j, r_2^j, \dots, r_{i-1}^j, r_i^j] \\ \vdots \\ [r_1^n, r_2^n, \dots, r_{n-1}^n, r_n^n] \end{bmatrix} \quad (10)$$

em que  $t_i^j$  representa a  $i$ -ésima componente da tendência, avaliada na iteração  $j$ ;  $s_i^j$  representa a  $i$ -ésima componente da sazonalidade, avaliada na iteração  $j$ ; e  $r_i^j$  representa a  $i$ -ésima componente do resíduo, avaliada na iteração  $j$ .

### 2.3 MODELOS DE APRENDIZADO PROFUNDO

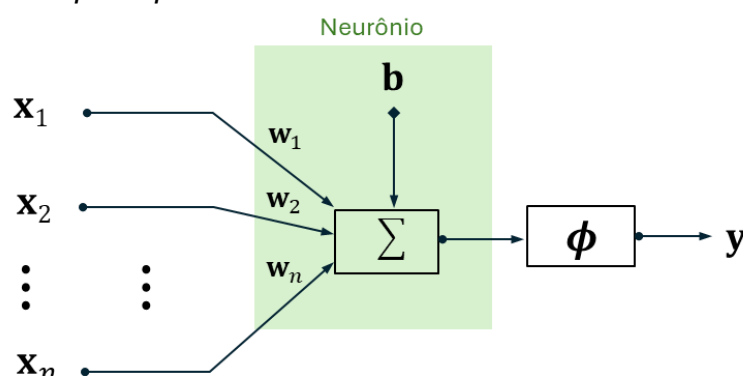
Aprendizado de máquina ou *machine learning* é um ramo de estudo de inteligência artificial que possui como objetivo o desenvolvimento de algoritmos e aplicação de técnicas que permitam aos computadores aprenderem padrões e tendências a partir de uma grande quantidade de exemplos. O potencial das técnicas

de aprendizado de máquina já é utilizado em diferentes âmbitos da engenharia, inclusive em estudos hidráulicos e hidrológicos (Mosaffa *et al.*, 2022; Shen; Chen; Laloy, 2021; Sit *et al.*, 2020).

Dentre as técnicas de aprendizado de máquina que já estão sendo aplicadas no estudo de séries temporais climatológicas, como as de precipitação, citam-se as com arquiteturas do tipo *Support Vector Machine* ou máquina de vetores de suporte (SVM), Redes Neurais Artificiais (ANN), Modelos Numéricos de Previsão do Clima (NWP), dentre outras (Camps-Valls *et al.*, 2021; Shrestha; Mahmood, 2019). Os principais avanços nessa área de pesquisa estão relacionados ao uso de novas técnicas de *machine learning*, a adoção da decomposição das variáveis de entrada, ou ainda o uso de novas tecnologias que agilizem e melhorem a medição das propriedades físicas ambientais (Bauer; Thorpe; Brunet, 2015; Shen; Chen; Laloy, 2021).

As redes neurais artificiais (ANN) são arquiteturas de aprendizado de máquina compostas por diversos neurônios distribuídos em camadas (Pouyanfar *et al.*, 2018). A depender dos dados de entrada, os neurônios presentes na camada respondem com diferentes níveis de ativação, conforme definido pela função de ativação utilizada, que determina o valor de saída de cada unidade com base em sua entrada ponderada. Ao longo do aprendizado, os pesos desses neurônios são calibrados, aumentando a acurácia das análises (Aggarwal, 2023). A Figura 5 apresenta uma esquemática da composição básica de um neurônio *Perceptron*.

**Figura 5** – Neurônio *perceptron*



**Fonte:** adaptado de Haykin (2009)

O *Perceptron* consiste em um neurônio que recebe múltiplas entradas  $x_1, x_2, \dots, x_n$ . Cada vetor de entrada  $x_i$  apresenta um peso  $w_i$ , que indica a importância

dessa entrada para o cálculo do vetor de saída  $\mathbf{y}$  (Equação (11)). Assim, uma combinação linear  $\mathbf{w}_i \cdot \mathbf{x}_i$  é realizada, e todos os produtos são somados e aplicados em uma função pré-definida para a determinação da saída  $\mathbf{y}$ , como indicado na Equação (11). A função de ativação  $\phi$  é responsável por introduzir não-linearidade, permitindo que ela aprenda e modele relações complexas entre entradas e saídas. Dentre os tipos mais utilizados estão a função sigmoide, tangente hiperbólica ( $\tanh$ ), degrau e unidade linear retificada (ReLU) (Fiorin *et al.*, 2011; Haykin, 2009; Aggarwal, 2023).

$$\mathbf{y} = \phi \left( \sum_{i=1}^n \mathbf{w}_i \mathbf{x}_i + \mathbf{b} \right) \quad (11)$$

em que  $\mathbf{y}$  é o vetor de saída do neurônio;  $\mathbf{x}_i$  é o vetor de entrada na posição  $i$ ,  $\mathbf{w}_i$  é o vetor peso para o vetor de entrada da posição  $i$ ;  $\mathbf{b}$  é o vetor viés para o função; e  $\phi$  é a função de ativação do neurônio.

Uma das principais limitações do *Perceptron* é a sua incapacidade de aprender funções lógicas não linearmente separáveis. De modo a aumentar a capacidade de processamento de dados e estudo de funções mais complexas, pode-se empregar mais neurônios por camadas e mais camadas ocultas, caracterizando um aprendizado profundo (Ahmed *et al.*, 2021; Haykin, 2009; Shrestha; Mahmood, 2019).

### 2.3.1 Aprendizado Profundo

*Deep learning*, ou aprendizado profundo, é um subcampo do aprendizado de máquina que se baseia no uso de redes neurais artificiais com múltiplas camadas organizadas de forma hierárquica (Sit *et al.*, 2020). Ao empilhar diversas camadas de processamento, essas arquiteturas são capazes de modelar relações complexas entre variáveis. Esse tipo de abordagem permite que o modelo identifique quais preditores são mais relevantes para explicar um fenômeno, ajustando os pesos internos por meio de algoritmos e otimizando a acurácia preditiva com base em dados de treinamento (Gharehbaghi, 2023; Zhang, A. *et al.*, 2021).

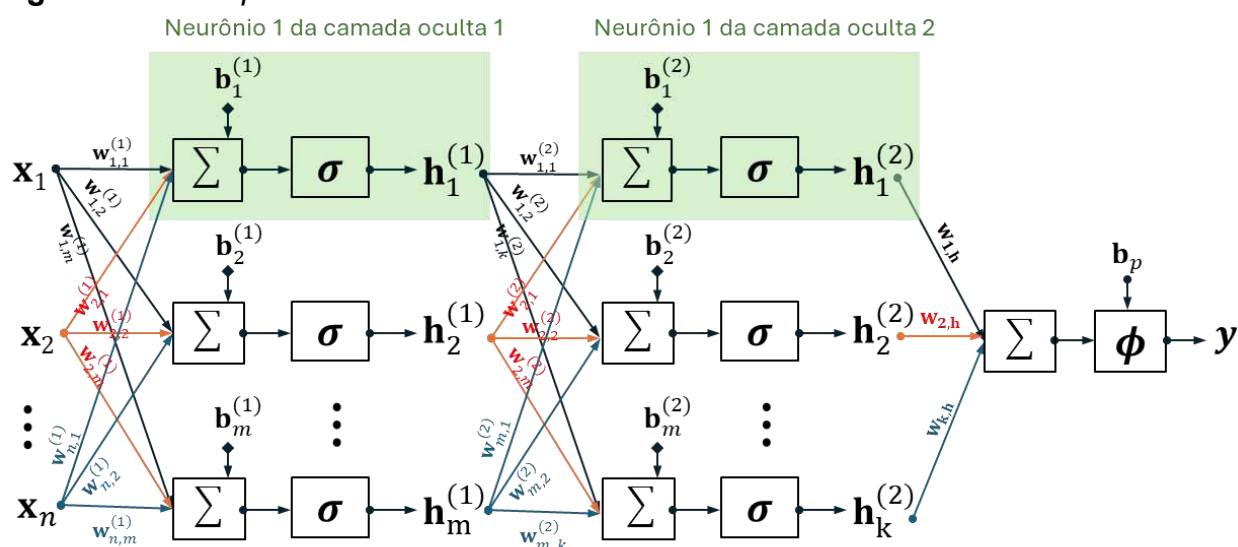
Segundo Gao *et al.* (2021) e Shrestha e Mahmood (2019), o uso de aprendizado profundo para a previsão de precipitações é vantajoso pois esse se enquadra como um problema de *big data*, ou seja, com uma grande quantidade de dados disponíveis e necessários para a sua estimativa. Esses conjuntos também estão em constante crescimento, de modo que os modelos de aprendizado profundo podem ser

atualizados com esses novos dados.

Outro ponto favorável é que as técnicas de *Deep Learning* são apropriadas para a resolução de modelos complexos e dinâmicos. A velocidade de inferência dos modelos de aprendizado profundo é superior que a dos métodos numéricos. Além de agilizar o processo como um todo, essa capacidade facilita a atualização dos modelos com dados recém observados, resultando em maior acurácia nas estimativas e melhor identificação das mudanças nos padrões climáticos(Gao *et al.*, 2021).

O *Perceptron* multicamada ou *multilayer perceptron* (MLP) é o modelo mais simples de arquitetura de aprendizado profundo. Neste modelo, a rede neural é composta por múltiplas camadas de neurônios do tipo *Perceptron*, em que cada neurônio presente em uma camada está conectado a todos os neurônios da camada seguinte (Figura 6) (Fiorin *et al.*, 2011; Haykin, 2009; Shrestha; Mahmood, 2019).

**Figura 6 – Perceptron Multicamada**



**Fonte:** a própria autora

A Figura 6 ilustra um MLP com duas camadas ocultas. Cada camada oculta tem múltiplos neurônios, e cada neurônio realiza cálculos baseados nas entradas recebidas dos neurônios da camada anterior. Para cada neurônio  $j$  na primeira camada oculta ( $\ell = 1$ ), a saída  $h_j^{(1)}$  é calculada pela soma ponderada das entradas  $x_i$  com os pesos correspondentes  $w_{i,j}^{(1)}$  e adicionando o viés  $b_j^{(1)}$ , aplicada a uma função de ativação  $\sigma$  (Haykin, 2009; Zhang, A. *et al.*, 2021).

$$\mathbf{h}_j^{(1)} = \sigma \left( \sum_{i=1}^n \mathbf{w}_{i,j}^{(1)} \mathbf{x}_i + \mathbf{b}_j^{(1)} \right) \quad (12)$$

em  $\mathbf{h}_j^{(1)}$  é a ativação do neurônio  $j$  na primeira camada oculta ( $\ell = 1$ );  $\mathbf{w}_{i,j}^{(1)}$  é o peso que conecta a entrada  $i$  ao neurônio  $j$  na primeira camada oculta;  $\mathbf{x}_i$  é o valor da  $i$ -ésima entrada;  $\mathbf{b}_j^{(1)}$  é o viés associado ao neurônio  $j$  na primeira camada oculta;  $\sigma$  é a função de ativação aplicada às somas ponderadas;  $n$  é o número total de entradas.

Para o neurônio  $k$  na segunda camada oculta ( $\ell = 2$ ), a entrada é o vetor de ativações da primeira camada  $\mathbf{h}_j^{(1)}$ . Dessa forma,  $\mathbf{h}_k^{(2)}$  é calculado por uma nova soma ponderada, a ser ativada pela função  $\sigma$ , como na Equação (13) (Haykin, 2009; Zhang, A. *et al.*, 2021).

$$\mathbf{h}_k^{(2)} = \sigma \left( \sum_{j=1}^m \mathbf{w}_{j,k}^{(2)} \mathbf{h}_j^{(1)} + \mathbf{b}_k^{(2)} \right) \quad (13)$$

em que  $\mathbf{h}_k^{(2)}$  é a ativação do neurônio  $k$  na segunda camada oculta ( $\ell = 2$ );  $\mathbf{w}_{j,k}^{(2)}$  é o peso que conecta o neurônio  $j$  da primeira camada oculta ao neurônio  $k$  da segunda camada oculta;  $\mathbf{b}_k^{(2)}$  é o viés associado ao neurônio  $k$  da segunda camada oculta; e  $m$  é o número de neurônios na primeira camada.

Finalmente, a saída da rede neural  $\mathbf{y}$  é modulada usando as ativações da segunda camada oculta, representada pela Equação (14) (Haykin, 2009; Zhang, A. *et al.*, 2021):

$$\mathbf{y} = \phi \left( \sum_{i=1}^k \mathbf{w}_{i,p}^{(3)} \mathbf{h}_i^{(2)} + \mathbf{b}_p^{(3)} \right) \quad (14)$$

em que  $\mathbf{w}_{i,p}^{(3)}$  é o peso que conecta o neurônio  $i$  da camada oculta ao neurônio  $p$  da camada de saída;  $\mathbf{h}_i^{(2)}$  é a ativação do neurônio  $i$  na segunda camada oculta ( $\ell = 2$ );  $\mathbf{b}_p^{(3)}$  é o viés associado ao neurônio  $p$  da camada de saída;  $k$  é o número de neurônios na camada oculta.

Todo esse processo pode ser também representado na forma implícita, considerando uma rede neural com  $\ell$  camadas, variando de  $i = 1$  até  $i = \ell - 1$ , a matriz de ativações  $\mathbf{H}^{(i)}$  pode ser calculada como (Zhang, A. *et al.*, 2021):

$$\mathbf{H}^{(i)} = \sigma(\mathbf{W}^{(i)}\mathbf{H}^{(i-1)} + \mathbf{B}^{(i)}) \quad (15)$$

em que  $\mathbf{H}^{(i)}$  é o vetor de ativações de todos os neurônios na camada  $i$ ;  $\mathbf{W}^{(i)}$  é a matriz que representa os pesos que conectam a camada  $i$  e  $i - 1$ ;  $\mathbf{H}^{(i-1)}$  é o vetor que contém as ativações de todos os neurônios da camada anterior  $i - 1$ ;  $\mathbf{B}^{(i)}$  é o vetor vieses para a camada  $i$ .

Dessa forma, tem-se o vetor de saída  $\mathbf{Y}$  da rede neural (Equação (16)), calculado em função dos pesos  $\mathbf{W}^{(\ell)}$  e das saídas  $\mathbf{H}^{(\ell-1)}$  (Haykin, 2009; Zhang, A. *et al.*, 2021).

$$\mathbf{Y} = \phi(\mathbf{W}^{(\ell)}\mathbf{H}^{(\ell-1)} + \mathbf{B}^{(\ell)}) \quad (16)$$

em que  $\mathbf{Y}$  é o vetor de saída da rede neural;  $\phi$  é a função de ativação aplicada à camada de saída;  $\mathbf{W}^{(\ell)}$  é o vetor de pesos entre a camada de saída  $\ell$  e  $\ell - 1$ ;  $\mathbf{H}^{(\ell)}$  é o vetor que contém as ativações de todos os neurônios da camada  $\ell - 1$ ;  $\mathbf{B}^{(\ell)}$  é o vetor com os vieses para a camada de saída .

Casolaro *et al.* (2023) destacou alguns dos avanços recentes e os problemas ainda existentes na aplicação de modelos de aprendizado profundo para as previsões de séries temporais. Em suas explicações, os autores descrevem o funcionamento dos principais tipos de arquiteturas de redes neurais atualmente empregadas, consideradas evoluções das redes *Perceptron* Multicamadas. Os autores citam como principais modelos aplicados as Redes Neurais Recorrentes (RNN), Redes de Estado de Eco, Memória Longa de Curto Prazo (LSTM), Unidades Recorrentes Fechadas (GRU), Rede Neural de Grafos, Redes Neurais Convolucionais, Redes Convolucionais Temporais e *Transformers*.

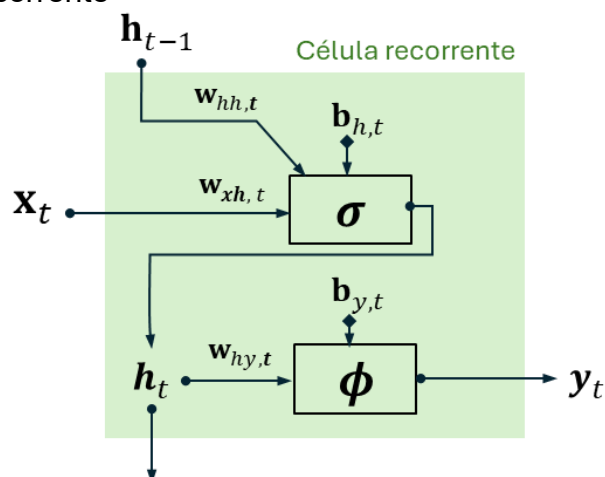
Sit *et al.* (2020) também realizou uma análise do estado da arte de aplicação de métodos de aprendizado profundo em estudos hidrológicos e gestão dos recursos hídricos. Os autores identificaram aplicações desses modelos em diferentes temas, principalmente em previsões de inundações, análises meteorológicas, uso e ocupação do solo e de qualidade da água. Dos artigos selecionados entre 2018 e 2019, a maioria empregou Redes Neurais Convolucionais, Rede Neurais Artificiais, e Rede Neurais Recorrentes, como as de Memória Longa de Curto Prazo e Unidade Recorrente Fechada. As aplicações tiveram como finalidade principal a previsão de séries temporais, classificação e regressões.

### 2.3.2 Redes neurais recorrentes

As Redes Neurais Recorrentes (*Recurrent Neural Networks* - RNN) são variações das redes neurais artificiais tradicionais, que incorporam uma célula de memória responsável por armazenar os valores de saída de cada célula. Dessa forma, tais valores poderão ser utilizados no aprendizado da próxima camada e nas interações subsequentes. Por essa razão, esse tipo de arquitetura e suas variações são comumente aplicadas para o estudo de dados sequenciais, em que pode haver correlação entre as componentes da série e a ordem desses importa (Casolaro *et al.*, 2023; Gao *et al.*, 2021; Zhang, A. *et al.*, 2021).

Nas redes neurais recorrentes, utiliza-se o termo “célula” para se referir à unidade funcional responsável por processar sequências de dados. Diferentemente dos neurônios presentes nas redes com *perceptrons*, as células recorrentes processam não apenas a entrada atual, mas também consideram o chamado estado oculto, que armazena informações de iterações anteriores, permitindo à rede capturar padrões temporais e dependências sequenciais (Haykin, 2009; Zhang, A. *et al.*, 2021). A Figura 7 expõe a configuração de uma célula recorrente padrão.

**Figura 7** – Célula recorrente



Fonte: a própria autora

Na célula recorrente apresentada, a entrada no tempo  $t$  é composta pelo vetor de características  $\mathbf{x}_t$  e um estado oculto  $\mathbf{h}_{t-1}$ , proveniente da iteração anterior. Essa segunda entrada é o que caracteriza a recorrência na arquitetura, permitindo que a rede armazene e reutilize informações passadas ao longo da sequência. As entradas  $\mathbf{x}_t$  e  $\mathbf{h}_{t-1}$  são multiplicadas pelas matrizes de pesos  $\mathbf{w}_{xh,t}$  e  $\mathbf{w}_{hh,t}$ , somadas a um termo

viés  $\mathbf{b}_{h,t}$  e ativadas pela função  $\sigma$ . O resultado é um novo estado oculto  $\mathbf{h}_t$ , que contém uma representação atualizada da memória da rede (Wüthrich; Merz, 2023; Yu *et al.*, 2019).

Esse novo estado oculto  $\mathbf{h}_t$  é então ponderado pelo peso  $\mathbf{w}_{y,t}$ , e processado pela função de ativação  $\phi$ , gerando o valor de saída  $\mathbf{y}_t$ . O funcionamento da célula recorrente pode ser expresso também por relações matemáticas na forma implícita, como indicado pelas equações (16) e (17) (Zhang, A. *et al.*, 2021):

$$\mathbf{H}_t^{(i)} = \sigma(\mathbf{W}_{xh}^{(i)} \cdot \mathbf{X}_t^{(i)} + \mathbf{W}_{hh}^{(i)} \cdot \mathbf{H}_{t-1}^{(i)} + \mathbf{B}_h^{(i)}) \quad (17)$$

$$\mathbf{Y}_t^{(i)} = \phi(\mathbf{W}_{hy}^{(i)} \cdot \mathbf{H}_t^{(i)} + \mathbf{B}_y^{(i)}) \quad (18)$$

em que  $\mathbf{H}_{t-1}^{(i)}$  e  $\mathbf{H}_t^{(i)}$  são vetores que contém os estados ocultos de todos os neurônios da camada  $i$  no tempo  $t - 1$  e  $t$ ,  $\mathbf{X}_t^{(i)}$  é a matriz dos dados de entrada da camada  $i$  no tempo  $t$ ,  $\mathbf{Y}^{(i)}$  é a saída da camada  $i$  da rede neural recorrente,  $\mathbf{W}_{xh}^{(i)}$ ,  $\mathbf{W}_{hh}^{(i)}$ ,  $\mathbf{W}_{hy}^{(i)}$  são as matrizes que representam todos os pesos,  $\mathbf{B}_h^{(i)}$  e  $\mathbf{B}_y^{(i)}$  são as matrizes com os vetores vieses,  $\sigma$  e  $\phi$  são as funções de ativação.

Considerando os processos realizados pela célula recorrente, tem-se que as entradas em cada instante  $t$  da série são processadas em conjunto com os estados ocultos das camadas anteriores. Dessa forma, permitindo a identificação de padrões sequenciais durante o processo de aprendizado. Apesar disso, mesmo com a presença de uma memória interna para o salvamento do estado oculto anterior, as RNNs apresentam baixa capacidade de identificar padrões de longo prazo (Gharehbaghi, 2023; Shrestha; Mahmood, 2019; Zhang, A. *et al.*, 2021).

O desempenho inferior em tarefas que exigem a captura de dependências temporais longas ocorre principalmente devido ao problema conhecido como "desaparecimento do gradiente" ou *vanishing gradient*. Neste, os gradientes associados a pesos de etapas temporais distantes tendem a serem reduzidos a valores muito baixos durante o treinamento por retropropagação. Como resultado, a rede tem dificuldade em ajustar os pesos adequadamente, levando à perda de informações sobre eventos passados que influenciam os estados futuros (Gharehbaghi, 2023; Mosaffa *et al.*, 2022).

De modo a superar essa limitação, outros modelos de células e de redes neurais recorrentes foram propostos, como as redes neurais de memória de curto

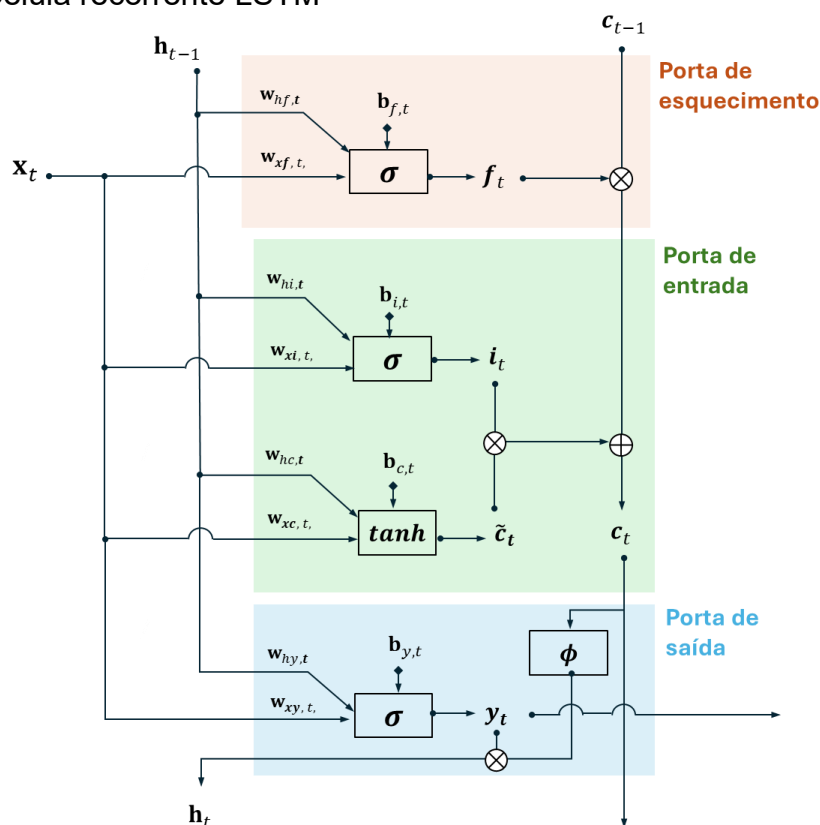
longo prazo e unidade recorrente fechada (Yu *et al.*, 2019).

### 2.3.3 Redes neurais de memória longa de curto prazo

Redes neurais de memória longa de curto prazo (*Long Short-Term Memory – LSTM*), também chamadas de *LSTM-dominated networks* são variações das redes neurais recorrentes, compostas prioritariamente por células LSTM e projetadas para lidar com sequências longas e não lineares. Essas redes apresentam maior capacidade de aprendizado de padrões temporais em comparação com as RNNs padrão, favorecendo o ajuste do modelo e a retenção de informações sequenciais (Shen; Ban, 2023; Jiang, 2023; Yu *et al.*, 2019).

A célula LSTM, núcleo funcional dessas redes, é composta por múltiplas componentes: células de memória e seu respectivo estado da célula, porta de entrada ou *Input Gate*, porta de saída ou *Output Gate*, porta de esquecimento ou *Forget Gate*, e o estado oculto ou *Hidden State* (Gharehbaghi, 2023; Shen; Ban, 2023). Tem-se, de forma simplificada, que as portas de entrada e saída controlam o fluxo de informações na célula, de modo que o estado da célula e o estado oculto são atualizados em cada passo de tempo, como representado na Figura 8.

**Figura 8** – Célula recorrente LSTM



Fonte: a própria autora

O processo inicia-se com a combinação da entrada  $\mathbf{x}_t$  com o estado oculto anterior  $\mathbf{h}_{t-1}$  na célula LSTM. Tais dados são combinados e ativados para o cálculo de  $\mathbf{f}_t$  na porta do esquecimento. Este é então aplicado para determinar quais partes do estado da célula anterior  $\mathbf{c}_{t-1}$  devem ser esquecidas. Em paralelo, os vetores de entrada  $\mathbf{x}_t$  e  $\mathbf{h}_{t-1}$  também são empregados na porta de entrada, determinando as informações  $\mathbf{i}_t$  a serem adicionadas ao estado da célula e o  $\tilde{\mathbf{c}}_t$ , que são os novos valores candidatos para o estado da célula. Os resultados das duas portas são combinados e direcionados para a porta de saída, responsável pela atualização do estado da célula  $\mathbf{c}_t$  e do estado oculto  $\mathbf{h}_t$  (Yu *et al.*, 2019; Zhang, A. *et al.*, 2021).

A representação matemática do procedimento em um camada  $i$  da rede neural pode ser expressa na forma implícita conforme as equações (Jiang, 2023; Shen; Ban, 2023):

$$\mathbf{F}_t^{(i)} = \sigma(\mathbf{W}_{hf}^{(i)} \cdot \mathbf{H}_{t-1} + \mathbf{W}_{xf}^{(i)} \cdot \mathbf{X}_t + \mathbf{B}_f^{(i)}) \quad (19)$$

$$\mathbf{I}_t^{(i)} = \sigma(\mathbf{W}_{hl}^{(i)} \mathbf{H}_{t-1} + \mathbf{W}_{xl}^{(i)} \mathbf{X}_t + \mathbf{B}_l^{(i)}) \quad (20)$$

$$\tilde{\mathbf{C}}_t^{(i)} = \tanh(\mathbf{W}_{hc}^{(i)} \cdot \mathbf{H}_{t-1} + \mathbf{W}_{xc}^{(i)} \mathbf{X}_t + \mathbf{B}_c^{(i)}) \quad (21)$$

$$\mathbf{C}_t^{(i)} = \mathbf{F}_t^{(i)} \cdot \mathbf{C}_{t-1}^{(i)} + \mathbf{I}_t^{(i)} \cdot \tilde{\mathbf{C}}_t^{(i)} \quad (22)$$

$$\mathbf{Y}_t^{(i)} = \sigma(\mathbf{W}_{ho}^{(i)} \cdot \mathbf{H}_{t-1}^{(i)} + \mathbf{W}_{xo}^{(i)} \cdot \mathbf{X}_t^{(i)} + \mathbf{B}_o^{(i)}) \quad (23)$$

$$\mathbf{H}_t^{(i)} = \mathbf{Y}_t^{(i)} \cdot \tanh(\mathbf{C}_t^{(i)}) \quad (24)$$

em que  $\mathbf{F}_t^{(i)}$ , representa uma matriz de valores 1 ou 0, mantendo ou esquecendo as informações do estado oculto,  $\mathbf{I}_t^{(i)}$  é a matriz com as modificações para o cálculo dos novos estados de célula;  $\mathbf{C}_{t-1}^{(i)}$  e  $\mathbf{C}_t^{(i)}$  são as matrizes dos estados das células no tempo  $t-1$  e  $t$ ;  $\tilde{\mathbf{C}}_t^{(i)}$  é a matriz com os novos candidatos ao estado de célula;  $\mathbf{W}_{hf}^{(i)}$ ,  $\mathbf{W}_{hl}^{(i)}$ ,  $\mathbf{W}_{hc}^{(i)}$ ,  $\mathbf{W}_{ho}^{(i)}$  são as matrizes de pesos para o vetor de estado oculto da camada  $i$ ;  $\mathbf{W}_{xf}^{(i)}$ ,  $\mathbf{W}_{xl}^{(i)}$ ,  $\mathbf{W}_{xc}^{(i)}$ ,  $\mathbf{W}_{xo}^{(i)}$  são os parâmetros de pesos para o vetor entrada da camada  $i$ ;  $\mathbf{B}_f^{(i)}$ ,  $\mathbf{B}_l^{(i)}$ ,  $\mathbf{B}_c^{(i)}$ ,  $\mathbf{B}_o^{(i)}$ ,  $\mathbf{B}_y^{(i)}$  são as matrizes com os *bias* ou vieses;  $\sigma$  e  $\phi$  são as funções de ativação.

Com a atualização do estado da célula ao longo do processo e o salvamento

de um estado oculto, uma rede LSTM é capaz de manter informações relevantes durante a análise das sequências de dados. Assim, conseguindo armazenar características que expliquem dependências de longo prazo e que, portanto, podem colaborar para a predição de dados futuros (Yu *et al.*, 2019; Zhang, A. *et al.*, 2021).

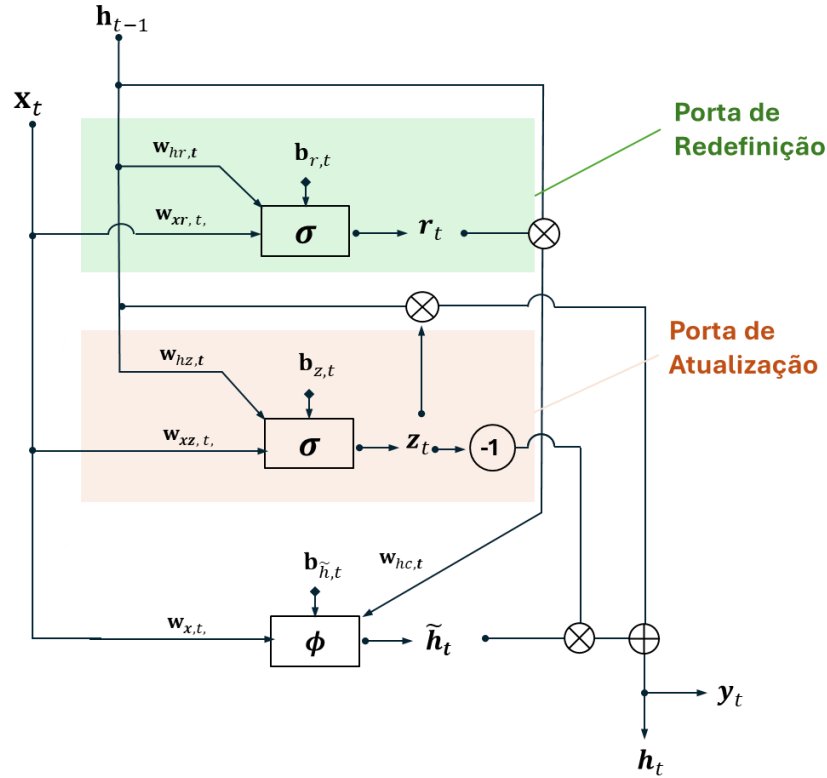
Como limitações, as redes LSTM apresentam maior demanda e complexidade computacional que as RNN. Isso ocorre devido ao aumento no número de processos de cálculo e pela alocação de memória para o armazenamento dos estados ocultos e dos estado de célula (Casolaro *et al.*, 2023; Yu *et al.*, 2019).

#### 2.3.4 Unidade recorrente fechada

A rede unidade recorrente fechada ou *Gated Recurrent Unit* (GRU) é uma rede neural recorrente, considerada uma evolução das redes LSTM. Segundo Yu *et al.* (2019) e Gharehbaghi (2023), tais redes empregam células GRU, que combinam a porta de esquecimento e a porta de entrada da célula LSTM em uma única porta de atualização. Dessa forma, a célula GRU reduz o número de parâmetros e, conseqüentemente, a demanda de processamento. Entretanto, com a redução de uma porta, a célula GRU tende a ser menos potente que a LSTM original.

A Figura 9 expõe um esquema básico da célula GRU. Nesta célula, o dado de entrada atual  $\mathbf{x}_t$  e o estado oculto anterior  $\mathbf{h}_{t-1}$  entram na célula. Essas são empregadas na porta de redefinição, que irá estabelecer qual o valor da influência do estado oculto anterior  $r_t$ . De forma paralela, na porta de atualização, determina-se quanto do estado oculto anterior deverá ser mantida  $z_t$ . Com isso, portas de redefinição ajudam a capturar dependências de curto prazo das sequências, enquanto as porta de atualização ajudam a capturar dependências de longo prazo das sequências, para a melhor definição dos valores candidatos  $\tilde{\mathbf{h}}_t$  (Gharehbaghi, 2023; Yu *et al.*, 2019; Zhang, A. *et al.*, 2021).

Figura 9 – Célula recorrente GRU



Fonte: a própria autora

A representação matemática do procedimento em uma camada  $i$  da rede neural GRU pode ser expressa na forma implícita conforme as equações

$$\mathbf{R}_t^{(i)} = \sigma(\mathbf{W}_{hr}^{(i)} \cdot \mathbf{H}_{t-1} + \mathbf{W}_{xr}^{(i)} \cdot \mathbf{X}_t + \mathbf{B}_r^{(i)}) \quad (25)$$

$$\mathbf{Z}_t^{(i)} = \sigma(\mathbf{W}_{hz}^{(i)} \cdot \mathbf{H}_{t-1} + \mathbf{W}_{xz}^{(i)} \cdot \mathbf{X}_t + \mathbf{B}_z^{(i)}) \quad (26)$$

$$\tilde{\mathbf{H}}_t^{(i)} = \phi(\mathbf{W}_{hh}^{(i)} \cdot (\mathbf{H}_{t-1} \cdot \mathbf{R}_t^{(i)}) + \mathbf{W}_{xh}^{(i)} \mathbf{X}_t + \mathbf{B}_h^{(i)}) \quad (27)$$

$$\mathbf{H}_t = (\mathbf{1} - \mathbf{Z}_t^{(i)}) \cdot \tilde{\mathbf{H}}_t^{(i)} + \mathbf{Z}_t^{(i)} \cdot \mathbf{H}_{t-1} \quad (28)$$

em que  $\mathbf{R}_t^{(i)}$  representa a matriz de valores de redefinição, que controla a quantidade de informação do estado oculto anterior  $\mathbf{H}_{t-1}$  a ser considerada no cálculo do novo estado oculto;  $\mathbf{Z}_t^{(i)}$  é a matriz de atualização, que regula a combinação entre o estado oculto anterior  $\mathbf{H}_{t-1}$  e dos valores candidatos ao estado oculto  $\tilde{\mathbf{H}}_t^{(i)}$ ;  $\mathbf{H}_t$  é a matriz do estado oculto final no tempo  $t$ ;  $\mathbf{W}_{hr}^{(i)}$ ,  $\mathbf{W}_{hz}^{(i)}$  e  $\mathbf{W}_{hh}^{(i)}$  são as matrizes de pesos associados a matriz de vetores de estado oculto  $\mathbf{H}_{t-1}$ ;  $\mathbf{W}_{xr}^{(i)}$ ,  $\mathbf{W}_{xz}^{(i)}$  e  $\mathbf{W}_{xh}^{(i)}$  são as matrizes de pesos associados a matriz de vetores de entrada  $\mathbf{X}_t$ ;  $\mathbf{B}_r^{(i)}$ ,  $\mathbf{B}_z^{(i)}$  e  $\mathbf{B}_h^{(i)}$  são as matrizes de bias

(viés);  $\sigma$  e  $\phi$  representam as funções de ativação.

Apesar de representarem um avanço ao modelo tradicional de rede neural recorrente, e apresentarem um ganho de eficiência em comparação com as LSTM, as GRUs também apresentam limitação na predição das séries temporais. O uso de um único modelo de aprendizado profundo pode não ser capaz de aprender todas as variações não lineares ou identificar a sazonalidade (Aggarwal, 2023; Gharehbaghi, 2023). Uma forma de aprimorar os modelos de predição por aprendizado profundo é com aplicação de técnicas de aprendizado por conjunto, também conhecidos como aprendizado por *ensemble* ou por agrupamento.

## 2.4 MODELOS DE APRENDIZADO POR CONJUNTO

Os modelos de aprendizado por conjunto ou *ensembles* são técnicas de aprendizado de máquina que combinam múltiplos modelos base (*base learners* ou *weak learners*) para criar um melhor preditivo mais robusto e eficaz (Ganaie *et al.*, 2022). Segundo Yadav (2023), o uso dessas abordagens diminui o sobre ajuste ou *overfitting*, produzindo modelos mais confiáveis. Para serem executadas, primeiro realiza-se o treinamento dos modelos base, para posteriormente esses serem combinados em um processo de meta aprendizado.

Os métodos de aprendizado por conjunto são divididos em quatro tipos: *Bagging*, *Boosting*, *Dagging* e *Stacking*. Esses tipos se distinguem pela forma como ocorre a combinação dos resultados dos múltiplos modelos base, variando nas estratégias de treinamento, agregação e tratamento de variações nos dados (Cha Zhang; Ma, 2012; Ganaie *et al.*, 2022; Kyriakides; Margaritis, 2019).

Os modelos *Bagging* (*Bootstrap Aggregating*) empregam a técnica de *bootstrapping* e posterior união dos modelos. No *bootstrapping* há a geração de diversos subconjuntos de treinamento a partir do conjunto original, com amostragem aleatória e reposição. Em seguida, cada subconjunto é utilizado para treinar um modelo distinto, promovendo diversidade entre os modelos produzidos. Após o treinamento, um processo de união dos modelos é realizado por agregação, ao qual a predição final do modelo é calculada pela média das predições individuais (Ganaie *et al.*, 2022; Kyriakides; Margaritis, 2019).

Devido à sua capacidade de gerar diferentes subconjuntos de entrada, a técnica de *Bagging* é especialmente útil em cenários com séries de treinamento de

pequena dimensão e de alta variabilidade. Essa abordagem pode ser aplicada tanto em estudos de regressão quanto de classificação. Sua aplicação em estudos de séries temporais é considerada limitada, visto que o processo de amostragem com reposição ocasiona quebras na sequência temporal. Desse modo, tais modelos de aprendizados não são capazes de considerar a estrutura temporal dos dados e as autocorrelações presentes (Cha Zhang; Ma, 2012; Ganaie *et al.*, 2022; Zounemat-Kermani *et al.*, 2021).

Dentre as arquiteturas mais conhecidas de aprendizado por *Bagging* estão as técnicas de *Random Forest*, *Random Subspace*, *Extremely Randomized Trees*. (Kyriakides; Margaritis, 2019; Zounemat-Kermani *et al.*, 2021).

Os modelos de aprendizado por *Dagging* (*Directed Acyclic Graph based Bagging*) são uma variação dos modelos de *Bagging*, e realizando a criação de múltiplos subconjuntos de treinamento e modelos independentes. Entretanto, as amostras dos subconjuntos são geradas de forma aleatória e sem reposição. Assim, nenhum elemento será repetido entre as séries de treinamento (Zounemat-Kermani *et al.*, 2021).

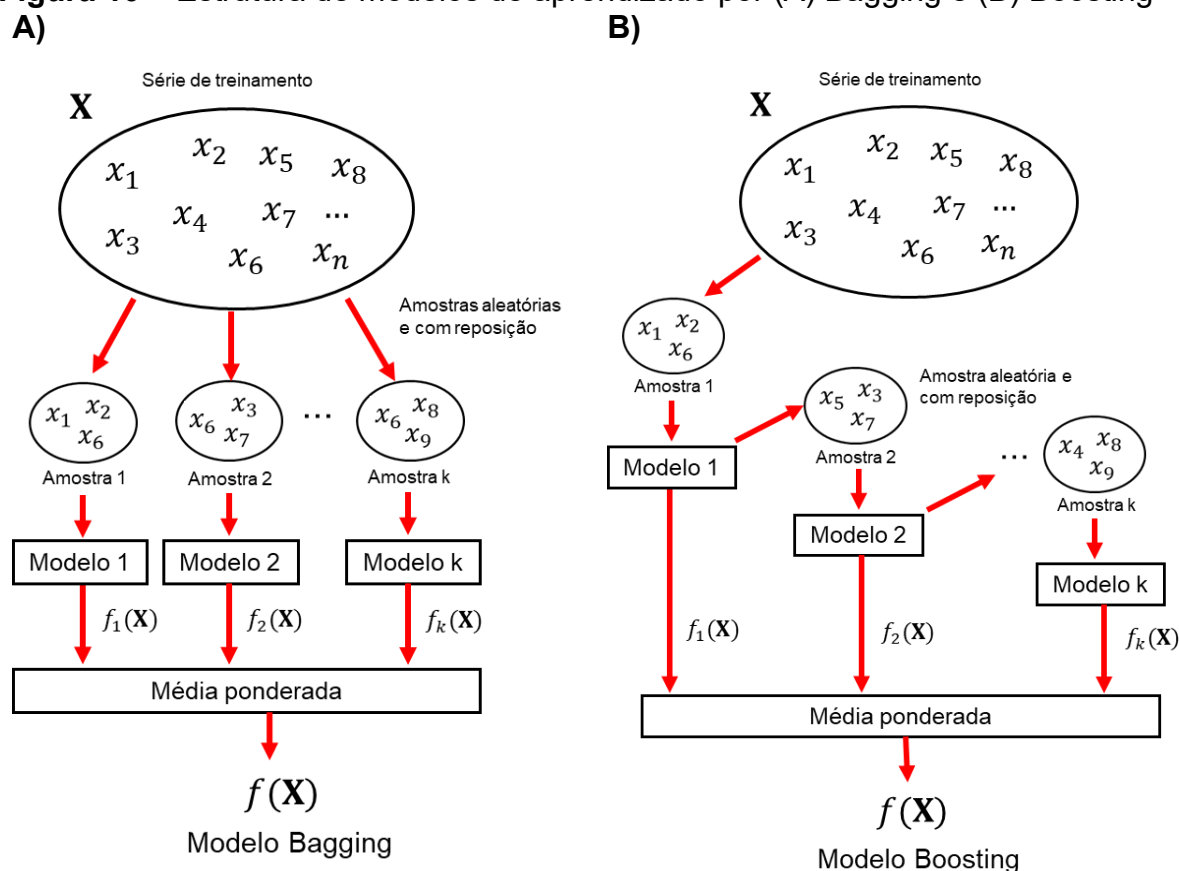
Os modelos do tipo *Boosting* promovem o treinamento de múltiplos modelos base de forma sequencial, com cada modelo subsequente sendo ajustado para corrigir os erros identificados nos anteriores. Para isso, essa estrutura também utiliza da técnica de *bootstrapping* para gerar múltiplas séries de treinamento, selecionando elementos de maneira aleatória e com reposição. Ao final do treinamento de todos os subconjuntos, os modelos base são combinados por uma ponderação das predições, considerando o desempenho de cada modelo (Kumar; Jain, 2020; Kyriakides; Margaritis, 2019; Zounemat-Kermani *et al.*, 2021)

A principal vantagem do *Boosting* é sua abordagem iterativa, que refina progressivamente os modelos e as predições ao longo do treinamento. No entanto, essa característica pode limitar sua aplicação em estudos com séries temporais altamente voláteis ou ruidosas, pois aumenta o risco de sobre ajuste (*overfitting*). Além disso, mesmo suas variantes mais modernas não são capazes de modelar explicitamente dependências temporais, embora sejam eficientes na redução do erro em tarefas supervisionadas. Entre os modelos mais conhecidos de Boosting estão: *AdaBoost*, *Stochastic Gradient Boosting* (SGB) e *Extreme Gradient Boosting* (XGBoost) (Kyriakides; Margaritis, 2019; Zounemat-Kermani *et al.*, 2021).

A Figura 10 apresenta a estruturas das técnicas de Bagging e Boosting, aplicados para melhorar a performance de predição com base em uma série de

treinamento  $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_n\}$ .

**Figura 10** – Estrutura de modelos de aprendizado por (A) Bagging e (B) Boosting



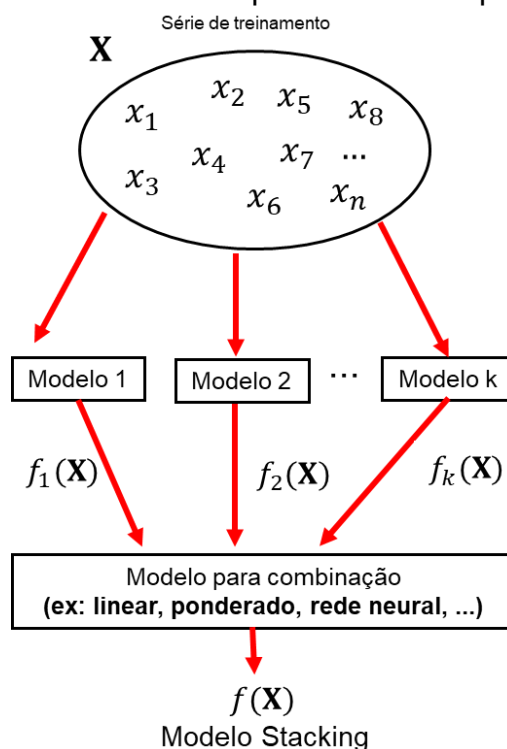
Fonte: a própria autora

Como indicado pela Figura 10 (A), o modelo *Bagging* emprega vários modelos base treinados de forma independente, com subconjuntos de dados obtidos por amostragem aleatória. Em seguida, suas previsões são combinadas para gerar uma previsão final  $f(\mathbf{X})$ . Já na Figura 10 (B), representando o processo de *Boosting*, os modelos base são treinados sequencialmente, de forma que cada novo modelo foca na correção dos erros dos anteriores, atribuindo maior peso aos dados mal classificados. Dessa forma, ambas as estruturas buscam a construção de um modelo geral mais estável, reduzindo assim a variância e o viés do modelo final.

Por último, as técnicas do tipo *Stacking* agregam os resultados de múltiplos modelos base por meio de um novo treinamento ou técnica de aprendizado. Ao combinar diferentes algoritmos com um metamodelo, este é capaz de aprender a ajustar e integrar as previsões de forma mais precisa. Dessa maneira, gerando uma aumento na capacidade de previsão do modelo final ao diminuir os erros derivados

do processo de aprendizado dos seus *base learners* (Kyriakides; Margaritis, 2019). A Figura 11 apresenta a estrutura de um modelo Stacking aplicado a uma série de treinamento  $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_n\}$  e múltiplos modelos base.

**Figura 11** – Estrutura de um modelo de aprendizado do tipo *Stacking*



**Fonte:** a própria autora

Como representado na Figura 11, as previsões de  $k$  modelos bases foram utilizadas como entrada para um segundo modelo, conhecido como metamodelo, produzindo a previsão final  $f(\mathbf{X})$ . Tal processo de empilhamento permite que o metamodelo capture relações e padrões que os modelos base, individualmente, podem ter sido capazes de identificar. Em conjunto, esse processo tende a reduzir o risco de super ajuste, aumentando também a capacidade de adaptação do modelo para múltiplas condições.

Zounemat-Kermani *et al.* (2021) avaliaram o estado da arte da aplicação de técnicas *ensemble* em pesquisas de recursos hídricos. Os autores indicaram que, na maioria dos casos, a adoção do aprendizado por conjunto gerou melhora na eficiência das previsões. Segundo os autores, houve um crescimento no número de publicações que abordaram o tema, sendo que a maioria das aplicações utilizaram *base learners* do tipo árvore de decisão e redes neurais artificiais.

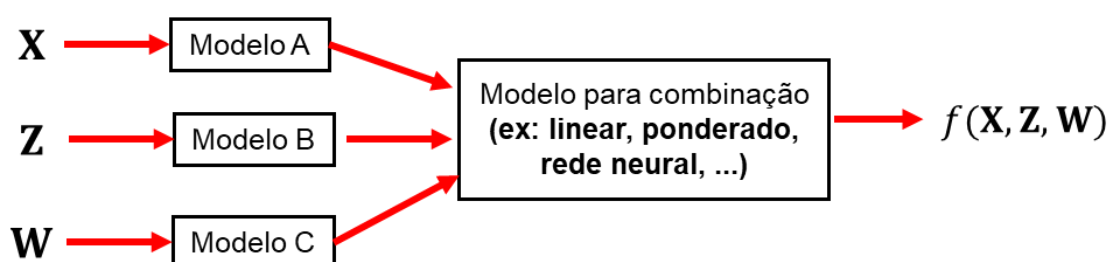
Embora o estudo de Zounemat-Kermani *et al.* (2021) destaque um aumento na

aplicação das técnicas de *Bagging* e *Boosting* em pesquisas de recursos hídricos, é importante considerar que o *Stacking* apresenta vantagens que justificam a sua aplicação em análises temporais. Ao contrário do *Bagging*, que foca na redução da variância, e do *Boosting*, que se concentra em melhorar modelos ‘fracos’, o *Stacking* combina diferentes tipos de modelos base, ou seja, modelos heterogêneos. Com isso, pode-se utilizar modelos base especializados na identificação de diferentes padrões ou variáveis que ajudem a explicar cada parcela do fenômeno.

Outras vantagem, é a sua aplicação em estudos com fusão de dado. Segundo Ganaie *et al.* (2022), essa habilidade está intrinsicamente ligada a estrutura do *Stacking*, visto que um modelo individual poderia ser treinado para cada variável exploratória. Posteriormente, as previsões podem ser combinadas com um metamodelo, que pode variar entre uma operação simples, como uma combinação ponderada, ou ainda, um outro modelo de aprendizado de máquina.

A Figura 12 ilustra o funcionamento de um modelo de Stacking, no qual várias variáveis preditoras  $X, Z, W$  são alimentados a diferentes modelos base. Cada um desses modelos processa as variáveis e gera suas respectivas previsões, que, por sua vez, são combinadas e passadas para um metamodelo. O metamodelo, utilizando as previsões como entradas, gera a previsão final, que será uma função  $f(X, Z, W)$ .

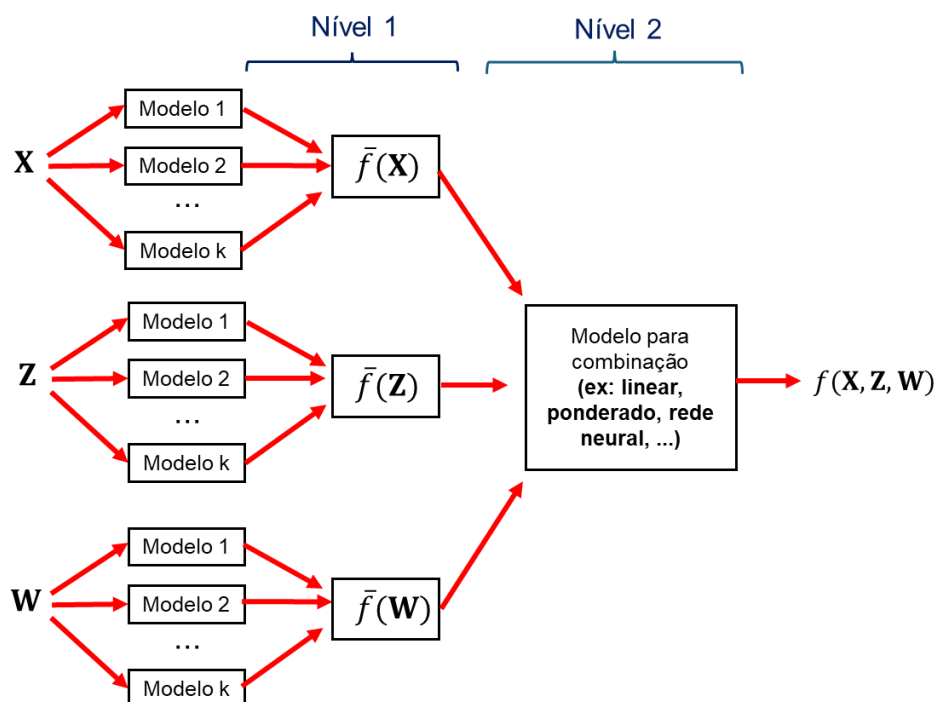
**Figura 12** – Estrutura de um modelo de aprendizado do tipo *Stacking* com múltiplas variáveis exploratórias



Fonte: a própria autora

Cha Zhang e Ma (2012) ainda propõem que múltiplos *base learners* sejam utilizados para cada variável, permitindo assim a aplicação de modelos *Stacking* em diferentes níveis. Na Figura 13, ilustra-se tal processo, em que vários modelos base são elaborados para cada variável exploratória e combinadas, em um chamado ‘Nível 1’. As previsões desses são então utilizadas como entrada para um metamodelo no ‘Nível 2’, que gera a previsão final  $f(X, Z, W)$ .

**Figura 13** – Estrutura de um modelo de aprendizado do tipo *Stacking* com múltiplos níveis



**Fonte:** a própria autora

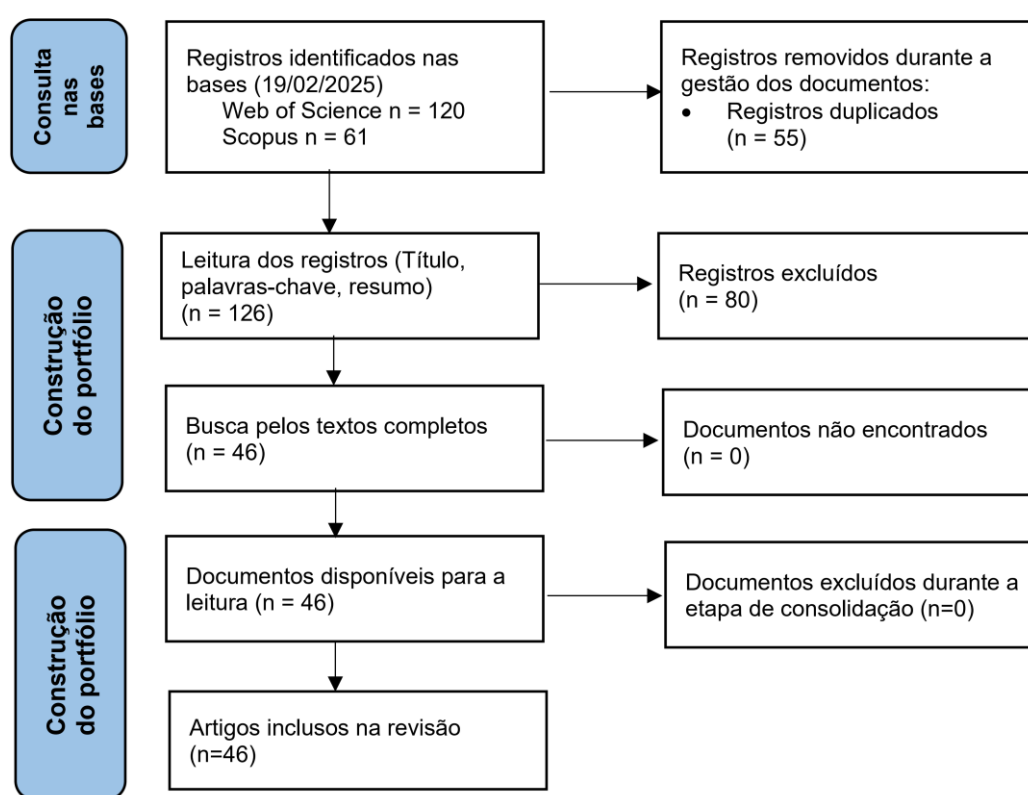
## 2.5 ESTADO DA ARTE

De modo a estabelecer a relevância científica do tema, foi realizada uma revisão de forma sistemática da literatura, executada com base na metodologia proposta por Ferenhof e Fernandes (2016), a qual orienta as etapas de planejamento, execução e análise da revisão. Para estruturar a apresentação dos resultados, adotou-se o fluxograma da diretriz internacional PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*)(Page et al., 2021).

A estratégia de busca foi delineada com o objetivo de compilar os estudos que abordassem a aplicação de redes neurais artificiais na previsão de precipitações, utilizando decomposições e associações de redes neurais por aprendizado por conjunto. Para isso, utilizou-se termos que contemplasse, variações e sinônimos relevantes a esses, como: *artificial neural networks (ANN)*, *recurrent neural networks (RNN)*, *rainfall*, *precipitation*, *forecast*, *prediction*, *ensemble* e *decomposition*. Para fins de replicabilidade, o protocolo de pesquisa utilizado foi: ALL= (("ANN" OR "RNN" OR "Neural Network\*") AND ("rainfall\*" OR "precipitation\*") AND ("prediction\*" OR "forecast\*") AND ("ensemble\*") AND ("decomposition\*")).


Foram selecionadas duas bases de dados internacionais multidisciplinares (*Web of Science* e *Scopus*), acessadas por meio da infraestrutura institucional da Universidade Estadual de Londrina. Os critérios de inclusão consideraram apenas artigos técnicos e de revisão, redigidos em português ou inglês, publicados até a data da consulta (19/02/2025) e disponíveis em periódicos com revisão por pares. Um resumo do processo de seleção e triagem dos registros identificados, com a respectiva quantidade de publicações em cada etapa, é apresentado na Figura 14.

**Figura 14** – Processo de busca de forma sistemática




Fonte: adaptado de Page et al. (2021)

A análise e consolidação dos artigos identificados indicou que o tema pesquisado é considerado recente, com o primeiro trabalho incluso datado de 2016. Houve também um crescimento no número de publicações em 2023 e 2024 (Figura 15), demonstrando a sua relevância e atualidade.

**Figura 15 – Total de publicações por ano**

**Fonte:** a própria autora

Apesar da busca de forma sistemática ter tido como foco nos estudos para a predição de precipitações, a pesquisa trouxe estudos com temas diferentes, porém ainda alinhados a área de recursos hídricos. Como apresentado na Figura 16, a maior parte dos artigos buscou a modelagem das precipitações (26 artigos ou 57,52%). Os escoamentos em rios foram objeto de 19 estudos (41,30%) e a temperatura de um artigo (2,17%).

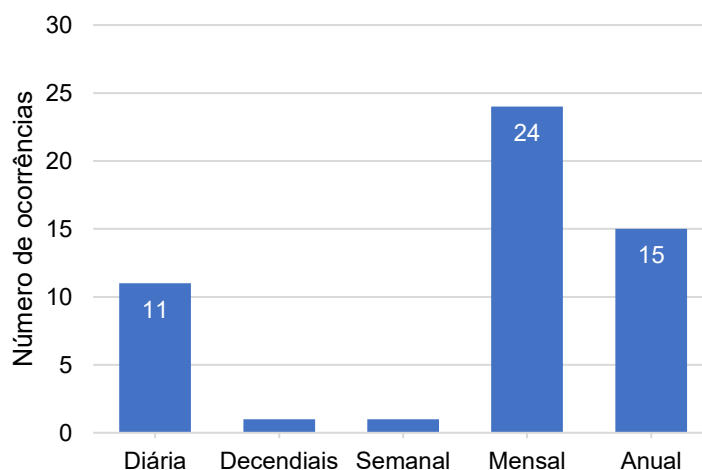
**Figura 16 – Total de estudos por variáveis previstas**

**Fonte:** a própria autora

Considerando o foco desta pesquisa em análises de séries temporais, contabilizou-se qual a escala temporal de predição foi avaliada pelos estudos compilados. Conforme indicado na Figura 17, houve uma predominância da modelagem para a predição de padrões de longo período, como mensais (46,15%) e

anuais (28,84%). Tal preferência se deve principalmente à natureza dos fenômenos hidrológicos, visto que os escoamentos e a precipitações frequentemente apresentam comportamentos cíclicos de longo prazo, influenciados por padrões sazonais e anuais.


**Figura 17** – Total de análises por escala temporal



**Fonte:** a própria autora

Com a busca realizada nos dois bancos de dados, verificou-se que somente um dos trabalhos compilados realizou estudos para previsão em escala decendial. Li *et al.* (2019) compararam a modelagem de séries decompostas com redes neurais *perceptrons* de múltiplas camadas para predição das vazões decendiais em rios da China. Os autores comparam a capacidade preditiva de modelos que realizaram a decomposição com decomposição em modos empíricos (EMD), decomposição em modos empíricos por conjunto (EEMD) e decomposição sazonal e de tendência usando LOESS (STL). Os resultados indicaram uma melhor eficiência do método STL-ANN, com todos os modelos obtendo Coeficiente de Nash-Sutcliffe (NSE) superior a 0,85.

Avaliando quais os métodos de decomposição utilizados nas publicações (Figura 18), houve uma predominância de métodos baseados na decomposição empírica. Esses incluem a decomposição EMD (10,38%), EEMD (20,77%), a decomposição empírica conjugada modificada (CEEMD) (11,68%) e o método de decomposição empírica por conjunto com ruído adaptativo (CEEMDAN) (12,98%).

**Figura 18** – Total de aplicações por método de decomposição

**Fonte:** a própria autora


Como discutido nas seções anteriores, os métodos de decomposição empírica geram um número variável de componentes intrínsecas (IMFs), que não é fixo ou predefinido (Li *et al.*, 2019; Li; Wang; Qiu, 2019; Sibtain; Li; Saleem, 2020; Zhang, X. *et al.*, 2021). Essa característica representa um desafio para a construção de modelos híbridos baseados na associação por conjunto, pois dificulta a padronização do processo de modelagem. Em contrapartida, o método de Decomposição Sazonal e de Tendência usando LOESS (STL), ao dividir a série explicitamente em componentes fixas, como as sazonais, de tendência e resíduo, e oferece maior previsibilidade e facilita a implementação dessas abordagens

A qualidade da decomposição STL associada a redes neurais já foi comprovada por outros autores. Como citado, Li *et al.* (2019), essa abordagem gerou melhores previsões de vazões decendiais. Outra aplicação relevante foi realizada por Tebong *et al.* (2023), que analisaram a combinação de modelos de aprendizado profundo com a decomposição STL para a previsão de vazões afluentes diárias em reservatórios. Nesse estudo, as subcomponentes foram modeladas utilizando redes do tipo *Dense*, LSTM e Convolucionais (1D).

Em relação as arquiteturas dos modelos preditivos empregados para as previsões das componentes, a revisão de forma sistemática expôs que houve uma predominância do uso de redes neurais (Figura 19). As redes neurais *perceptrons* de múltiplas camadas foram as mais empregadas, com 17 ocorrências (17,52%). Tais

usos demonstram sua versatilidade e aplicabilidade. Já as arquiteturas de redes neurais recorrentes, em particular suas variantes avançadas, também foram muito utilizadas, como as redes neurais LSTM, BiLSTM, GRU e a GRU Convolutacional. Somadas, elas representaram 23,40% das análises.

**Figura 19** – Total de aplicações por modelo preditivo



**Fonte:** a própria autora

Um exemplo de aplicação foi a realizada por Shen e Ban (2023), que modelaram precipitações mensais em Lanzhou na China. Em suas análises, foi utilizado o algoritmo CEEMDAN para a decomposição da série temporal de precipitação. Em seguida, o modelo SVM foi aplicado ao primeiro componente modal (maior frequência) e modelos LSTM foram aplicados aos demais componentes. Como forma de avaliar a eficiência dessa configuração, o modelo recomposto foi comparado com previsões realizadas por outros tipos de arquitetura LSTM simples, ARIMA, redes neurais de múltiplas camadas, SVM, CEEMDAN-LSTM e CEEMDAN-SVM. O modelo híbrido proposto obteve  $R^2$  de 0,95, indicando uma boa aproximação para a série observada de validação e superando os modelos simples.

Yuan *et al.* (2021) modelaram o escoamento diário usando a decomposição EEMD e rede neural LSTM. Em seus resultados, os autores avaliaram que o modelo EEMD-LSTM apresentou um bom desempenho ao longo dos períodos de predição ,

com Coeficiente de Nash-Sutcliffe (NSE) de 0,98. Entretanto, à medida que o período de predição aumentou, a precisão diminuiu. Outros exemplos podem ser verificados nas publicações de Jiang (2023), Peng *et al.*(2021), Sibtain, Li e Saleem (2020); Tebong *et al.* (2023), Zhao *et al.* (2023) e Zhao, Nie e Wen (2023).

Avaliando os artigos compilados, percebeu-se que os modelos híbridos elaborados nestes se limitavam somente a realizar a sobreposição das predições dos modelos de cada subcomponente. No total, cerca de 93,47% dos estudos empregaram somente uma única arquitetura ou modelo preditivo por componente da série temporal.

Como exemplo, Zhao *et al.* (2023) propôs um modelo acoplado de predição de precipitação mensal da bacia do Rio Amarelo, na China. O algoritmo de entropia de permutação (PE) foi usado para dividir os dados processados pelo CEEMDAN em diferentes frequências. Em seguida, as subcomponentes com maior frequência foram modeladas com redes neurais do tipo GRU, e as de baixa frequência por uma rede neural do tipo *Transformer*. O modelo final, nomeado como CEEMDAN-GRU-Transformer, apresentou boas predições, com coeficiente de determinação ( $R^2$ ) superior a 0,8. Entretanto, o modelo se limitou a uma arquitetura de rede neural por função IMF.

Outro estudo, realizado por Xu *et al.* (2016), propôs um modelo híbrido baseado na decomposição por EEMD. Nesse modelo, os modos resultantes foram previstos individualmente por uma rede neural artificial de retropropagação e por uma equação de regressão não linear. De forma semelhante aos estudo anterior, apenas um tipo de técnica foi aplicado a cada IMF, e os resultados foram posteriormente recombinados para estimar o escoamento anual do rio Kaidu, localizado no noroeste da China.

Tebong *et al.* (2023) compararam diferentes configurações de modelos híbridos, sendo o modelo mais complexo proposto nomeado como STL-Dense-LSTM-Conv1D. Neste, foi realizada a modelagem da tendência com a arquitetura *Dense*, da sazonalidade com a rede LSTM e do resíduo com uma rede neural convolucional (1D). As predições de cada subcomponente foram posteriormente somadas. Todas as sete combinação avaliadas apresentaram boa capacidade preditiva, com NSE superior a 0,98. Semelhante aos exemplos anteriores, apesar de serem configuradas como modelos híbridos, essa proposta não apresentou uma real associação caracterizada como um *ensemble* ou associação por conjunto.

Com a pesquisa de forma sistemática, foram identificados três estudos que

abordaram metodologias de associações por conjunto entre múltiplas arquiteturas. Parviz, Rasouli e Haghighi (2023) combinaram modelos lineares (ARIMA, SARIMA) com modelos não lineares (GEP, SVR, GMDH) para previsão de precipitações mensais e anuais em uma bacia hidrográfica no Irã. De forma complementar, os autores promoveram a melhora dos modelos com o emprego de técnicas de associação por conjunto, comparando o uso da média ponderada segundo o inverso da variância, média ponderada segundo o inverso do erro quadrático médio, algoritmos genéticos, regressão com vetores de suporte e redes neurais artificiais do tipo *feedforward*.

Garai *et al.* (2024) integraram a decomposição CEEMDAN com algoritmos de aprendizagem de máquina para predição de precipitação anual em três regiões da Índia. As séries de precipitação foram inicialmente decompostas em várias componentes intrínsecas por meio do CEEMDAN. Em seguida, múltiplas arquiteturas de aprendizado (ARIMA, ANN, *Random Forest*, entre outros ) foram aplicados para a modelagem de cada componente. Os autores avaliaram a eficiência da previsão de modelos híbridos uma única arquitetura e a de um modelo híbrido com associação (CEEMDAN- RF-KRR). Este último indicou que a efetividade da associação é dependente da variabilidade e magnitude da série original.


Khairudin *et al.* (2024) propõem um modelo híbrido com associação de redes neurais para predição de inundações que integra técnicas de otimização de entrada e de decomposição. Inicialmente, a Transformada Wavelet (DWT) é utilizada para reduzir a variabilidade dos dados de chuva, seguida da seleção de características dominantes por meio da informação mútua (MI). Em seguida, modelos individuais, como a rede neural de retropropagação (BPNN) e a *Extreme Learning Machine* (ELM), são treinados para prever o nível de água. O diferencial do trabalho reside na combinação final das predições desses modelos, por meio do cálculo da média aritmética, resultando em uma predição mais robusta e com menor erro de generalização.

Um pesquisa complementar em outros bancos de dados, permitiu identificar outra publicação relevante, escrita por Gu *et al.* (2022). Quatro modelos base e um modelo híbrido com associação *Stacking* foram utilizados para modelar as precipitações mensais em nove estações na bacia de Taihu, na China. Os resultados indicaram que o desempenho dos modelos base variou bastante entre as nove estações. O modelo híbrido tendeu a superar os modelos base, com os melhores

resultados obtidos nos meses de primavera e inverno. Considerando os resultados obtidos nesse e nos três estudos anteriormente mencionados, identificou-se uma lacuna metodológica relacionada à avaliação da eficácia de associações entre redes neurais na predição de séries temporais de precipitação previamente decompostas.

Em conjunto com as características dos modelos já discutidas, a pesquisa de forma sistemática também permitiu a compilação dos parâmetros utilizados nas construções dos modelos. Para o processo de calibração e validação, por exemplo, torna-se necessária a divisão da série histórica disponível, a fim de evitar a contaminação de dados entre ambos os processos, e o super ajuste do modelo. Como indicado pela Figura 20, a maior parte dos estudos dedicou 70% ou mais da série original para a calibração, e uma parcela de 30% ou menos para a validação dos modelos.

**Figura 20** – Número de publicações segundo a faixa percentual de calibração/validação

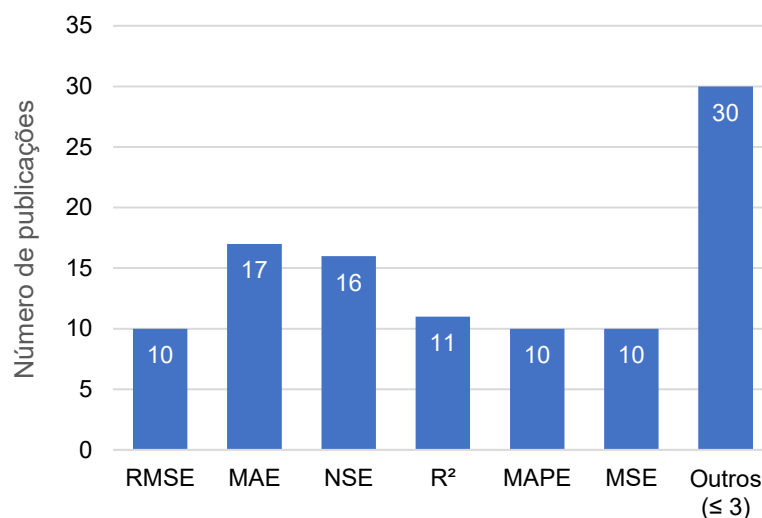


**Obs:** As proporções foram agrupadas em faixas próximas para melhor visualização dos dados.

**Fonte:** a própria autora

De modo a avaliar a qualidade dos modelos durante a calibração e validação, todas as pesquisas identificadas utilizaram as chamadas métricas de performance. Como contabilizado na Figura 21, as métricas mais utilizadas nas pesquisas sobre o tema foram o Coeficiente de Determinação ( $R^2$ ), o Erro Médio Absoluto (MAE), o Erro Médio Absoluto Percentual (MAPE), o Erro Quadrático Médio (MSE), a Raiz do Erro Quadrático Médio (RMSE) e o Coeficiente de Eficiência de Nash–Sutcliffe (NSE).

**Figura 21** – Número de publicações que empregaram a referente métrica de performance



**Fonte:** a própria autora

Considerando os resultados da revisão de forma sistemática, constatou-se que a maioria dos estudos que aplicam modelos híbridos com redes neurais e decomposição de séries hidrológicas se limita à recombinação direta das previsões geradas para cada subcomponente. Essa abordagem, no entanto, desconsidera a possibilidade de integração entre diferentes arquiteturas por meio de estratégias de aprendizado por conjunto. Entre os quatro estudos identificados que aplicaram esse tipo associação, os resultados mostraram-se divergentes quanto à eficácia das estratégias utilizadas, sugerindo que o desempenho pode variar em função da variável prevista, das características da série, das arquiteturas adotadas e do nível de combinação aplicado (Garai *et al.*, 2024; Gu *et al.*, 2022; Khairudin *et al.*, 2024; Parviz; Rasouli; Haghghi, 2023).

Essa limitação também é destacada por autores que revisaram a literatura recente. Ganaie *et al.* (2022), por exemplo, destacam que a maior parte dos trabalhos se concentra na proposição de novas arquiteturas de redes neurais profundas, mas dedica pouca atenção à forma como as previsões dos modelos base são combinadas. Os autores ressaltam ainda que não há, até o momento, critérios bem definidos para a escolha e a fusão das previsões em modelos de *ensemble* e *deep learning*, o que reforça a necessidade de mais estudos nessa área.

Diante disso, esta pesquisa propõe avançar no uso de redes neurais aplicadas a séries temporais por meio da associação de modelos em séries previamente decompostas. A ideia é reduzir a complexidade do problema original e organizar as

predições segundo diferentes níveis de combinação entre arquiteturas. A proposta metodológica inclui o uso de técnicas de *stacking* em diferentes níveis da modelagem, com o objetivo de avaliar se a associação entre modelos de redes neurais pode trazer melhorias reais na predição de séries hidrológicas.

### 3 MATERIAIS E MÉTODOS

Frente aos avanços obtidos com o uso das técnicas *ensemble* e *deep learning*, esse estudo propõe a elaboração de modelos híbridos para a predição de precipitações, se enquadrando como de natureza exploratória e explicativa.

#### 3.1 TRATAMENTO E DECOMPOSIÇÃO DA SÉRIE TEMPORAL

Para a pesquisa, foram utilizadas séries históricas de precipitação diária provenientes de estações pluviométricas, com o objetivo de avaliar e comparar o desempenho dos modelos preditivos e os efeitos das estratégias de associação. Foram selecionadas duas estações localizadas no estado do Paraná, priorizando-se aquelas com registros contínuos e de longa duração, com no mínimo 30 anos de dados e sem descontinuidades significativas (World Meteorological Organization, 2012).

As séries foram obtidas a partir do Sistema Nacional de Informações sobre Recursos Hídricos (Agência Nacional de Água e Saneamento, 2024; Silva, 2023). A extração dos dados foi realizada por meio do plugin *ANA Data Acquisition*, desenvolvido pelo grupo de pesquisa Hidrologia de Grande Escala (HGE), vinculado ao Instituto de Pesquisas Hidráulicas (IPH) da Universidade Federal do Rio Grande do Sul (UFRGS) (Petry; Jardim; Fan, 2021).

As séries diárias de precipitação abrangeram o período de 1975 a 2019 e passaram por um controle de qualidade com base na metodologia proposta de Serrano-Notivoli, De Luis e Beguería (2017), conforme descrito por Silva (2023). Inicialmente, foram calculados valores de referência com base nas dez estações pluviométricas mais próximas à estação pluviométrica de interesse. A partir disso, os dados foram avaliados segundo seis critérios de consistência (Quadro 2), os quais permitiram identificar registros suspeitos. Os dados considerados inconsistentes foram excluídos e posteriormente preenchidos por predição, utilizando-se as séries diárias das estações vizinhas e a coerência com os totais mensais previstos e observado.

**Quadro 2** – Critérios de classificação dos dados das séries de precipitação

Condição	Critério
<b>Dado suspeito</b>	Valor observado é maior que zero e todas as 10 estações mais próximas tem dados iguais a zero
<b>Zero suspeito</b>	Valor observado é zero e todas as 10 estações mais próximas tem dados maiores que zero;
<b>Outliner</b>	Valor observado é 10 vezes maior ou menor que o previsto pelas 10 estações mais próximas
<b>Chuva suspeita</b>	Valor observado é zero, probabilidade de chuva é maior que 0,99 e a intensidade prevista é maior que 5 mm
<b>Seca suspeita</b>	Valor observado é maior que 5 mm, a probabilidade de seca é maior que 0,99 e a intensidade prevista é menor que 0,1 mm
<b>Erro</b>	Valor observado é inferior a zero

**Fonte:** adaptado de Silva (2023)

Antes da aplicação da técnica de decomposição da série temporal, os dados de precipitação foram convertidos para a escala decendial, considerando-se o acumulado de precipitação a cada 10 dias consecutivos, sem sobreposição entre os períodos. A adoção de janelas fixas ao invés da média móvel, baseou-se em análises preliminares que indicaram maior adequação dessa abordagem ao problema proposto. Mesmo que essa estratégia implique na redução no número de observações disponíveis, seu uso simplifica a estrutura de entrada dos modelos, reduzindo a demanda computacional. Adicionalmente, a ausência de sobreposição evita a criação de amostras interdependentes, favorecendo a independência entre as entradas e reduzindo a redundância durante o treinamento. Ressalta-se, ainda, que essa escolha metodológica está alinhada às práticas adotadas em outros estudos (Liu *et al.*, 2022), incluindo aos voltados à predição em escalas mensais ou anuais, nos quais também não há sobreposição entre os períodos acumulados (Gu *et al.*, 2022; Parisouj *et al.*, 2023; Zounemat-Kermani *et al.*, 2021).

Após a agregação decendial, a série foi normalizada de modo a melhorar a convergência e favorecer a redução do desaparecimento do gradiente. Para o procedimento, utilizou-se a técnica de padronização normal (*Standard*) (Equação (29)), que transforma os dados para uma distribuição com média zero e desvio padrão unitário (Latifoglu; Kaya, 2023; Zhao, J. *et al.*, 2023; Zhao; Nie; Wen, 2023).

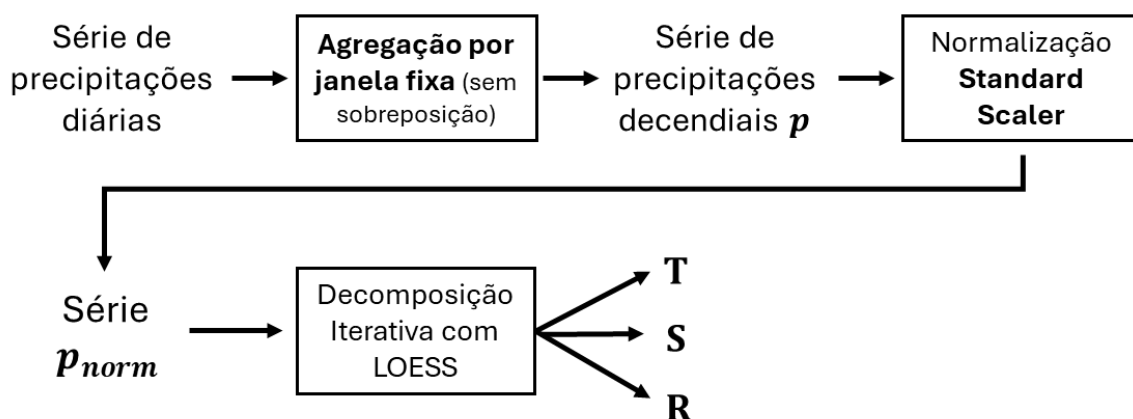
$$z = \frac{x - u}{s} \quad (29)$$

Em que  $z$  é o novo valor padronizado,  $x$  é o valor original da variável,  $u$  é a média da

série e  $s$  é o desvio padrão da série.

Para a decomposição da série temporal, foi adotado o método de decomposição em etapas com base no procedimento STL (*Seasonal and Trend decomposition using Loess*), proposto por Cleveland *et al.* (1990) e recomendado por Tebong *et al.* (2023). Esse método, segundo os autores, mostrou-se apropriado para capturar tendências e padrões sazonais em séries não lineares e de comportamento complexo, como as séries de precipitação. Considerando a presença de variabilidade interanual e padrões sazonais anuais (Ely, 2019; Hyndman; Athanasopoulos, 2021), definiu-se um horizonte de decomposição de 365 dias, correspondente a aproximadamente 37 decêndios. A Figura 22 expõe uma esquematização dos processos de transformação executados.

**Figura 22** –Fluxograma dos procedimentos de agregação, normalização e decomposição da série de precipitações decendiais



**Fonte:** a própria autora

A aplicação desse procedimento à série de precipitações decendiais resultou em três componentes distintas: tendência (**T**), sazonalidade (**S**) e ruído (**R**). Essas componentes, juntamente com a série de precipitação decendial original, foram utilizadas para a construção dos vetores de entrada (**X**) e de saída (**Y**) empregados nos modelos preditivos. Para a definição desses vetores, considerou-se a seguinte estrutura: a dimensão  $m$  como o número de valores históricos (*lags*) utilizados como variáveis explanatórias; e a dimensão  $d$  como o número de valores futuros previstos a cada execução do modelo.

Com base nesses parâmetros, a construção dos conjuntos de dados para modelagem respeitou a sequência temporal dos dados e garantiu que apenas

informações anteriores ao tempo de previsão fossem utilizadas como entrada. Assim, obtém-se as componentes :

$$\mathbf{X} = \begin{bmatrix} [x_1^m, x_2^m, \dots, x_{m-1}^m, x_m^m] \\ \vdots \\ [x_{i-m}^{i-1}, x_{i-m+1}^{i-1}, \dots, x_{i-2}^{i-1}, x_{i-1}^{i-1}] \\ \vdots \\ [x_{(n-d)-m+1}^{n-d}, x_{(n-d)-m+2}^{n-d}, \dots, x_{n-d}^{n-d}] \end{bmatrix} \text{ para } (m+1) \leq i \leq (n-d+1) \quad (30)$$

$$\mathbf{Y} = \begin{bmatrix} [x_{m+1}^n, \dots, x_{m+d}^n] \\ \vdots \\ [x_i^n, \dots, x_{i+d-1}^n] \\ \vdots \\ [x_{n-d+1}^n, \dots, x_n^n] \end{bmatrix} \text{ para } (m+1) \leq i \leq (n-d+1) \quad (31)$$

Considerando o interesse do estudo na previsão do próximo decêndio (10 dias), definiu-se que o horizonte de previsão ( $d$ ) corresponderia a um único período futuro ( $d = 1$ ), e que a janela de valores exploratórios ( $m$ ) seria composta pelos três decêndios anteriores ( $m = 3$ ). Para a divisão dos dados, estabeleceu-se que 80% das observações seriam utilizadas para a etapa de calibração dos modelos e os 20% restantes para validação. Essa proporção é compatível com práticas recorrentes na literatura, conforme discutido na seção 2.5 - Estado da Arte. Ao final do processo de segmentação, foram gerados os pares de vetores de entrada e saída para cada componente da série temporal:  $(\mathbf{p}_x, \mathbf{p}_y)_{cal}, (\mathbf{p}_x, \mathbf{p}_y)_{val}, (\mathbf{T}_x, \mathbf{T}_y)_{cal}, (\mathbf{T}_x, \mathbf{T}_y)_{val}, (\mathbf{S}_x, \mathbf{S}_y)_{cal}, (\mathbf{S}_x, \mathbf{S}_y)_{val}, (\mathbf{R}_x, \mathbf{R}_y)_{cal}, (\mathbf{R}_x, \mathbf{R}_y)_{val}$ .

### 3.2 CONFIGURAÇÃO E TREINAMENTO DAS REDES NEURAIAS

Para viabilizar a construção dos modelos híbridos com associação por conjunto, bem como dos modelos comparativos, foi necessário definir previamente as configurações das redes neurais e os procedimentos de treinamento. Essa etapa envolveu a seleção da linguagem de programação, das bibliotecas especializadas e da estratégia de ajuste dos hiperparâmetros.

A implementação foi realizada na linguagem *Python*, utilizando os módulos *Keras* e *TensorFlow*, amplamente reconhecidos pelo suporte avançado à construção, treinamento e otimização de redes neurais (Chollet; François, 2015; Martín Abadi *et al.*, 2015). A escolha desse ambiente fundamentou-se na ampla disponibilidade de

bibliotecas de código aberto, na compatibilidade com recursos de paralelização e na facilidade de replicação dos experimentos. As especificações do equipamento computacional e as versões dos principais pacotes empregados encontram-se detalhadas no Apêndice B.

Considerando a natureza contínua da variável analisada e a importância da dependência temporal na tarefa de previsão, adotaram-se redes neurais do tipo recorrente simples (RNN), LSTM e GRU ao longo do estudo. Para a calibração dessas redes, foi necessário ajustar hiperparâmetros como o número de camadas ocultas, a quantidade de unidades por camada, a taxa de aprendizado, o tamanho do *batch* e o número de *epochs*.

Visando automatizar esse processo e garantir configurações adequadas para cada modelagem, empregou-se uma abordagem empírica aleatória utilizando o módulo *Optuna*, em linguagem *Python*. Esse método permitiu automatizar a busca pelos melhores hiper parâmetros, reduzindo o tempo dedicado à calibração. O método foi configurado para executar 50 tentativas de ajuste (*random state = 37*), selecionando a melhor combinação com base nos resultados da função de perda (*loss function*). Os intervalos de valores considerados em cada calibração encontram-se apresentados no Quadro 3. A adoção de estratégias empíricas de calibração é comum na literatura, sendo observada em estudos como os de Li *et al.* (2019), Tebong *et al.* (2023), Zhang, Zheng e Wu (2020), Zhao *et al.* (2023), Zhao, Nie e Wen (2023).

**Quadro 3** – Valores propostos para os hiper parâmetros das redes neurais

Hiper parâmetros	Valores
Número de camadas ocultas	1,2,3
Número de células	25, 50, 100
Taxa de Aprendizado	0,1 , 0,01, 0,001
Tamanho do Batch	64, 128, 256
Número de <i>epochs</i> .	50, 100 e 200

A definição da função de ativação e do método de normalização foi orientada por testes preliminares realizados sobre a componente de tendência da série de precipitações da Estação Maringá. Os procedimentos e resultados desses testes encontram-se descritos no Apêndice A. Com base nos resultados obtidos,

estabeleceu-se como configuração final das redes neurais a inclusão da padronização normal dos dados de entrada (*Standard*) e o uso da função de ativação *tanh*.

Para avaliação do erro nas previsões e ajuste dos pesos internos das redes, empregou-se o Erro Quadrático Médio (*Mean Squared Error – MSE*) como função de perda. Essa métrica penaliza de forma mais severa os erros de maior magnitude, favorecendo a sensibilidade da rede aos extremos da série, como picos e vales (Jadon; Patil; Jadon, 2024; Sohrabbeig; Ardakanian; Musilek, 2023). A equação correspondente ao cálculo do MSE está apresentada na Equação (32).

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (32)$$

em que, *MSE* é o Erro Quadrático Médio;  $y_i$  é o valor real observado no tempo  $i$ ;  $\hat{y}_i$  foi o valor previsto para a variável com o modelo para o tempo  $i$ , e  $n$  é o número total valores observados.

Para a otimização dos pesos das redes neurais, foi adotado o algoritmo *Adaptive Moment Estimation* (ADAM), que combina s benefícios do método de momento com a adaptação dinâmica da taxa de aprendizado. Essa abordagem tem se mostrado eficaz para problemas de alta dimensionalidade, proporcionando convergência mais rápida e estável (Ahmed; Hassan; Mstafa, 2022; Peng *et al.*, 2021; Tebong *et al.*, 2023). Adicionalmente, com o objetivo de mitigar o risco de sobreajuste durante a calibração dos modelos, foi incorporada uma taxa de *dropout* de 20%. O treinamento foi conduzido com *random state* fixado em 37, garantindo a reprodutibilidade dos resultados (Chen *et al.*, 2023; Jiang, 2023; Zhao; Nie; Wen, 2023).

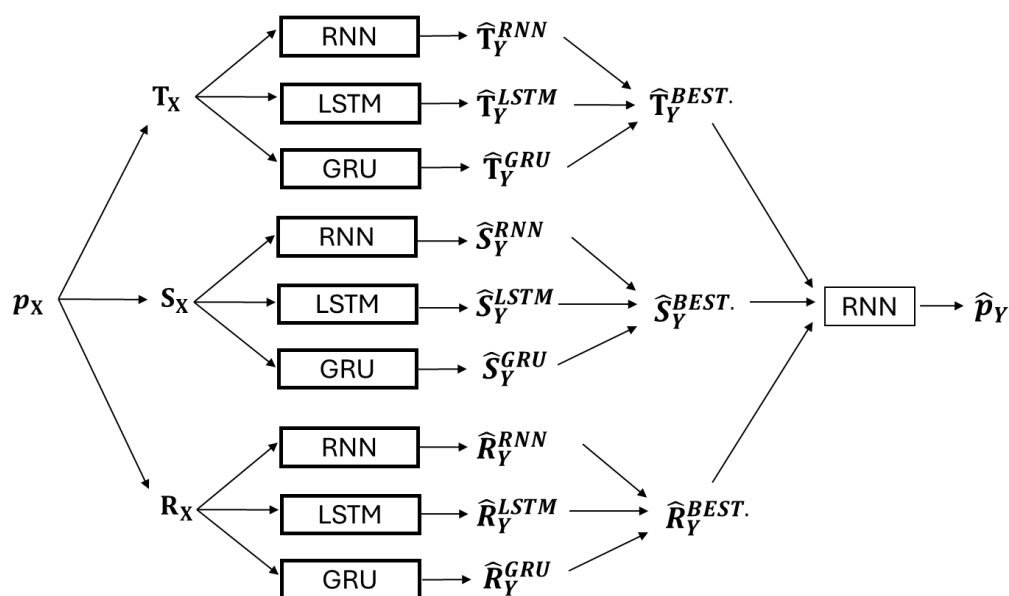
### 3.3 DESENVOLVIMENTO DOS MODELOS HÍBRIDOS

A construção dos modelos híbridos concentrou-se na combinação de previsões geradas por diferentes modelos individuais, por meio de estratégias de aprendizado por conjunto. Considerando que o objetivo da pesquisa foi a modelagem de séries temporais, e conforme discutido nas seções 2.4 - Modelos de aprendizado por conjunto e 2.5 - Estado da Arte, optou-se pela utilização de modelos de associação do tipo *Stacking*.

Para avaliar os efeitos da inclusão da associação em diferentes níveis, foram elaboradas cinco estruturas híbridas que preveem as precipitações decendiais. O

primeiro modelo híbrido, denominado modelo H1 (Figura 23), corresponde a uma associação de nível 1. Neste, os resultados a melhor previsão encontrada para as componentes de  $\hat{T}_Y$ ,  $\hat{S}_Y$ ,  $\hat{R}_Y$  (indicados pelo sobrescrito *BEST*) foram utilizados como entrada de uma rede neural recorrente, cuja finalidade é estimar a série original de precipitação decendial.

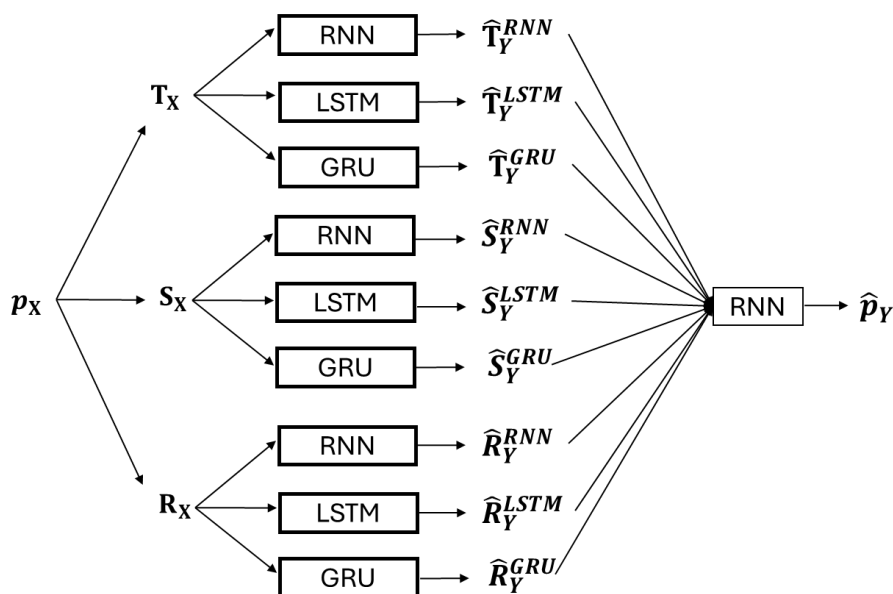
**Figura 23** – Estrutura do modelo híbrido H1



**Fonte:** a própria autora

O modelo H2, representado na Figura 24, também corresponde a uma associação de primeiro nível. No entanto, diferentemente do H1, este modelo utiliza todas as previsões para as componentes de tendência, sazonalidade e resíduo. Essa configuração permite que a rede neural recorrente avalie a contribuição relativa de cada previsão componente, ponderando seu impacto sobre a estimativa final da precipitação decendial ao longo do tempo.

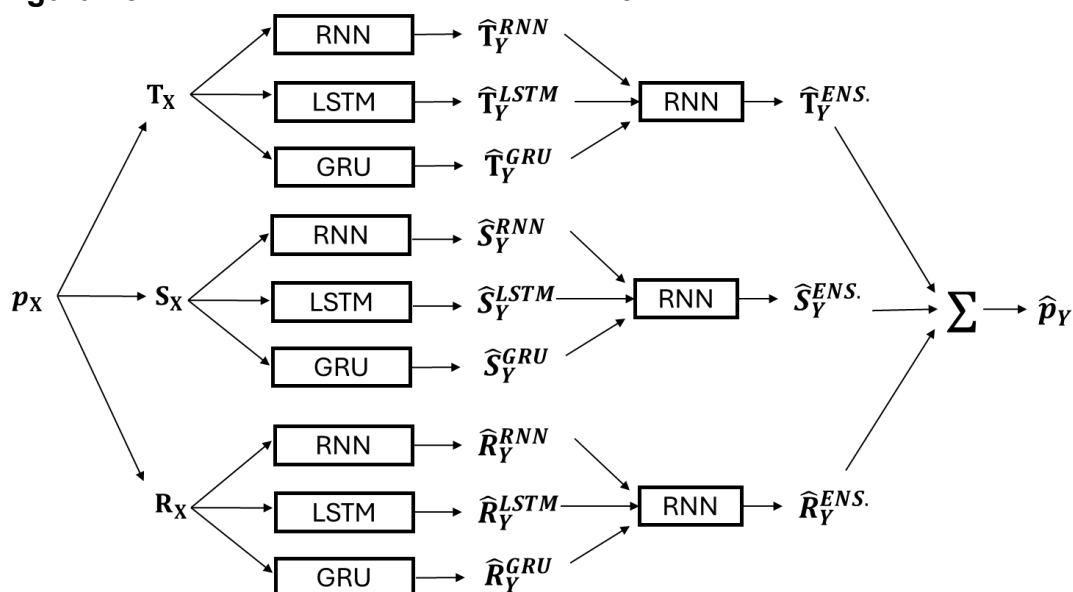
**Figura 24** – Estrutura do modelo híbrido H2



Fonte: a própria autora

O modelo H3, representado na Figura 25, propõe a aplicação de associações de primeiro nível realizadas separadamente para cada componente da série de precipitação. Em sua estrutura, as previsões para cada componente (tendência, sazonalidade e resíduo) são combinadas por uma rede neural recorrente, com o objetivo de aprimorar a previsão de cada componente individual. Na etapa final, as predições resultantes dessas associações ( $\hat{T}_Y^{ENS.}$ ,  $\hat{S}_Y^{ENS.}$ ,  $\hat{R}_Y^{ENS.}$ ) são somadas para a reconstrução da série de precipitação.

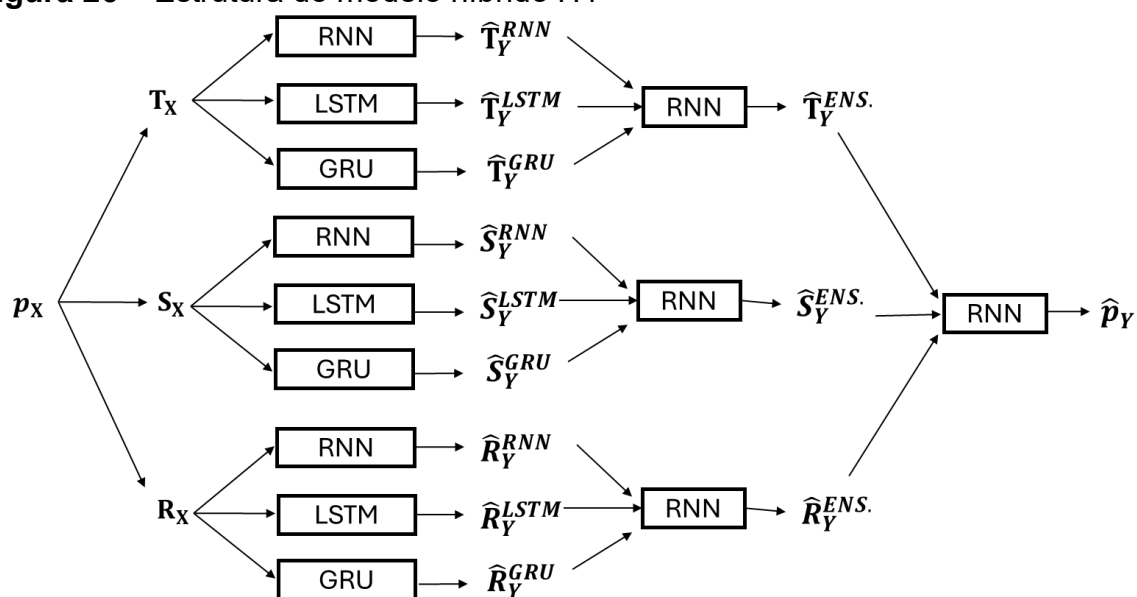
**Figura 25** – Estrutura dos modelo híbrido H3



Fonte: a própria autora

O modelo H4, ilustrado na Figura 26, caracteriza-se como uma estrutura de associação do tipo *Stacking* em dois níveis. Semelhante ao modelo anterior, as previsões para cada componente são inicialmente combinadas por redes neurais individuais, representando a primeira camada de associação. Como diferencial, as previsões resultantes de cada componente são integradas por uma nova rede neural, constituindo uma associação de segundo nível responsável pela previsão final da precipitação decendial.


**Figura 26** – Estrutura do modelo híbrido H4



Fonte: a própria autora

O último modelo híbrido desenvolvido, denominado Modelo H5 e apresentado na Figura 27, objetiva avaliar o impacto da aplicação da técnica de *Stacking* em modelos construídos diretamente sobre a série original, ou seja, sem a etapa prévia de decomposição temporal.

**Figura 27** – Estrutura do modelo híbrido H5




Fonte: a própria autora

### 3.4 MODELOS COMPARATIVOS PARA AVALIAÇÃO DE DESEMPENHO

Nesta seção, são descritos os modelos comparativos elaborados com o objetivo de avaliar o desempenho dos modelos com associação por conjunto apresentados na Seção 3.3 - Desenvolvimento dos Modelos Híbridos.

Inicialmente, foram construídos modelos baseados em redes neurais aplicados diretamente à série original de precipitação decendial, sem a realização da decomposição prévia (Figura 28). Esses modelos servem como referência para verificar se a complexidade adicional introduzida pelas estratégias de decomposição e associação é justificável em termos de desempenho preditivo.

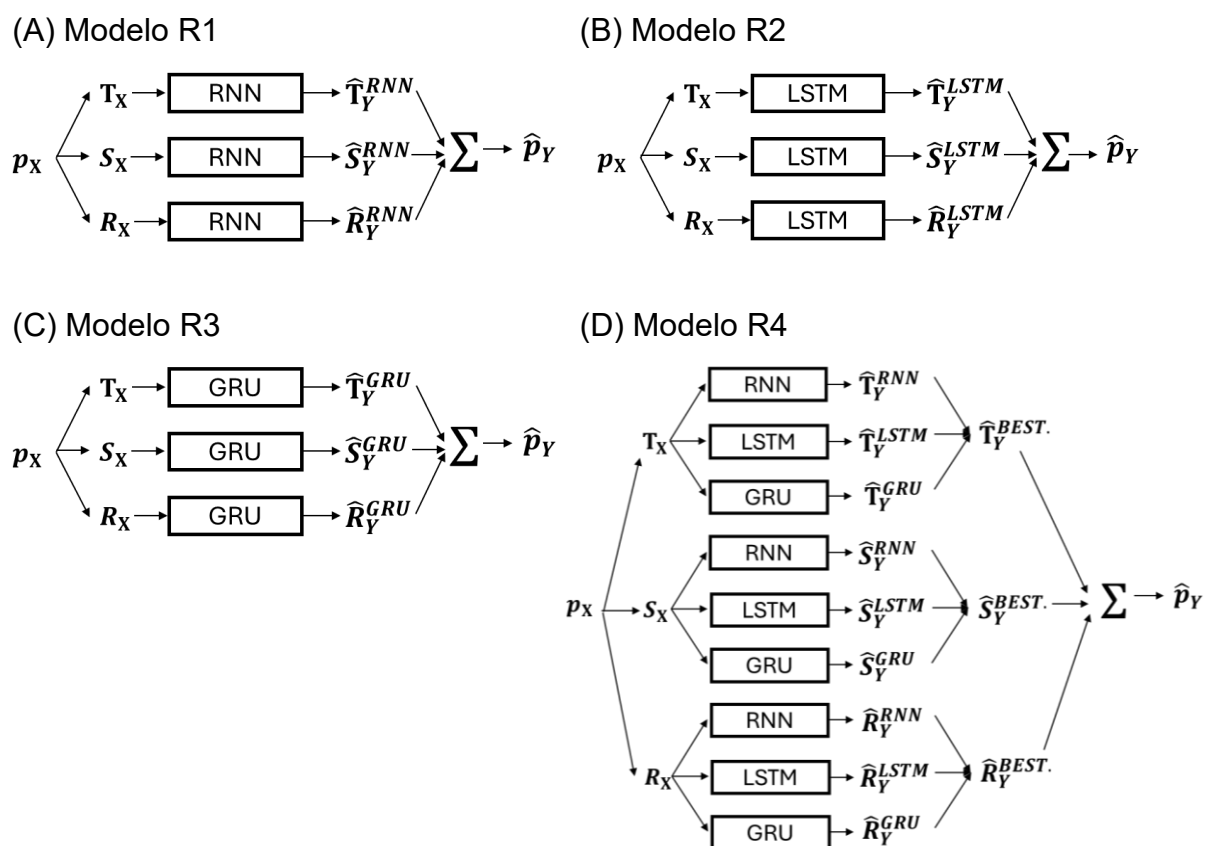
**Figura 28** – Estruturas dos (A) Modelo B1 (RNN), (B) Modelo B2 (LSTM) e (C) Modelo B3 (GRU).



**Fonte:** a própria autora

Em seguida, foram elaborados modelos individuais para as componentes de tendência, sazonalidade e resíduo, utilizando diferentes arquiteturas de redes neurais, seguidos pela recomposição direta dos valores previstos (Figura 29). Destaca-se que, devido à ausência de um mecanismo mais complexo para a combinação dessas componentes, tais modelos não são classificados como estratégias de associação por conjunto. Em complemento, apenas o modelo R4 (Figura 29 (D)) pode ser considerado um modelo híbrido, por ser o único a empregar múltiplas arquiteturas de redes neurais na modelagem das componentes.

**Figura 29** – Estruturas dos (A) Modelo R1 (RNN), (B) Modelo R2 (LSTM), (B) Modelo R3 (GRU), (D) Modelo R4 (Híbrido)



**Fonte:** a própria autora

Além dos sete modelos comparativos elaborados, foram também consideradas as previsões geradas por modelos determinísticos. Para isso, foram coletados dados de previsão decendial a partir da plataforma TIGGE (*THORPEX Interactive Grand Global Ensemble*). O TIGGE é um repositório global de previsões probabilísticas derivadas de modelos numéricos de previsão do tempo, desenvolvido por centros meteorológicos internacionais e disponibilizado para pesquisas científicas por meio dos portais do ECMWF e da Administração Meteorológica da China (CMA) (Bougeault *et al.*, 2010; Swinbank *et al.*, 2016).

No repositório, identificou-se a disponibilidade da variável de precipitação total (*total precipitation*, abreviação: *tp*), expressa em  $\text{kg/m}^2$ . Essa variável representa a soma das precipitações convectiva e de grande escala acumuladas desde o início da simulação. Para este estudo, foram utilizados os dados com horizonte de previsão de 240 *time-steps*, correspondendo a 240 horas ou um decêndio à frente (Mladek, 2016).

Dessa forma, selecionaram-se as previsões de controle do Modelo Global Atmosférico Brasileiro (BAM) e as previsões determinísticas do Sistema Integrado de

Previsões (IFS) (Bougeault *et al.*, 2010; Mladek, 2025). A escolha desses modelos baseou-se na disponibilidade de dados para o período e a região estudados.

O BAM é um modelo de previsão numérica do tempo fundamentado em equações de circulação atmosférica global, utilizado operacionalmente no Brasil para previsões de médio prazo. Desenvolvido e mantido pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), o modelo opera de forma independente, sem acoplamento direto a um modelo oceânico, adotando um esquema numérico semi-Lagrangiano e semi-implícito para a integração temporal (Figuerola *et al.*, 2016). Os dados referentes ao BAM disponíveis no repositório TIGGE abrangem o período de fevereiro de 2008 a abril de 2020 (Mladek, 2025).

O IFS é um modelo de previsão numérica do tempo desenvolvido e operado pelo Centro Europeu de Previsão de Tempo de Médio Prazo (ECMWF), amplamente empregado em aplicações de médio e longo prazo. Sua estrutura é baseada em uma abordagem acoplada, integrando componentes atmosféricas, oceânicas e de superfície terrestre. Assim como o BAM, o IFS adota um esquema numérico semi-Lagrangiano e semi-implícito para a integração temporal, o que assegura elevada eficiência computacional e precisão nas simulações. Os dados gerados por esse modelo estão disponíveis no repositório TIGGE desde outubro de 2006 (Mladek, 2025; Mladek; Lock, 2025).

As previsões de ambos os modelos são fornecidas no formato GRIB (*General Regularly-distributed Information in Binary form*), na resolução de  $0,5^\circ$  por  $0,5^\circ$ , correspondente a uma malha de aproximadamente 55 km por 55 km (Bougeault *et al.*, 2010). O código utilizado para a extração dos arquivos GRIB e leitura das variáveis de precipitação acumulada nas localidades analisadas encontram-se disponíveis na pasta 'TIGEE' do link a seguir, mediante requisição de acesso: [https://drive.google.com/drive/folders/1nAog9l-kkqEu74v12kWVjDr6Cxjzq8Ck?usp=drive\\_link](https://drive.google.com/drive/folders/1nAog9l-kkqEu74v12kWVjDr6Cxjzq8Ck?usp=drive_link)

Ressalta-se que os modelos determinísticos utilizados não foram simulados nem calibrados no escopo deste estudo. Suas previsões foram utilizadas diretamente, conforme disponibilizadas pelo repositório TIGGE, sem adaptações adicionais. Dessa forma, a análise comparativa foi restrita ao período de validação, permitindo avaliar a performance relativa dos modelos baseados em redes neurais frente a uma abordagem tradicional de previsão numérica.

### 3.5 ANÁLISE DA EFICIÊNCIA DOS MODELOS

Considerando o levantamento realizado por meio da revisão de forma sistemática (Figura 21), foram definidas as seguintes métricas de desempenho utilizadas nesta pesquisa: Coeficiente de Determinação ( $R^2$ ), Erro Médio Absoluto (MAE), Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Eficiência de Nash–Sutcliffe (NSE). Essas métricas foram selecionadas para a avaliação da qualidade preditiva dos modelos e das estratégias de associação implementadas.

O Coeficiente de Determinação ( $R^2$ ) foi utilizado para quantificar a proporção da variabilidade observada nos dados que foi explicada pelo modelo, em comparação com um modelo de referência que utiliza a média dos valores observados como predição. Seu cálculo está expresso na Equação (33). Valores de  $R^2$  próximos a 1 indicam maior capacidade explicativa do modelo, enquanto valores negativos revelam desempenho inferior ao da média dos dados, sugerindo inadequação do modelo à série observada (Dodge, 2010; Liu *et al.*, 2022; Moosavi; Gheisoori Fard; Vafakhah, 2022; Sibtain; Li; Saleem, 2020).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (33)$$

em que  $y$  é o valor real observado;  $\hat{y}$  foi o valor previsto para a variável com o modelo,  $\bar{y}$  é o valor médio observado, e  $n$  é o número total valores observados.

A Raiz Quadrada do Erro Quadrático Médio (RMSE), cujo cálculo está apresentado na Equação (34), foi utilizada como uma medida do desvio médio entre os valores observados e previstos. Essa métrica é amplamente empregada em estudos com séries temporais e apresenta a mesma unidade da variável avaliada, o que facilita sua interpretação em termos práticos (Li; Wang; Qiu, 2019; Li; Ma; Yang, 2018; Peng *et al.*, 2021; Song *et al.*, 2021; Tayyab *et al.*, 2022).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y})^2}{n}} \quad (34)$$

O Erro Médio Absoluto (MAE) foi calculado a partir da média das diferenças absolutas entre os valores previstos e os valores observados, como indicada pela Equação (35). Trata-se de uma medida direta da precisão do modelo, que apresenta a mesma unidade da variável modelada (Chen *et al.*, 2023; Peng *et al.*, 2021; Wen *et al.*, 2019; Zhang, X. *et al.*, 2021).

$$\text{MAE} = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \quad (35)$$

O Coeficiente de Nash-Sutcliffe (NSE) cuja fórmula está apresentada na Equação (36), foi utilizado para avaliar o desempenho dos modelos em relação a uma predição de referência, como a média histórica ou a persistência. Essa métrica é amplamente empregada em estudos hidrológicos e apresenta sensibilidade a valores extremos (Song *et al.*, 2021; Yu; Zhang; Singh, 2018; Zhang *et al.*, 2023a; Zhang; Zheng; Wu, 2020).

$$\text{NSE} = 1 - \frac{\sum_{t=1}^n (y_i - \hat{y}_i)^2}{\sum_{t=1}^n (y_i - y_i^*)^2} \quad (36)$$

Valores de NSE iguais a zero indicam desempenho equivalente ao modelo de referência, enquanto valores entre 0 e 1 indicam capacidade preditiva crescente, sendo que quanto mais próximo de 1, melhor o desempenho do modelo.

### 3.6 LOCAL DE ESTUDO

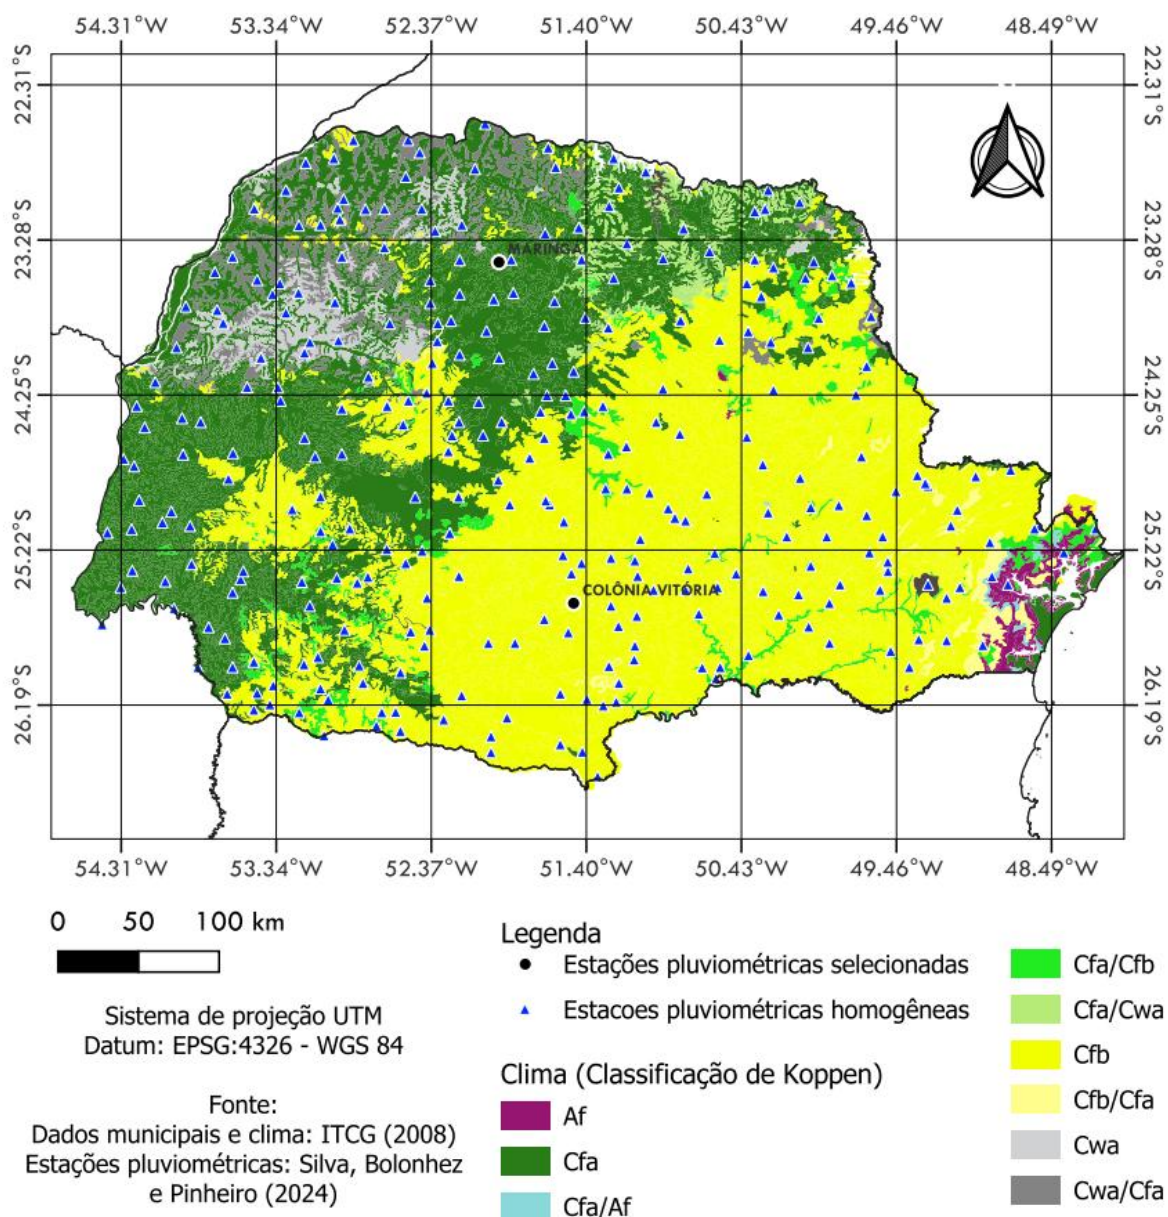
O estado do Paraná possui uma área de 199.298,981 km<sup>2</sup> e uma população residente estimada em 11,8 milhões de habitantes em 2024 (IBGE, 2024). De acordo com a classificação climática de Köppen (Alvares *et al.*, 2013; Nitsche *et al.*, 2019), predominam no estado os tipos Cfa (subtropical úmido com verão quente) e Cfb (subtropical úmido com verão ameno). De forma geral, observa-se uma transição de um padrão climático tropical na região norte para um subtropical nas áreas centro-sul do território. As precipitações no estado são influenciadas tanto por sistemas climáticos tropicais quanto extratropicais, além de fatores orográficos. Destacam-se, nesse contexto, a atuação e a migração da Alta Subtropical do Atlântico Sul, as incursões de massas de ar equatoriais provenientes da Amazônia e os sistemas frontais polares oriundos do Atlântico Sul (Alves *et al.*, 2021).

Para esta pesquisa, foram selecionadas duas estações meteorológicas localizadas em regiões distintas do Paraná, representando diferentes regimes climáticos. A seleção baseou-se no estudo de Silva, Bolonhez e Pinheiro (2024), o qual avaliou os dados de precipitação disponibilizados pelo Sistema Nacional de Informações sobre Recursos Hídricos, com ênfase na base de dados da plataforma HydroWeb, mantida pela Agência Nacional de Águas e Saneamento Básico (ANA).

Segundo os autores, existiam, até 25 km além dos limites estaduais, 1.442

estações pluviométricas cadastradas na base. A partir desse total, foram filtradas as estações com dados disponíveis de janeiro de 1975 a dezembro de 2019, índice de falhas inferior a 25% e localização integralmente dentro dos limites do estado. Como resultado, foram selecionadas 482 estações (Figura 30), que passaram por um controle de qualidade e preenchimento de dados com base na metodologia de Serrano-Notivoli, De Luis e Beguería (2017) (Silva; Bolonhez; Pinheiro, 2024).

**Figura 30** – Estações filtradas para o estado do Paraná



**Fonte:** a própria autora

No estudo de Silva, Bolonhez e Pinheiro (2024), foram aplicados quatro testes estatísticos de homogeneidade às séries históricas das estações pluviométricas do

estado do Paraná: Buishand (Buishand, 1982), Von Neumann (Von Neumann, 1941), SNHT - *Standard Normal Homogeneity Test* (Alexandersson, 1986) e Pettitt (Pettitt, 1979). Com base nos resultados desses testes, e segundo os critérios de classificação propostos por Wijngaard, Klein Tank e Können (2003), foram identificadas 355 estações consideradas homogêneas e adequadas para análises hidrológicas.

A seleção das duas estações pluviométricas analisadas nesta pesquisa foi feita a partir desse subconjunto, combinando critérios técnicos e a representatividade climática das regiões. Também foi considerada a familiaridade prévia com as localidades, o que favoreceu a contextualização dos padrões regionais e a interpretação dos resultados obtidos.

Dessa forma, os dois locais selecionados estão inseridos em diferentes classificações climáticas e padrões pluviométricos (Figura 30). Primeiro, a Estação Maringá (código 02351013), está localizada na região noroeste do estado, e atualmente apresenta pluviômetros convencionais e automáticos (INMET, 2025a, 2025b). Conforme Montanher e Minaki (2020), o clima no município é uma transição entre tropical e subtropical, com as maiores médias de precipitação ocorrendo no verão. Tal condição é decorrência da entrada de sistemas tropicais úmidos. Em contrapartida, os meses mais secos são os de julho e agosto, no inverno, com a intensificação dos sistemas extratropicais.

A segunda estação pluviométrica selecionada foi a Estação Colônia Vitória (código 02551008), do tipo convencional, situada na região sul do estado do Paraná (Agência Nacional de Água e Saneamento, 2024). Segundo o ITCG (2008), o clima no local possui características de climas oceânicos, com verões mais úmidos que o inverno, e chuvas abundantes distribuídas ao longo de todo o ano.

## 4 RESULTADOS E DISCUSSÃO


A seguir, são apresentados os resultados obtidos e a discussão sobre o uso de associações de redes neurais para a predição de precipitações decendiais. Para facilitar a consulta, os scripts desenvolvidos e os resultados brutos gerados nesta pesquisa estão disponíveis na pasta a seguir, mediante requisição de acesso: <https://drive.google.com/drive/folders/1nAog9l-kkqEu74v12kWVjDr6Cxjzq8Ck?usp=sharing>.

### 4.1 ESTRUTURAÇÃO E DECOMPOSIÇÃO DAS SÉRIES DE PRECIPITAÇÃO DECENDIAL

As séries temporais de precipitação utilizadas neste estudo foram originalmente disponibilizadas na escala diária, totalizando 16.436 registros por estação pluviométrica. Para a análise, os dados foram convertidos para a escala decendial, o que resultou em 1.643 registros de precipitações decendiais. A série foi então segmentada em dois subconjuntos: 80% dos dados foram utilizados para a etapa de calibração e os 20% restantes para a validação, respeitando-se a ordem temporal dos dados e evitando sobreposição entre os períodos. Dessa forma, a série de calibração compreendeu o intervalo de 09/02/1975 a 12/12/2010, totalizando 1.310 pares de variáveis de entrada e saída, enquanto a série de validação abrangeu o período de 11/01/2011 a 25/12/2019, com 328 pares.

Com o intuito de aprimorar a capacidade preditiva dos modelos, a série original de precipitação decendial foi submetida a um processo de decomposição em etapas, utilizando o método iterativo com LOESS (STL). Essa técnica permitiu a separação das componentes estruturais da série (tendência, sazonalidade e resíduo), favorecendo uma modelagem mais direcionada e interpretável. O tempo de processamento da decomposição foi de 9 segundos para a Estação Maringá e 4 segundos para a Estação Colônia Vitória. Os resultados desse procedimento estão apresentados nas Figura 31 e Figura 32, com suas respectivas estatísticas descritivas nas Tabela 1 e Tabela 2.

**Figura 31** – Série de precipitação decendial e suas componentes segundo o processo em etapas e completo – Estação Maringá (02351013)




Fonte: autora

**Tabela 1** – Análise descritiva das componentes derivadas da decomposição completa e em etapas – Estação Maringá (02351013)

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Precipitação Decendial (Completa)</b>	45,49	47,51	0,00	8,30	31,50	68,40	321,76
<b>Precipitação Decendial (Etapas)</b>	45,49	47,51	0,00	8,30	31,50	68,40	321,76
<b>Tendência (Completa)</b>	45,49	23,31	2,00	27,47	43,48	60,32	132,09
<b>Tendência (Etapas)</b>	45,43	35,45	-47,01	18,77	40,79	67,39	210,39
<b>Sazonalidade (Completa)</b>	0,01	8,36	-23,60	-5,99	-0,76	5,40	26,28
<b>Sazonalidade (Etapas)</b>	0,02	16,46	-55,51	-10,55	-1,05	9,91	65,20
<b>Resíduo (Completa)</b>	-0,01	37,79	-114,65	-23,96	-6,99	15,45	199,55
<b>Resíduo (Etapas)</b>	0,04	28,75	-109,70	-17,17	-0,80	15,71	131,48

Fonte: a própria autora

**Figura 32** – Série de precipitação decendial e as componentes das decomposições STL – Estação Colônia Vitória (02551008)



Fonte: a própria autora

**Tabela 2** – Análise descritiva das componentes derivadas da decomposição completa e em etapas – Estação Colônia Vitória (02551008)

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Precipitação Decendial (Completa)</b>	54,01	52,81	0,00	14,33	40,60	77,47	382,40
<b>Precipitação Decendial (Etapas)</b>	54,01	52,82	0,00	14,33	40,60	77,4	382,40
<b>Tendência (Completa)</b>	54,04	23,15	4,04	37,59	51,29	67,60	182,38
<b>Tendência (Etapas)</b>	54,02	37,16	-30,28	26,87	49,48	74,17	246,72
<b>Sazonalidade (Completa)</b>	-0,01	10,48	-24,28	-6,17	-0,74	5,06	47,94
<b>Sazonalidade (Etapas)</b>	-0,01	19,33	-93,47	-12,08	-1,04	10,04	103,37
<b>Resíduo (Completa)</b>	-0,02	43,76	-113,60	-29,46	-7,13	20,41	254,28
<b>Resíduo (Etapas)</b>	0,00	32,85	-113,80	-18,85	-1,58	17,99	165,95

Além da semelhança gráfica, verificou-se que as séries recompostas de

precipitação decendial (Figura 31 e Figura 32) derivadas dos dois processos de decomposição apresentaram médias idênticas e desvios padrão equivalentes, com coeficientes de determinação unitário ( $R^2=1$ ). No entanto, ao avaliar separadamente as componentes da série, observa-se que essa equivalência na recomposição foi obtida a partir de partes distintas, ou seja, com divergências expressivas entre as componentes.

Na tendência, por exemplo, as médias obtidas pela decomposição em etapas apresentaram variações percentuais discretas em relação à decomposição completa (-0,14% em Maringá e 0,04% em Colônia Vitória). Contudo, os coeficientes de determinação foram baixos ( $R^2 = 0,133$  em Maringá e  $R^2 = -0,108$  em Colônia Vitória), indicando que, mesmo com médias semelhantes, houve perda de aderência ao comportamento original. Essa limitação se torna ainda mais evidente ao analisar o desvio padrão, que apresentou reduções de 52,10% em Maringá e 60,52% em Colônia Vitória, sugerindo perda de variabilidade na componente estimada.

Para a sazonalidade, as diferenças entre os dois processos de decomposição foram ainda mais pronunciadas. As médias estimadas pela abordagem em etapas variaram de -173,20% em Maringá e 34,64% em Colônia Vitória, em relação à decomposição completa. Os desvios padrão também indicaram reduções acentuadas, de 96,82% e 84,42%, respectivamente. Essa divergência foi reforçada pelos coeficientes de determinação negativos ( $R^2 = -1,27$  em Maringá e  $R^2 = -0,92$  em Colônia Vitória), demonstrando que a decomposição em etapas não conseguiu reproduzir adequadamente o padrão sazonal originalmente identificado pela decomposição completa.

Na componente resíduo, a diferença entre as médias foi a mais expressiva, atingindo 420,78% em Maringá e 79,29% em Colônia Vitória. Apesar disso, os desvios padrão apresentaram variações mais moderadas (23,92% e 24,93%, respectivamente). Essa também foi a componente com maior correspondência entre as decomposições completa e em etapas, com  $R^2 = 0,68$  na avaliação das séries de ambas as estações. Com isso, embora o processo em etapas tenha impactado a média dos resíduos, o padrão geral de variação se manteve.

Diante do resultado obtido com o processo decomposição em etapas, é necessário destacar que esse procedimento ainda reflete de maneira mais realista as condições de predição em aplicações práticas. Em um contexto operacional, os modelos de predição são alimentados somente com os dados disponíveis até a data

da simulação, sem acesso a valores futuros da série.

Conforme discutido por Tan *et al.* (2018), dois critérios são fundamentais para garantir o realismo nos modelos preditivos: primeiro, informações futuras não devem ser utilizadas no processo de decomposição e, segundo, tanto a decomposição quanto os modelos de predição devem ser adaptáveis. Assim, ainda que as componentes geradas pela decomposição em etapas não apresentem qualidade idênticas às obtidas com a série completa, essa estratégia preserva a coerência temporal necessária para aplicações práticas (Jiao; He, 2024; Johnny; Pai; Adarsh, 2020; Wu *et al.*, 2024).

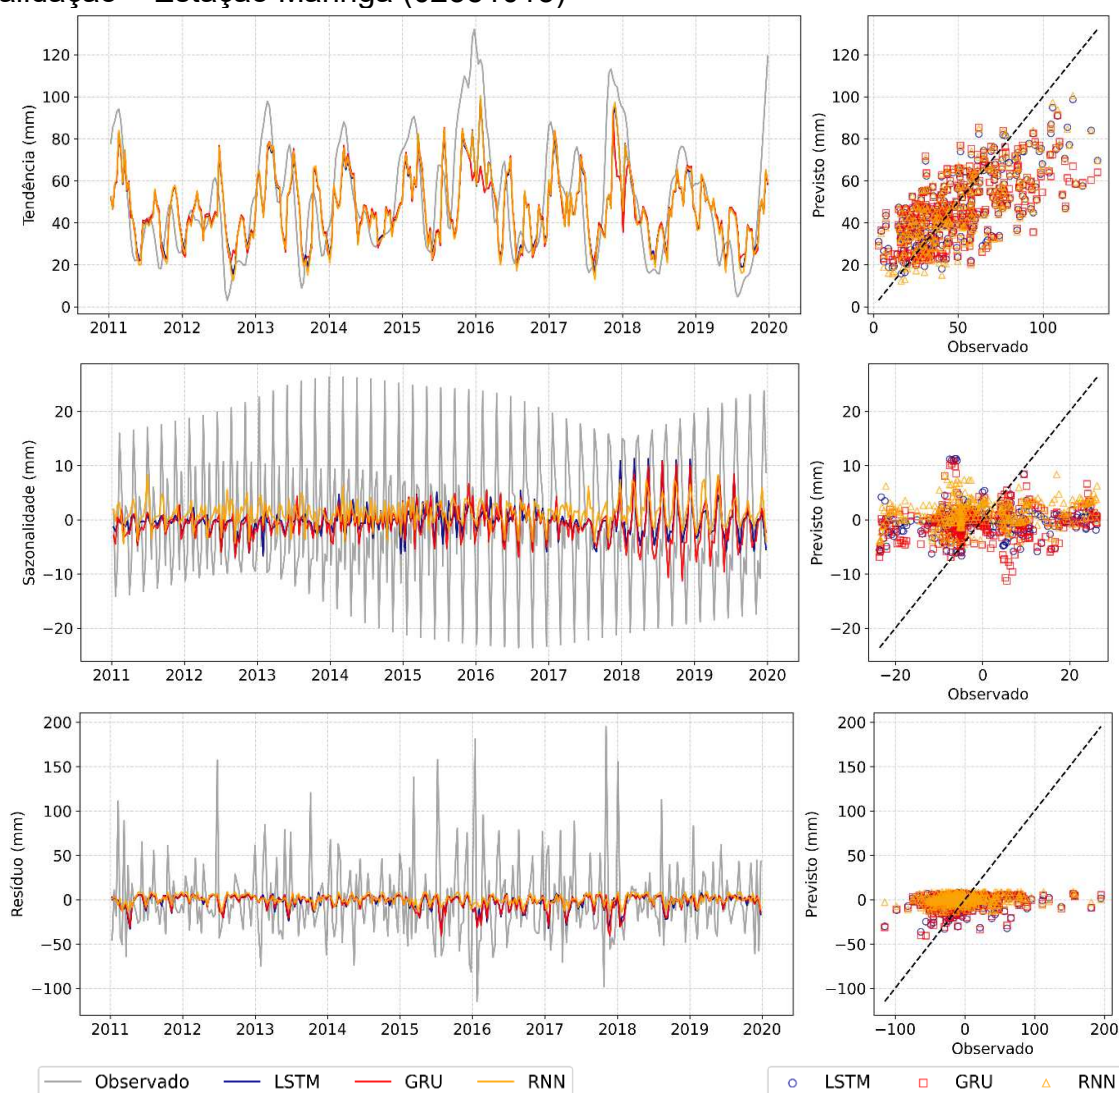
A necessidade de respeitar a independência temporal é reforçada pela observação de que múltiplos estudos revisados não seguiram essa restrição metodológica, o que pode ter introduzido viés nos resultados reportados. Pesquisas como as de Jiang (2023), Li, Ma e Yang (2018), Parvize e Ghorbanpour (2024) e Zhao, Nie, Wen (2023) utilizaram séries completas para compor variáveis explanatórias em seus modelos híbridos, comprometendo a separação entre entradas e variáveis previstas. Esse procedimento pode ter superestimado a qualidade preditiva obtida, o que reforça a necessidade de um rigor metodológico maior na escolha da abordagem de decomposição.

Neste estudo, como as componentes geradas pela decomposição em etapas foram utilizadas como variáveis de entrada nos modelos híbridos e de associação, assume-se que um dos papéis das redes neurais é justamente compensar os erros introduzidos pela decomposição, ajustando a predição da precipitação decendial a partir dessas informações. Isso significa que o desempenho final dos modelos será diretamente impactado pelas características das componentes disponibilizadas como entrada.

## 4.2 MODELAGEM DAS COMPONENTES

Três arquiteturas de redes neurais foram utilizadas na modelagem das componentes das séries de precipitação decendial. Os resultados obtidos para a Estação Maringá (02351013) e Colônia Vitoria (02551008) estão ilustradas na Figura 33 e Figura 34, respectivamente. As performances dos modelos são apresentadas nas Tabela 3 e Tabela 4, enquanto as configurações e hiperparâmetros otimizados estão detalhados no Apêndice C.

**Figura 33** – Predição para as componentes da série de precipitação decendial – Validação – Estação Maringá (02351013)

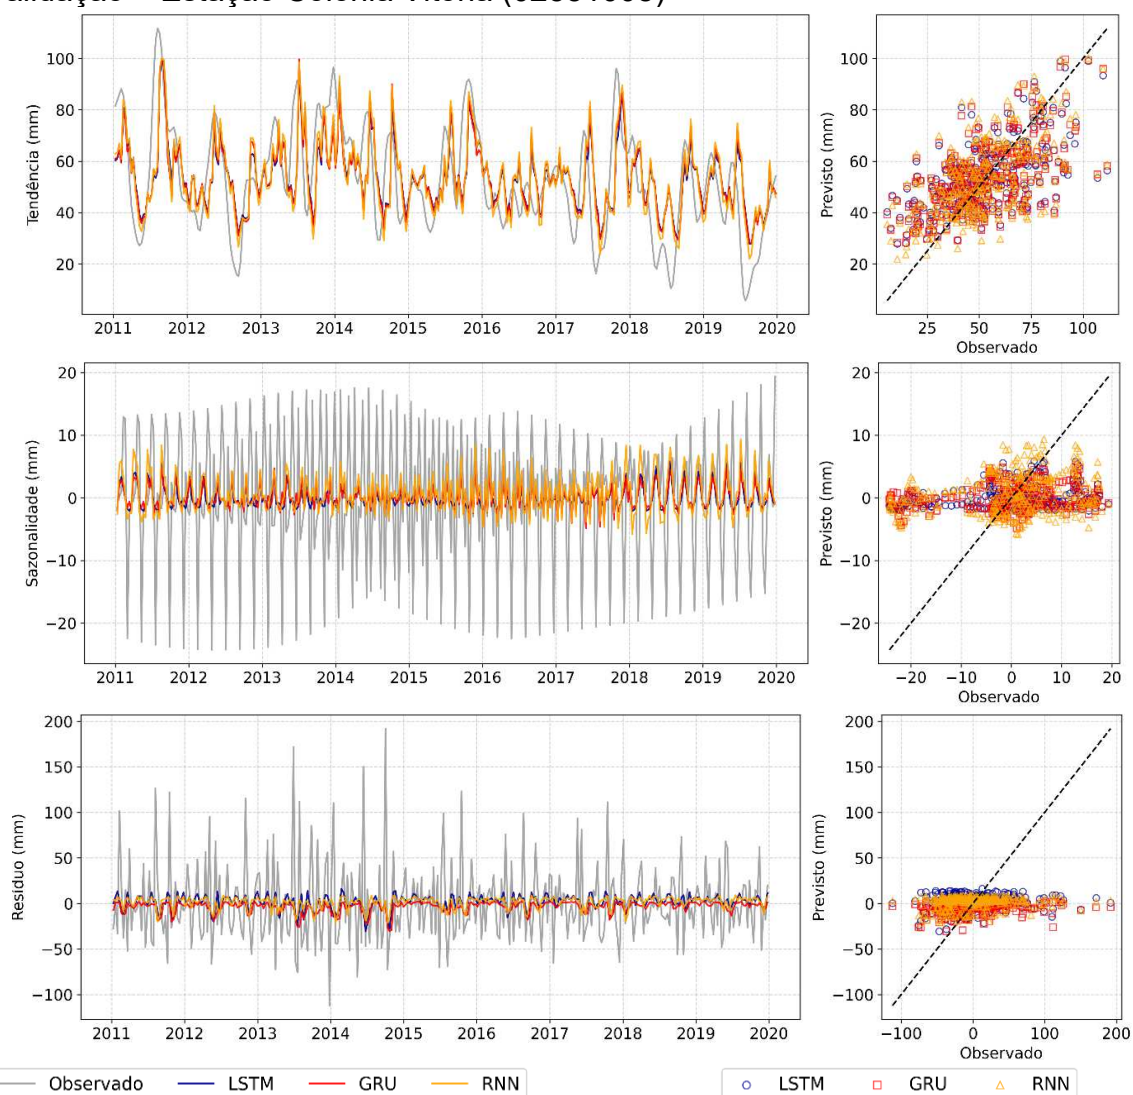


Fonte: a própria autora

**Tabela 3** – Métricas de performance dos modelos de predição das componentes da série de precipitação decendial – Estação Maringá (02351013)

Modelo	Calibração					Validação				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>RNN<sub>TEND.</sub></b>	13,13	264,28	16,26	0,457	0,457	15,58	402,26	20,06	0,451	0,451
<b>LSTM<sub>TEND.</sub></b>	13,20	264,17	16,25	0,457	0,457	15,54	401,74	20,04	0,452	0,452
<b>GRU<sub>TEND.</sub></b>	13,04	261,48	16,17	0,463	0,463	16,51	454,20	21,31	0,380	0,380
<b>RNN<sub>SAZON.</sub></b>	5,64	45,43	6,74	0,108	0,108	9,86	142,04	11,92	0,027	0,027
<b>LSTM<sub>SAZON.</sub></b>	5,33	41,84	6,47	0,179	0,179	9,73	146,65	12,11	-0,005	-0,005
<b>GRU<sub>SAZON.</sub></b>	5,45	43,67	6,61	0,143	0,143	9,60	144,46	12,02	0,010	0,010
<b>RNN<sub>RESÍD.</sub></b>	27,09	1290,58	35,92	0,02	0,024	31,39	1823,88	42,71	0,02	0,019
<b>LSTM<sub>RESÍD.</sub></b>	26,26	1264,48	35,56	0,04	0,044	30,67	1809,22	42,54	0,03	0,027
<b>GRU<sub>RESÍD.</sub></b>	26,41	1271,09	35,65	0,04	0,039	30,40	1791,88	42,33	0,04	0,036

**Figura 34** – Predição para as componentes da série de precipitação decendial – Validação – Estação Colônia Vitória (02551008)



Fonte: a própria autora

**Tabela 4** – Métricas de performance dos modelos de predição das componentes da série de precipitação decendial – Estação Colônia Vitória (02551008)

Modelo	Calibração					Validação				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>RNN<sub>TEND.</sub></b>	14,08	329,1	18,1	0,419	0,419	13,09	276,2	16,6	0,324	0,324
<b>LSTM<sub>TEND.</sub></b>	14,16	329,6	18,2	0,418	0,418	12,87	267,7	16,4	0,345	0,345
<b>GRU<sub>TEND.</sub></b>	14,02	324,0	18,0	0,428	0,428	12,99	269,7	16,4	0,340	0,340
<b>RNN<sub>SAZON.</sub></b>	7,66	101,93	10,10	0,058	0,058	8,12	110,68	10,52	0,037	0,037
<b>LSTM<sub>SAZON.</sub></b>	7,56	103,24	10,16	0,046	0,046	8,03	109,92	10,48	0,044	0,044
<b>GRU<sub>SAZON.</sub></b>	7,42	101,12	10,06	0,065	0,065	8,01	110,89	10,53	0,035	0,035
<b>RNN<sub>RESÍD.</sub></b>	32,28	1858,00	43,10	0,038	0,038	32,19	1812,99	42,58	0,016	0,016
<b>LSTM<sub>RESÍD.</sub></b>	32,39	1862,47	43,16	0,036	0,036	32,33	1831,05	42,79	0,007	0,007
<b>GRU<sub>RESÍD.</sub></b>	31,63	1893,27	43,51	0,020	0,020	31,58	1835,54	42,84	0,004	0,004

Analisando as métricas expostas nas Tabela 3 e Tabela 4, observa-se que nenhuma componente foi com desempenho satisfatório pelas redes neurais recorrentes. A modelagem da tendência obteve desempenho de baixo à moderado, com coeficientes de determinação ( $R^2$ ) variando entre 0,32 e 0,45 nas localidades avaliadas. O que sugere uma dificuldade das arquiteturas testadas em capturar o padrão geral dessa componente, mesmo sendo projetadas para lidar com sequências temporais. Essa limitação também é consequência da alta variabilidade na série original de precipitações, um comportamento esperado para tal variável climática dessa magnitude.

Apesar disso, a tendência foi a componente que apresentou o melhor desempenho entre as três analisadas. Esse padrão já foi observado em outros estudos que empregaram essa técnica de decomposição, nos quais a maior regularidade e estabilidade da componente de tendência, em comparação com as demais componentes, favoreceu o desempenho preditivo (Ren; Ghazali, 2025; Zhao, L. *et al.*, 2023). Em contextos de séries temporais com menor magnitude e variabilidade, como as de deslocamentos de superfície ou umidade do solo, essa maior estabilidade possibilitou a obtenção de predições de alta precisão mesmo com arquiteturas relativamente simples.

Para as componentes de sazonalidade e resíduo, o desempenho foi insatisfatório. No caso da sazonalidade, embora os modelos tenham tentado capturar o comportamento cíclico da série, observou-se erros na identificação dos instantes de máximos e mínimos, além da subestimação das predições. Os coeficientes de determinação próximos de zero reforçam a limitação dos modelos em reproduzir adequadamente essa estrutura. Estudos aplicado a outras áreas, como vazões de reservatórios (Ren; Ghazali, 2025; Tebong *et al.*, 2023), indicam que a modelagem da componente sazonal tende a ser complexa, sendo melhorada somente com a inclusão de variáveis externas que forneçam contexto adicional para a previsão dos ciclos.

No caso do resíduo, o desempenho foi baixo era esperado, dada sua natureza essencialmente aleatória. Além dos  $R^2$  reduzidos, os modelos apresentaram erros médios absolutos (MAE) superiores a 30 mm e RMSE acima de 40 mm, indicando que as redes neurais recorrentes tiveram baixa capacidade de extrair padrões considerados úteis nessa componente. Trabalhos recentes (Huang *et al.*, 2022; Zhao, L. *et al.*, 2023) sugerem que arquiteturas mais sofisticadas, como *Transformers*, podem ser mais eficazes para a captura de padrões de curto prazo ainda presentes

nessa componente.

A análise das representações das predições (Figura 33 e Figura 34) e das estatísticas descritivas (Apêndice C) permitiu identificar divergências que não foram captados pelas métricas globais. Na tendência, por exemplo, os valores médios e a dispersão das predições foram bastante similares entre as arquiteturas, indicando um padrão comum de subestimação. Já no resíduo, embora nenhuma arquitetura tenha conseguido captar adequadamente a variabilidade da série observada, o modo como os erros se distribuíram ao longo do tempo diferiu entre os modelos.

Uma comparação das métricas de performance obtidas para a estação pluviométrica de Maringá e de Colônia Vitória é apresentada na Tabela 5. Para a componente de tendência, todos os modelos apresentaram coeficientes de determinação ( $R^2$ ) superiores na Estação Maringá, em comparação à Estação Colônia Vitória, mesmo que os erros (RMSE) tenham sido mais elevados nessa localidade. Esse padrão sugere que, embora os modelos tenham sido mais eficazes em capturar a estrutura geral da série em Maringá, a maior dispersão da componente da tendência no local pode ter contribuído para o aumento dos erros. Essa hipótese é reforçada pelos maiores desvios padrão observados para a tendência na Estação Maringá (27,11mm), em comparação com a Estação Colônia Vitória (20,24mm) (Apêndice C).

**Tabela 5** – Comparação das métricas  $R^2$  e RMSE (mm) das componentes entre as estações - Validação

Modelo	$R^2$			RMSE (mm)		
	Maringá	Colônia Vitória	Variação %	Maringá	Colônia Vitória	Variação %
<b>RNN</b> <sub>TEND.</sub>	0,451	0,324	28,16%	20,06	16,6	17,25%
<b>LSTM</b> <sub>TEND.</sub>	0,452	0,345	23,67%	20,04	16,4	18,16%
<b>GRU</b> <sub>TEND.</sub>	0,380	0,340	10,53%	21,31	16,4	23,04%
<b>RNN</b> <sub>SAZON.</sub>	0,027	0,037	-37,04%	11,92	10,52	11,74%
<b>LSTM</b> <sub>SAZON.</sub>	-0,005	0,044	980,00%	12,11	10,48	13,46%
<b>GRU</b> <sub>SAZON.</sub>	0,010	0,035	-250,00%	12,02	10,53	12,40%
<b>RNN</b> <sub>RESÍD.</sub>	0,02	0,016	20,00%	42,71	42,58	0,30%
<b>LSTM</b> <sub>RESÍD.</sub>	0,03	0,007	76,67%	42,54	42,79	-0,59%
<b>GRU</b> <sub>RESÍD.</sub>	0,04	0,004	90,00%	42,33	42,84	-1,20%

No caso da sazonalidade, observam-se variações percentuais expressivas nos valores de  $R^2$  entre as estações, chegando a diferenças de até 980%. Contudo, é importante ressaltar que esses percentuais decorrem de coeficientes absolutos muito

baixos ou negativos, o que limita sua interpretação como indicador de melhora real. A baixa capacidade dos modelos em reproduzir a estrutura sazonal também é evidenciada pelos desvios padrão das predições, como por exemplo para a Estação Colônia Vitória. Nessa localidade, os desvios padrão da predição da sazonalidade variaram entre 1,73 e 3,17 em Colônia Vitória, frente a 10,74 da série observada de validação (Apêndice C).

Para o resíduo, os coeficientes de determinação permaneceram baixos em ambas as estações, com variações muito pequenas no RMSE, inferiores a 1,2%. Entretanto, as séries observadas na validação apresentaram desvios padrão acima de 43 mm, enquanto as predições das arquiteturas raramente ultrapassaram 8 mm (Apêndice C). Esses resultados indicam que, independentemente da arquitetura ou da localidade, os modelos apresentaram limitações significativas na captura da estrutura residual.

Conforme destacado por Ng et al. (2023), a qualidade das subcomponentes geradas durante o processo de decomposição exerce influência direta sobre o desempenho preditivo dos modelos. Segundo os autores, subcomponentes bem estruturadas favorecem ganhos significativos, enquanto componentes mal definidas tendem a comprometer os resultados.

Nesse contexto, os resultados deste estudo também refletem essa condição, especialmente diante da divergência entre as variáveis de entrada e a variável prevista. Novamente, as séries explanatórias foram geradas com base apenas nos dados históricos disponíveis até o instante da predição (decomposição em etapas), enquanto a variável a ser prevista foi obtida a partir da decomposição completa da série. Essa diferença pode ter dificultado o ajuste dos modelos, influenciando negativamente os resultados, particularmente para as componentes de sazonalidade e resíduo.

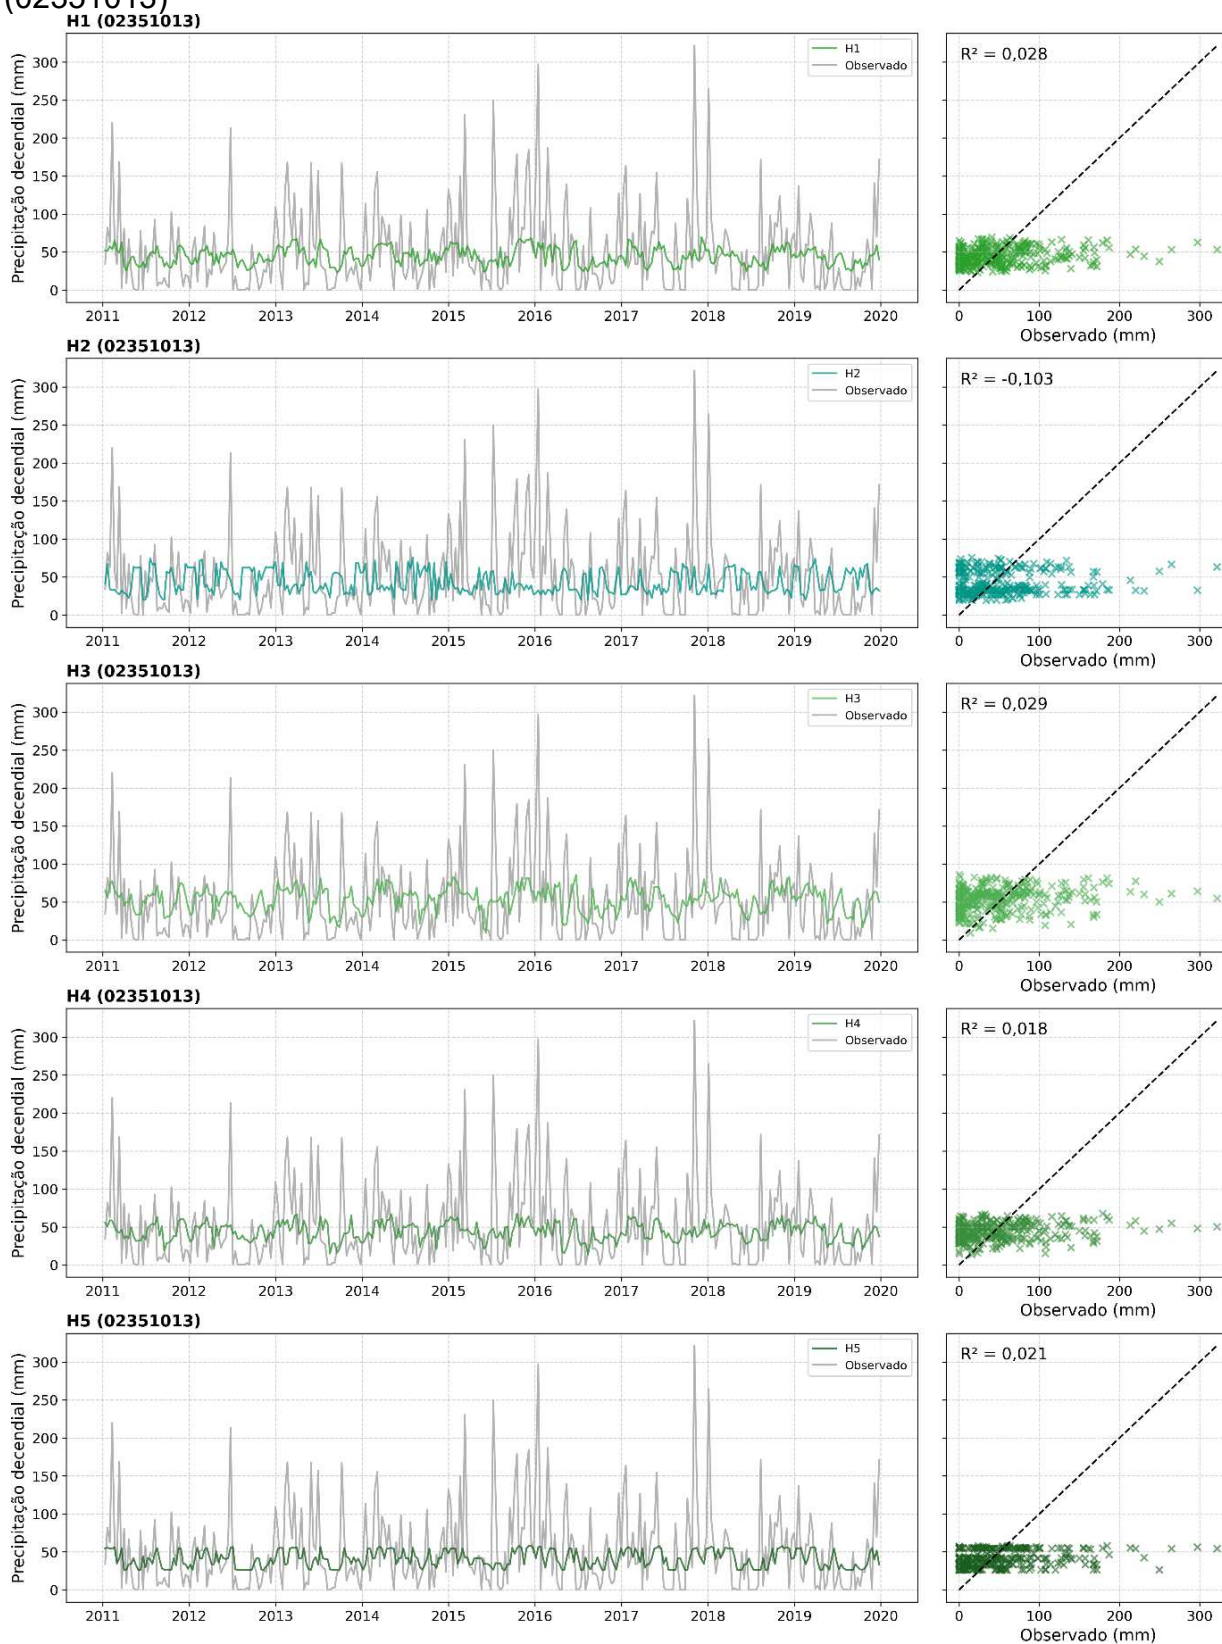
De forma geral, as análises estatísticas indicam que, embora o desempenho médio das redes tenha sido semelhante, suas respostas não são idênticas, sendo influenciadas por particularidades climáticas locais e pelas características das componentes geradas. Ainda que sutis, as diferenças observadas entre as arquiteturas sugerem que a combinação de suas características poderia vir a contribuir para o aprimoramento da capacidade preditiva dos modelos de precipitação decendial.

### 4.3 MODELAGEM DA PRECIPITAÇÃO DECENDIAL

Cinco modelos híbridos foram calibrados e simulados para a predição da precipitação decendial nas estações analisadas. Os resultados obtidos no período de validação estão ilustrados nas Figura 35 e Figura 36, enquanto a Tabela 6 apresenta as principais métricas de desempenho. As configurações completas dos modelos calibrados, bem como suas análises descritivas estão, encontram-se disponíveis no Apêndice B.

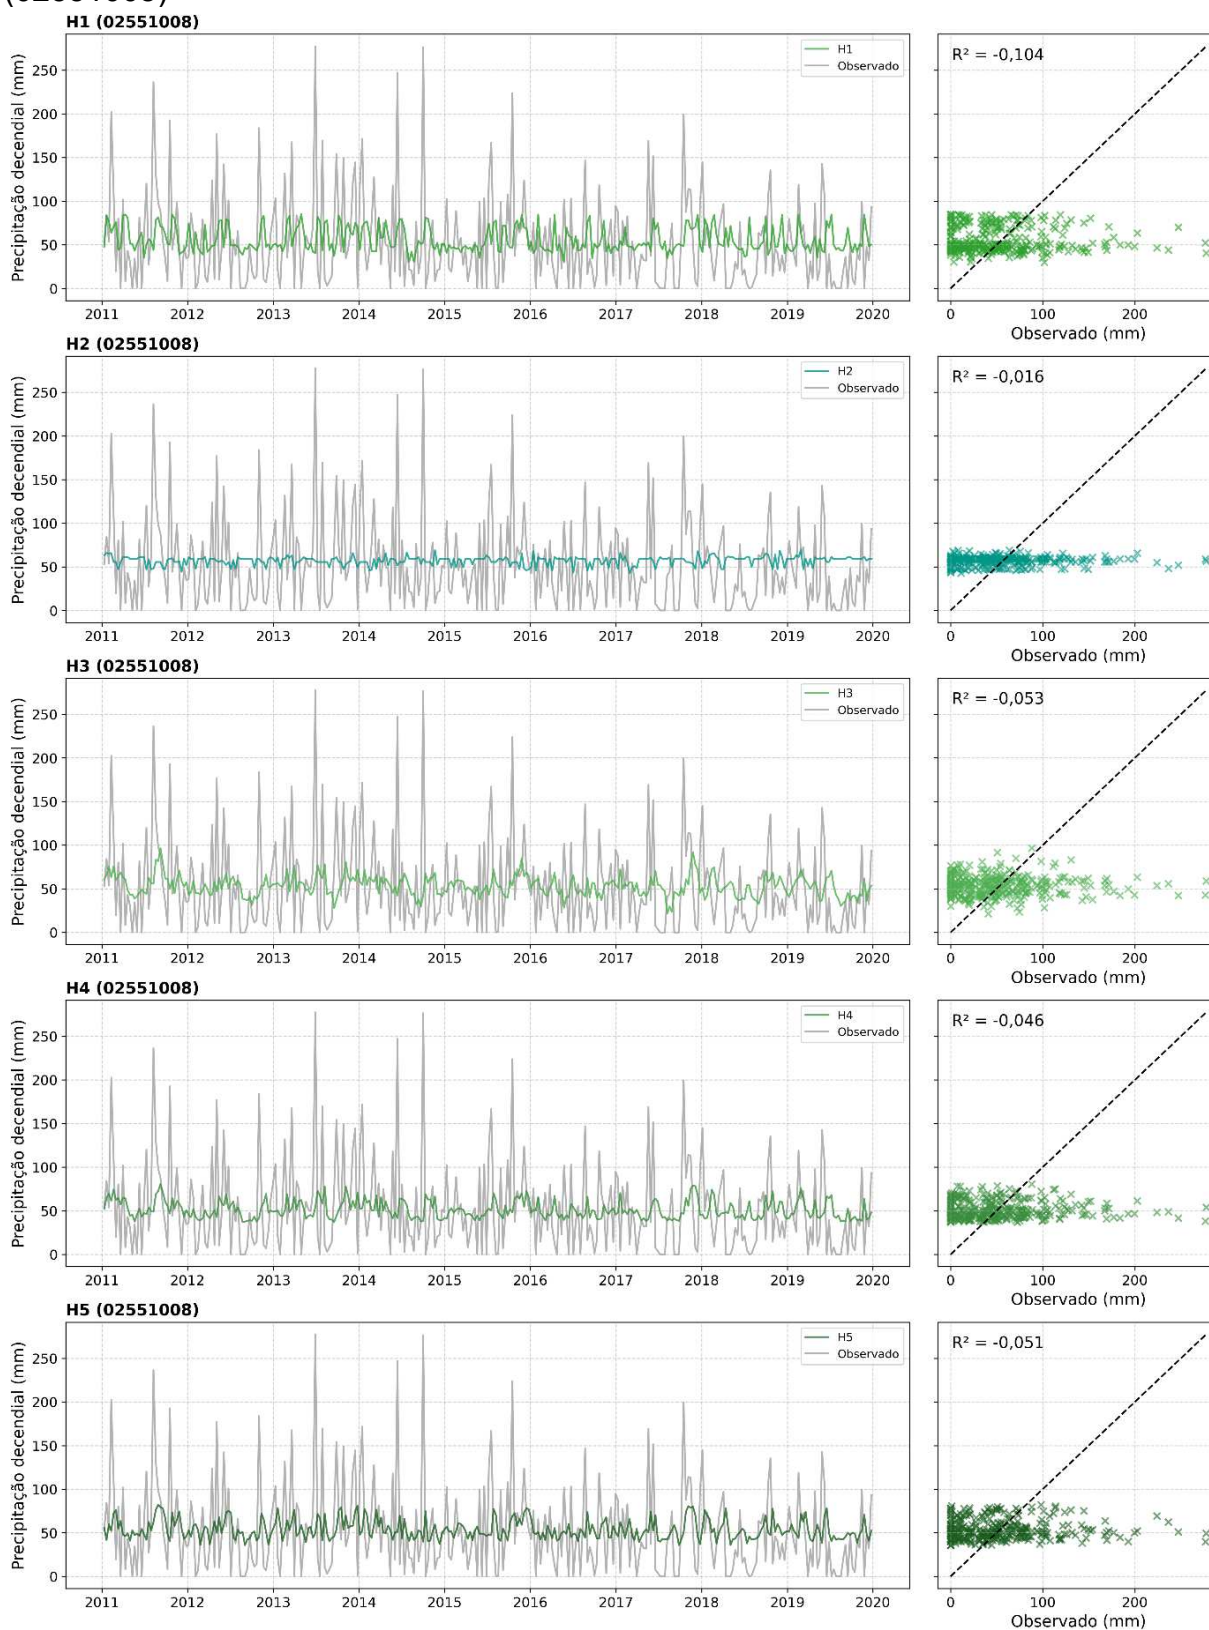
**Tabela 6 – Métricas de performance dos modelos H1 a H5**

Est.	Modelo	Calibração					Validação				
		MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
Est. Maringá	H1	33,72	1953,12	44,19	0,058	0,058	38,54	2884,85	53,71	0,028	0,028
	H2	38,47	2344,34	48,42	-0,131	-0,131	41,31	3273,24	57,21	-0,103	-0,103
	H3	35,93	2027,57	45,03	0,022	0,022	40,35	2882,44	53,69	0,029	0,029
	H4	33,57	1930,11	43,93	0,069	0,069	38,65	2914,79	53,99	0,018	0,018
	H5	32,66	1938,49	44,03	0,065	0,065	37,56	2906,77	53,91	0,021	0,021
Est. Colônia Vitória	H1	41,15	2947,43	54,29	-0,037	-0,037	40,66	2862,36	53,50	-0,104	-0,104
	H2	40,73	2895,29	53,81	-0,019	-0,019	39,54	2633,25	51,32	-0,016	-0,016
	H3	39,29	2790,63	52,83	0,018	0,018	39,49	2730,63	52,26	-0,053	-0,053
	H4	38,86	2769,63	52,63	0,025	0,025	38,80	2713,08	52,09	-0,046	-0,046
	H5	39,39	2772,34	52,65	0,024	0,024	39,24	2724,63	52,20	-0,051	-0,051

**Figura 35 – Predição dos modelos H1 a H5 – Validação – Estação Maringá (02351013)**

Fonte: a própria autora

**Figura 36** – Predição dos modelos H1 a H5 – Validação – Estação Colônia Vitória (02551008)



Fonte: a própria autora

Considerando os resultados, observa-se que nenhum dos modelos híbridos de redes neurais com associação apresenta desempenho satisfatório. Todos registraram coeficientes de determinação ( $R^2$ ) e de Nash-Sutcliffe (NSE) baixos, independentemente da localidade estudada.

Na Estação Maringá, o modelo H3 obteve os melhores resultados entre os cinco modelos testados, com os menores erros (RMSE = 53,69 mm e MAE = 40,35 mm). Apesar disso, a performance ainda pode ser considerada ruim, com valores de  $R^2$  e NSE próximos de zero (ambos iguais a 0,029), indicando que o modelo pouco supera a performance que seria obtida por uma predição baseada na média.

A análise visual e descritiva dos modelos também confirma essa limitação. Em Maringá, embora o modelo H3 tenha apresentado média próxima à observada (52,29 mm e 51,17 mm observada), o desvio padrão da série prevista foi significativamente menor (14,97 mm contra 27,11 mm). Essa compressão da variabilidade, evidenciada nos gráficos das Figura 35, foi comum a todos os modelos com associação, demonstrando a dificuldade desses em reproduzir a amplitude real dos dados.

Para a Estação Colônia Vitória, observa-se uma performance ainda mais limitada dos modelos H1 a H5. Nenhum deles obteve valores positivos para o  $R^2$  ou NSE no período de validação, e os erros permaneceram elevados, com RMSE variando entre 51 e 54 mm e MAE entre 39 mm e 41 mm. Diferente da Estação Maringá, foi o modelo H2 que apresentou o menor erro na Estação Colônia Vitória, embora seu desempenho também tenha sido satisfatório.

Além disso, todos os modelos por associação avaliados apresentaram baixa capacidade de estimar adequadamente os valores extremos. As Figura 35 e Figura 36 – juntamente com as análises descritivas (Apêndice C) – revelam a ausência de valores mínimos próximos a zero e subestimação dos máximos previstos. Essa limitação compromete a representatividade dos modelos, sobretudo para aplicações voltadas à gestão de eventos extremos.

A análise das características das séries originais nas duas estações permite compreender alguns fatores que podem ter influenciado o desempenho insatisfatório dos resultados. Como discutido nas seções anteriores, o desempenho da modelagem das componentes depende diretamente da eficácia do processo de decomposição (Ng *et al.*, 2023). Essa eficácia, por sua vez, está relacionada às condições climáticas locais e ao padrão das séries temporais, afetando a capacidade dos modelos em respeitar adequadamente a estrutura imposta pela decomposição.

Existe, assim, um possível efeito combinado entre a estrutura da série, a eficiência dos modelos base e a estratégia de associação a ser adotada. Em séries mais regulares, como a observada em Maringá, abordagens que preservaram a separação das componentes apresentaram desempenho relativamente superior. O modelo H3, que realizou associações por componente seguidas de recomposição direta (Figura 25), obteve a melhor performance entre os modelos com associação, ainda que com ganhos discretos. De maneira semelhante, os modelos H1 e H4, que também respeitam a lógica de combinação estruturada (Figura 23 e Figura 26), demonstraram resultados mais consistentes do que aqueles que desconsideraram a decomposição.

Já em séries mais irregulares, como a de Colônia Vitória, a associação entre modelos não resultou em ganhos expressivos, reforçando que a simples adoção da decomposição ou da combinação de predições não garante, por si só, a melhora do desempenho preditivo. Quando as predições das componentes apresentam erros significativos, esses tendem a se propagados pelas estruturas de associação. Nesse contexto, estratégias que ampliem a diversidade e a quantidade de variáveis de entrada, como sugerido por Ren e Ghazali (2025) e implementado no modelo H2 (Figura 24), podem ser alternativas metodológicas mais adequadas.

Por outro lado, o modelo H5, ao eliminar a etapa da decomposição (Figura 27), apresentou resultados semelhantes ou inferiores aos obtidos pelos modelos com decomposição. Mesmo em Colônia Vitória, onde a decomposição não gerou benefícios expressivos, sua exclusão também não trouxe vantagens. Esse achado reforça a hipótese de que a utilidade da decomposição não depende apenas da série original, mas também da capacidade dos modelos em explorar adequadamente as subcomponentes geradas (Garai *et al.*, 2024; Gu *et al.*, 2022; Khairudin *et al.*, 2024; Ouyang; Ravier; Jabloun, 2021).

Em complemento, a comparação entre as métricas de calibração e validação indica que os modelos mantiveram um padrão relativamente estável de desempenho ao longo da série. Como exemplo, as variações no coeficiente de determinação entre os períodos são consideravelmente baixas ( $\Delta R^2 < 0,08$ ). Logo, a ausência de uma queda brusca na performance preditiva sugere que os modelos não sofreram com superajuste para a série de calibração.

Adicionalmente, os padrões estatísticos das séries previstas permaneceram próximos dos observados, mesmo com pequenas alterações nas médias entre os

períodos. Esse comportamento indica que a baixa qualidade preditiva está mais relacionada às limitações dos próprios modelos do que a mudanças climáticas relevantes entre calibração e validação (Gu *et al.*, 2022).

Em síntese, os resultados apontam para um desempenho limitado dos modelos de associação, sobretudo na reprodução dos extremos e da dispersão real das séries de precipitação decendial. Essa limitação destaca a necessidade de avaliar criticamente se a associação, mesmo quando empregada em estruturas complexas, representa um ganho efetivo em relação a outras abordagens tradicionais, com e sem a decomposição, ou a modelos determinísticos já consolidados.

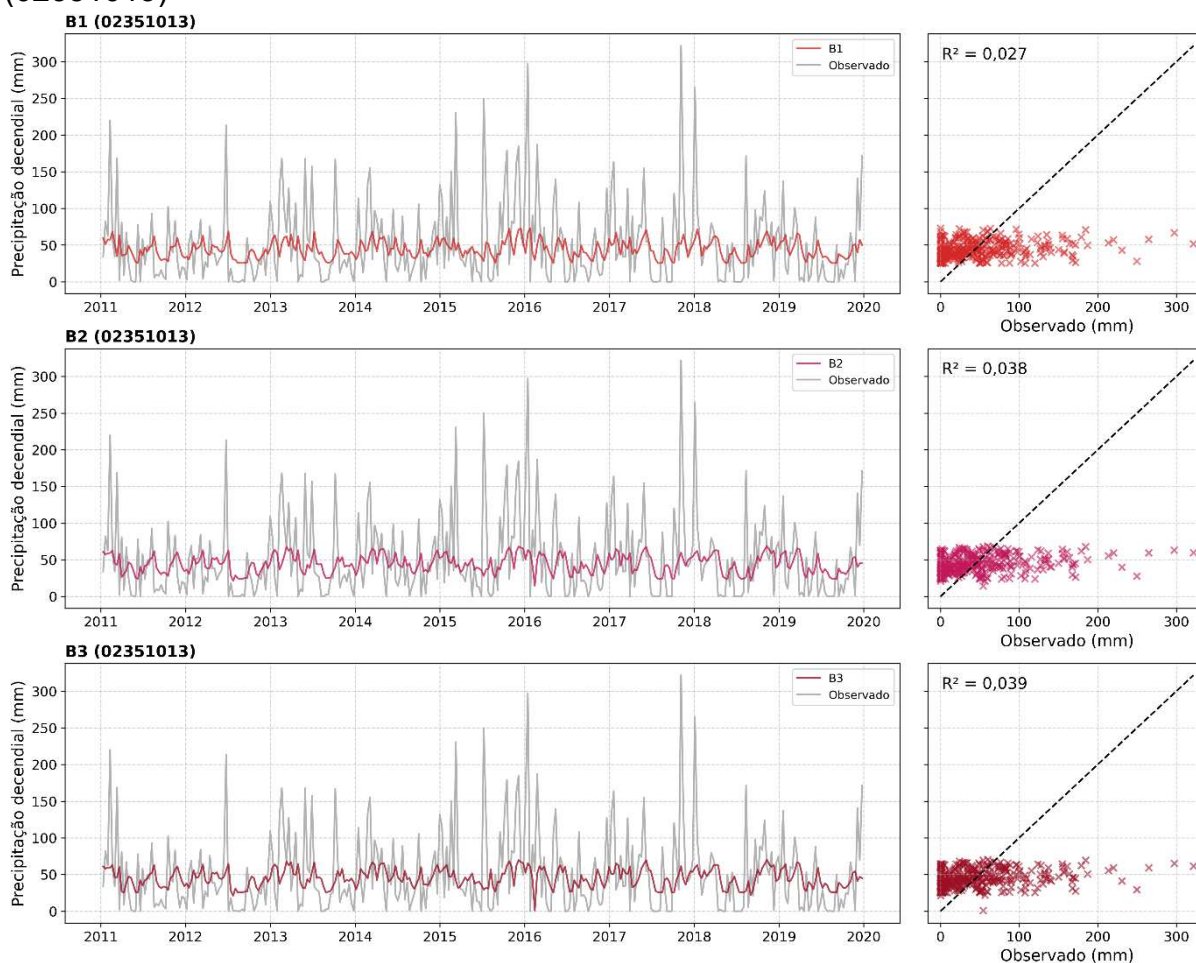
#### 4.3.1 Desempenho frente aos modelos comparativos

Diversos modelos comparativos baseados em redes neurais foram elaborados com o intuito de avaliar, de forma mais abrangente, o real impacto do uso de estratégias por associação na predição da precipitação decendial. Informações complementares sobre a configuração desses modelos, bem como a descrição das séries previstas e as métricas obtidas, encontram-se nos Apêndice A ao C.

Inicialmente, foi realizada a comparação entre os modelos híbridos com associação (H1 a H5) e os modelos recorrentes simples (B1 a B3), que utilizaram diretamente a série original de precipitação decendial como entrada preditiva (Figura 28). As predições dos modelos B1, B2 e B3 para o período de validação, ilustradas nas Figura 37 e Figura 38, indicam que o desempenho geral também foi limitado, sobretudo na representação dos eventos de mínima e máxima precipitação.

Entretanto, a análise das métricas de performance, resumidas na Tabela 7, revela que os modelos mais simples apresentaram desempenho superior aos híbridos com associação. O modelo B3, construído com a arquitetura GRU aplicada diretamente à série original, superou todos os modelos com associação nos coeficientes  $R^2$  e NSE. A melhora relativa no  $R^2$  chegou a 34,48% em relação ao modelo H3 (Maringá) e 71,24% quando comparado ao modelo H2 (Colônia Vitória).

**Figura 37** – Predição dos modelos B1, B2 e B3 – Validação – Estação Maringá (02351013)



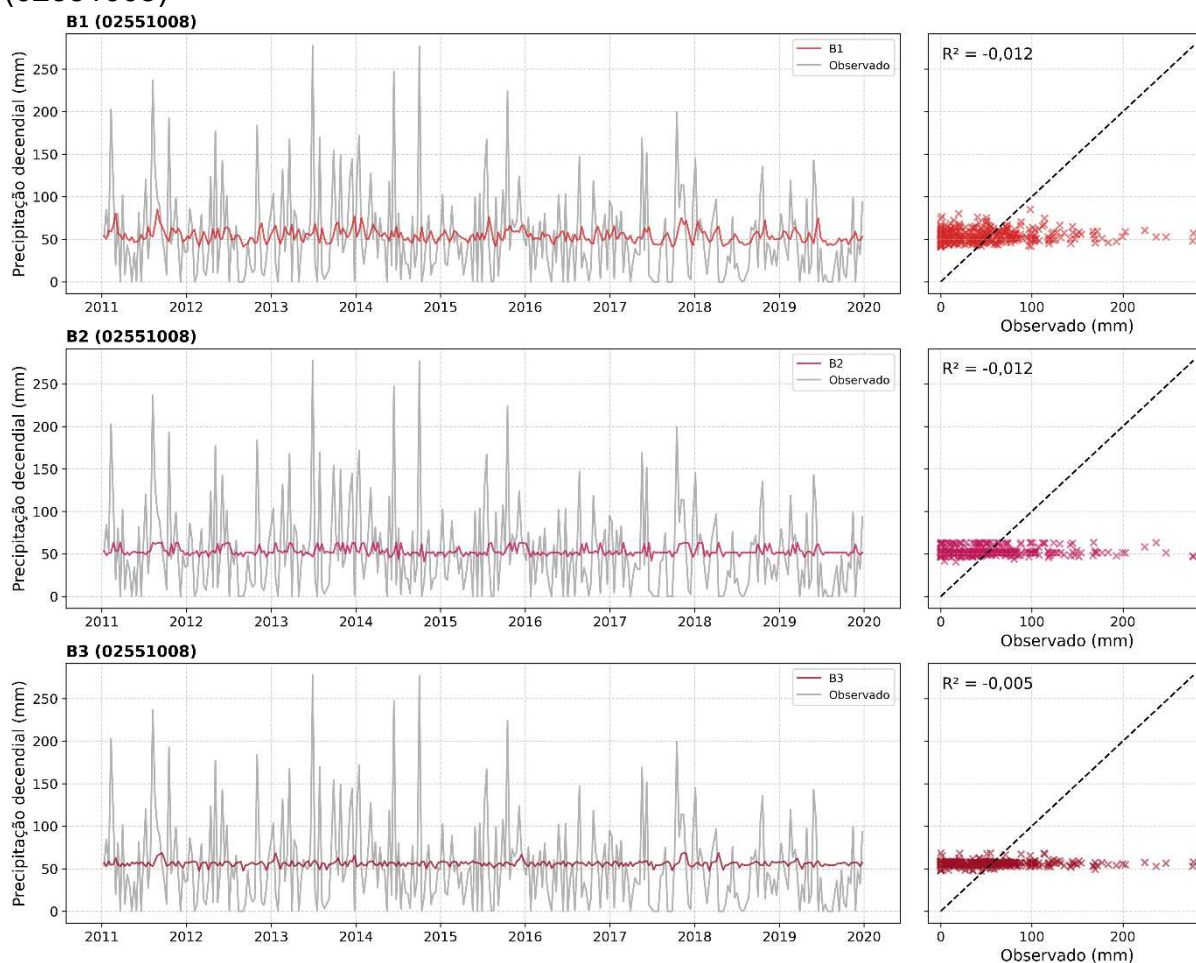
Fonte: a própria autora

**Tabela 7** – Métricas de performance para os modelos B1, B2 e B3

Est.	Modelo	Calibração					Validação				
		MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
Est. Maringá	B1	33,37	1938,21	44,03	0,065	0,065	38,56	2887,61	53,74	0,027	0,027
	B2	33,29	1923,63	43,86	0,072	0,072	38,34	2854,18	53,42	0,038	0,038
	B3	33,48	1921,69	43,84	0,073	0,073	38,55	2852,93	53,41	0,039	0,039
Est. Colônia Vitória	B1	39,33	2769,72	52,63	0,025	0,025	38,67	2623,09	51,22	-0,012	-0,012
	B2	39,43	2796,23	52,88	0,016	0,016	38,63	2625,05	51,24	-0,012	-0,012
	B3	40,06	2805,94	52,97	0,012	0,012	39,05	2604,34	51,03	-0,005	-0,005

Fonte: a própria autora

**Figura 38** – Predição dos modelos B1, B2 e B3 – Validação – Estação Colônia Vitória (02551008)



**Fonte:** a própria autora

Cabe destacar, porém, que essas diferenças devem ser interpretadas com cautela, dada a baixa magnitude absoluta dos coeficientes envolvidos. Em Maringá, por exemplo, a diferença entre os modelos com melhor desempenho em cada grupo foi de apenas 0,0004 ( $R^2_{H3} = 0,0292$  e  $R^2_{B3} = 0,0288$ ). Em Colônia Vitória, embora o ganho percentual tenha sido mais expressivo, a diferença absoluta permaneceu inferior a 0,011 ( $R^2_{H2} = -0,016$  e  $R^2_{B3} = -0,005$ ).

Do ponto de vista dos erros, as variações também foram discretas. As diferenças entre os melhores modelos de associação e o modelo B3 ficaram abaixo de 1 mm tanto para o RMSE quanto para o MAE, indicando que, na prática, a simplificação arquitetural não comprometeu a acurácia, mas tampouco foi capaz de superá-la com expressividade.

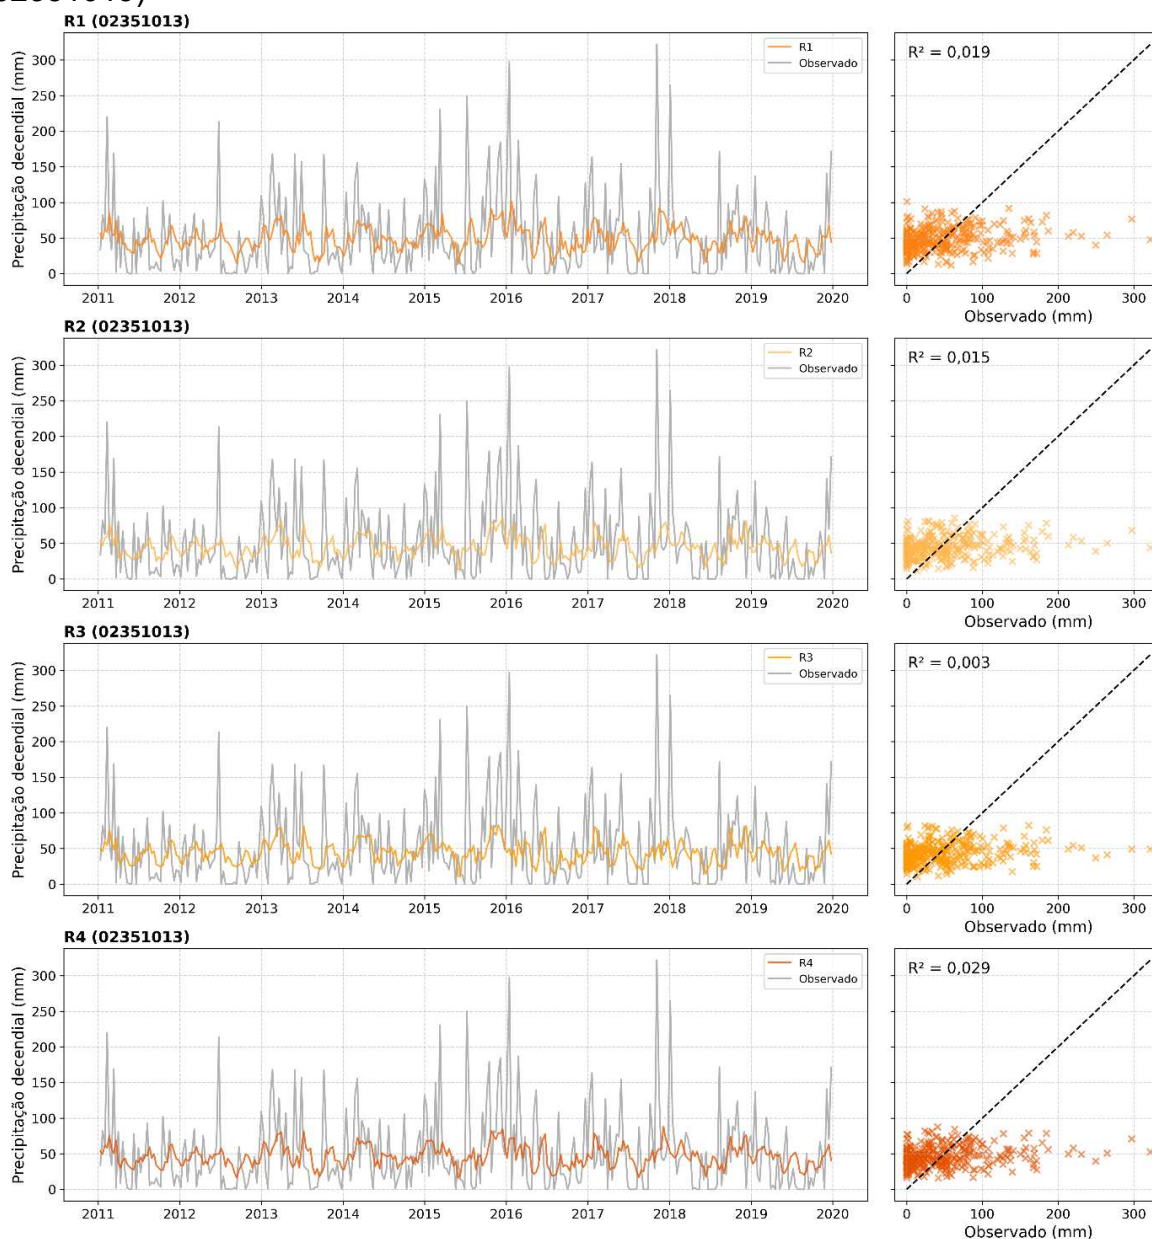
Visualmente, observa-se que, para ambas as estações, todos os modelos de redes neurais apresentaram um comportamento comum de compressão das

predições em torno da média da série observada. Esse efeito foi particularmente evidente em Colônia Vitória, em que os modelos B1, B3 e H2 suavizaram as flutuações naturais da série, resultando na subestimação dos máximos e na ausência de valores mínimos próximos a zero. Essa limitação, comum em séries com alta variabilidade como a precipitação, decorre da forma como as redes neurais são ajustadas. Com isso, ainda que conseguissem representar o padrão geral da série, os modelos demonstraram dificuldades em prever volumes muito baixos ou muito elevados de precipitação.

A comparação entre os modelos B1 a B3 e o modelo H5 reforça a constatação de que a associação, por si só, não garante ganhos preditivos. O modelo H5, estruturado como a combinação das predições geradas por B1 (RNN), B2 (LSTM) e B3 (GRU) (Figura 27), apresentou coeficientes de determinação inferiores aos obtidos por cada uma dessas arquiteturas isoladamente. Esses resultados sugerem que a associação entre modelos de estrutura semelhante e baseados nos mesmos dados de entrada tende apenas a reproduzir os mesmos padrões e erros, sobretudo em séries altamente variáveis.

Com o objetivo de avaliar se essas limitações também se reproduziriam na modelagem baseada em componentes das séries, analisaram-se os resultados dos modelos H1 a H5 em comparação aos modelos R1 a R4. Estes últimos realizaram a modelagem individual das componentes de tendência, sazonalidade e resíduo com diferentes arquiteturas de redes neurais, seguidos de uma recomposição simples por soma (Figura 29). As predições para o período de validação estão ilustradas nas Figura 39 e Figura 40, e suas respectivas métricas de desempenho estão resumidas na Tabela 8.

**Figura 39** – Predição dos modelos R1 a R4 – Validação – Estação Maringá (02351013)

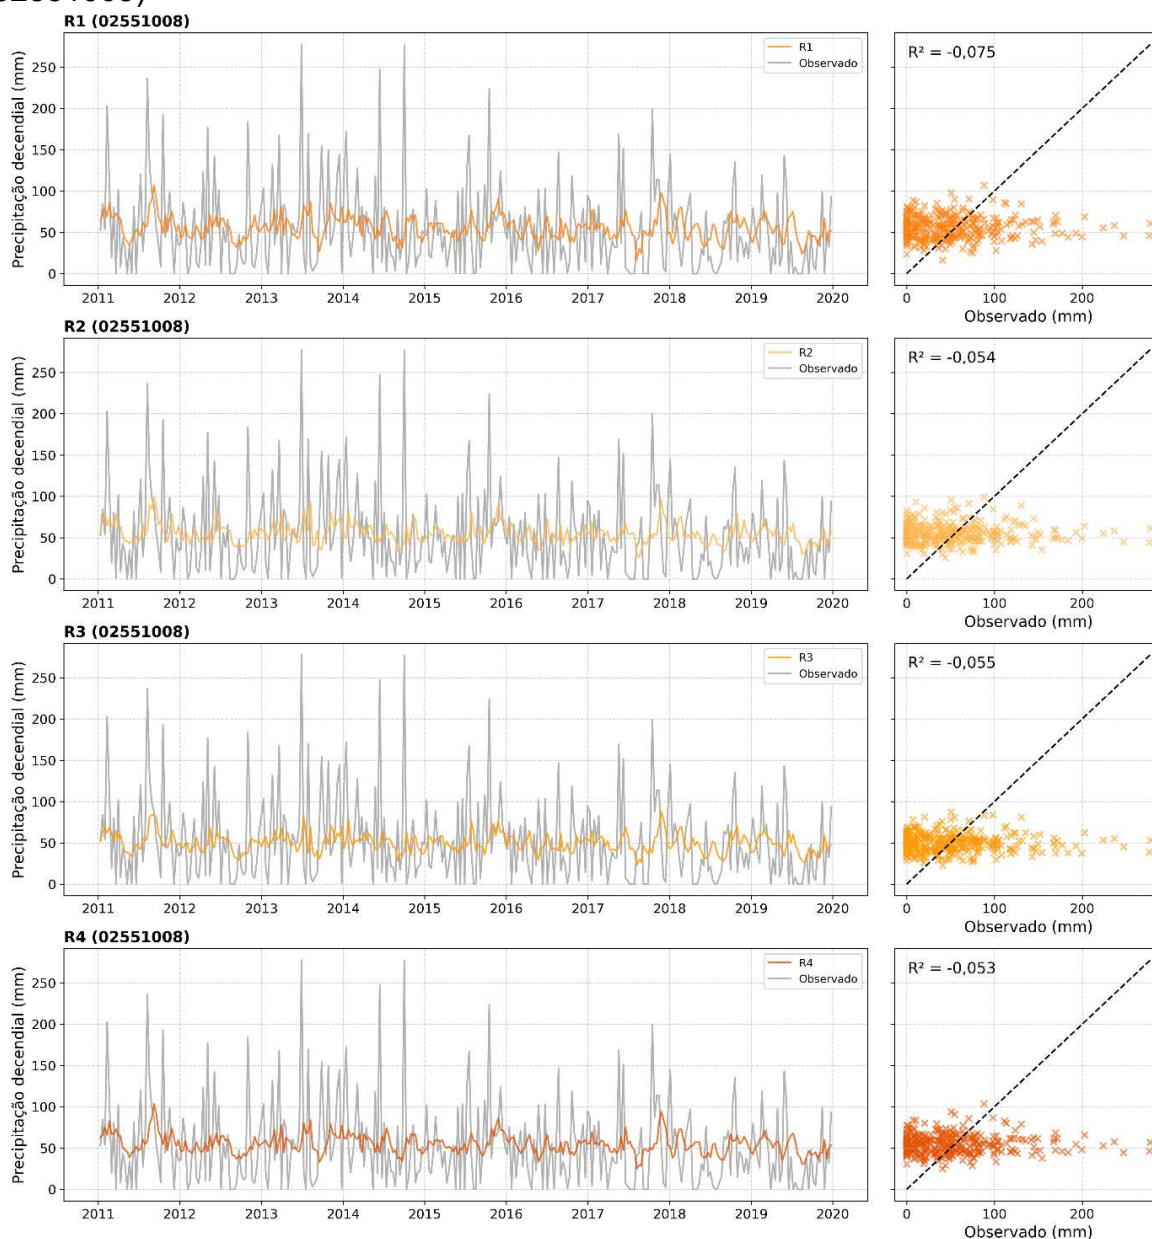


Fonte: a própria autora

**Tabela 8** – Métricas de performance para os modelos R1 a R4

Est.	Modelo	Calibração					Validação				
		MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
Est. Maringá	R1	34,78	2022,61	44,97	0,024	0,024	39,70	2911,09	53,95	0,019	0,019
	R2	33,47	1967,52	44,36	0,051	0,051	39,05	2922,68	54,06	0,015	0,015
	R3	33,42	1976,50	44,46	0,046	0,046	38,94	2957,83	54,39	0,003	0,003
	R4	34,03	1984,05	44,54	0,043	0,043	38,98	2881,38	53,68	0,029	0,029
Est. Colônia Vitória	R1	40,25	2852,68	53,41	-0,004	-0,004	40,38	2786,81	52,79	-0,075	-0,075
	R2	40,05	2826,20	53,16	0,005	0,005	39,77	2733,85	52,29	-0,054	-0,054
	R3	38,88	2836,64	53,26	0,002	0,002	38,81	2735,77	52,30	-0,055	-0,055
	R4	40,00	2822,18	53,12	0,007	0,007	39,93	2729,65	52,25	-0,053	-0,053

**Figura 40** – Predição dos modelos R1 a R4 – Validação – Estação Colônia Vitória (02551008)



**Fonte:** a própria autora

Entre os modelos deste grupo, o R4 obteve os melhores resultados. No entanto, as diferenças de desempenho entre os modelos R1 até R4 foram discretas, como evidenciado pela baixa variação observada nas métricas de validação ( $\Delta R^2 < 0,055$ ;  $\Delta RMSE < 0,54$  mm;  $\Delta MAE < 1,58$  mm). O principal diferencial do R4 foi adotar a seleção da melhor arquitetura para cada componente individual, o que pode ter contribuído para um ajuste ligeiramente mais preciso, ainda que os ganhos obtidos tenham sido limitados.

Assim como nos demais modelos analisados, o desempenho em Maringá

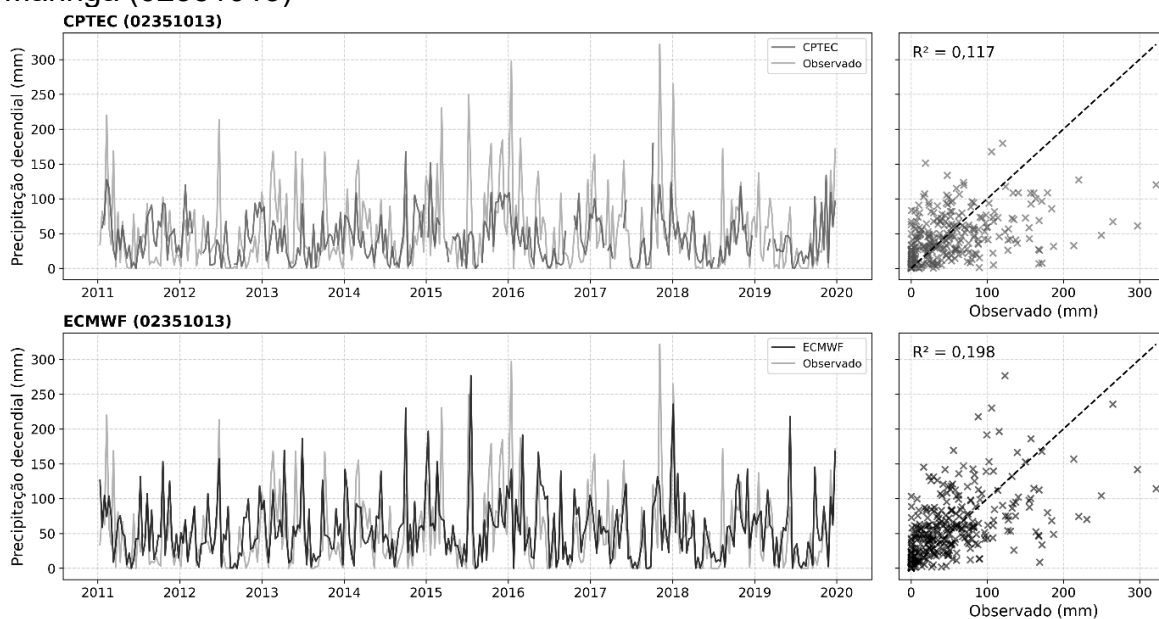
superou o observado para Colônia Vitória, refletindo a influência da estrutura da série original e da qualidade da decomposição realizada. Observa-se também que o padrão de compressão das previsões em torno da média persistiu nos modelos R1 a R4, mesmo na ausência de uma etapa explícita de associação. Esse comportamento é resultado das limitações já verificadas na modelagem individual das componentes, as quais demonstraram baixa capacidade de reproduzir os valores extremos e a variabilidade inerente das séries. Ao serem recombinaadas, essas deficiências foram preservadas, comprometendo o desempenho global das previsões.

Comparando os resultados dos modelos R1 a R4 com aqueles obtidos pelos modelos com associação (H1 a H5), verifica-se que a associação, por si só, também não promoveu melhorias relevantes. Para a Estação Maringá, a diferença no coeficiente de determinação ( $R^2$ ) entre os melhores modelos de cada grupo foi de apenas 0,0004 ( $R^2_{H3} = 0,0292$  e  $R^2_{R4} = 0,0288$ ) enquanto que para a Estação Colônia Vitória, a variação foi de -0,037 ( $R^2_{H2} = -0,016$  e  $R^2_{R4} = -0,053$ ). Em relação ao RMSE, as diferenças foram inferiores a 2 mm, e para o MAE, inferiores a 1 mm (Apêndice D).

Especificamente, comparando o modelo R4 com o H1, ao qual a recomposição por soma foi substituída por um modelo do tipo RNN, não houve uma melhora no desempenho preditivo ( $\Delta R^2 < 0,051$ ,  $\Delta RMSE < -1,255\text{mm}$  e  $\Delta MAE < 0,73\text{mm}$ ). Neste caso, a adoção de uma rede neural para recomposição também não foi suficiente para promover ganhos na qualidade da estimativa da precipitação decendial. Esses resultados indicam que, quando a modelagem das componentes apresenta limitações importantes, o aumento da complexidade na etapa de recomposição não é suficiente para corrigir os problemas estruturais. Tanto a recomposição simples quanto as estratégias de associação apenas reproduziram as deficiências já presentes nas previsões individuais das componentes, sem promover melhorias expressivas na qualidade das previsões.


Por fim, os resultados obtidos pelos modelos com associação foram comparados aos dos modelos determinísticos globais do CPTEC e do ECMWF. As previsões geradas por esses modelos para o período de validação encontram-se ilustradas na Figura 41 e Figura 42, e suas respectivas métricas de desempenho estão apresentadas na Tabela 9.

**Figura 41** – Predição dos modelos do CPTEC e ECMWF – Validação – Estação Maringá (02351013)



Fonte: a própria autora

**Figura 42** – Predição dos modelos do CPTEC e ECMWF – Validação – Estação Colônia Vitória (02551008)



Fonte: a própria autora

**Tabela 9** – Métricas de performance para os modelos CPTEC e ECMWF - Validação

Est.	Modelo	Validação				
		MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
Est. Maringá	CPTEC	35,39	2657,38	51,55	0,117	0,117
	ECMWF	34,25	2380,60	48,79	0,198	0,198
Est. Colônia Vitória	CPTEC	38,61	3130,52	55,95	-0,192	-0,192
	ECMWF	34,89	2511,25	50,11	0,031	0,031

De modo geral, nota-se que, embora tenham apresentado desempenho superior ao dos modelos baseados em redes neurais, os modelos determinísticos também enfrentaram limitações na previsão da precipitação decendial, especialmente na Estação Colônia Vitória. Em Maringá, ambos os modelos determinísticos obtiveram coeficientes de determinação positivos para o período de validação, com  $R^2$  de 0,117 para o modelo BAM do CPTEC e 0,198 para o modelo IFS do ECMWF. Esse desempenho relativamente superior, em comparação aos modelos aqui propostos, também foi refletido nas métricas de erros, com o modelo IFS do ECMWF apresentando o menor valor de RMSE entre todos os modelos avaliados.

Na Estação Colônia Vitória, os resultados foram mais discrepantes. O modelo BAM do CPTEC apresentou o pior desempenho, com  $R^2$  negativo (-0,192) e os maiores valores de erro. Em contrapartida, o modelo IFS do ECMWF foi o único a alcançar  $R^2$  positivo na localidade (0,031), ainda que tenha apresentado limitações na reprodução dos volumes precipitados.


As diferenças de desempenho entre os modelos determinísticos podem ser atribuídas, em parte, às características estruturais dos próprios modelos. O modelo BAM do CPTEC, por exemplo, não é acoplado a um modelo oceânico, o que pode ter limitado sua capacidade de representar processos atmosféricos de maior escala. Além disso, as previsões analisadas do CPTEC corresponderam ao produto *Control Forecast*, ou seja, derivado da execução principal do modelo numérico, sem a aplicação de perturbações nas condições iniciais, o que pode ter reduzido sua capacidade de capturar a variabilidade natural.

Apesar de suas limitações, os modelos determinísticos mostraram-se mais eficazes na reprodução dos extremos de precipitação máxima e mínima, ao contrário dos modelos com associação, que concentraram as previsões em torno da média observada. Ainda que a acurácia geral tenha sido restrita, o desempenho superior dos modelos determinísticos pode ser justificado pela maior robustez estrutural de suas formulações e pela incorporação de variáveis meteorológicas globais, que favorecem uma representação mais completa dos processos físicos envolvidos.

Uma síntese dos resultados obtidos para o coeficiente de determinação ( $R^2$ ) segundo o modelo e localidade está apresentada na Figura 43. Observa-se, de forma mais clara, que todos os modelos avaliados demonstraram capacidade restrita na previsão das precipitações decendiais. Além disso, o desempenho preditivo foi consistentemente superior na Estação Maringá. Esse padrão se manteve para

praticamente todos os modelos avaliados, exceto para o modelo H2, cuja estrutura desconsiderou a decomposição das componentes.

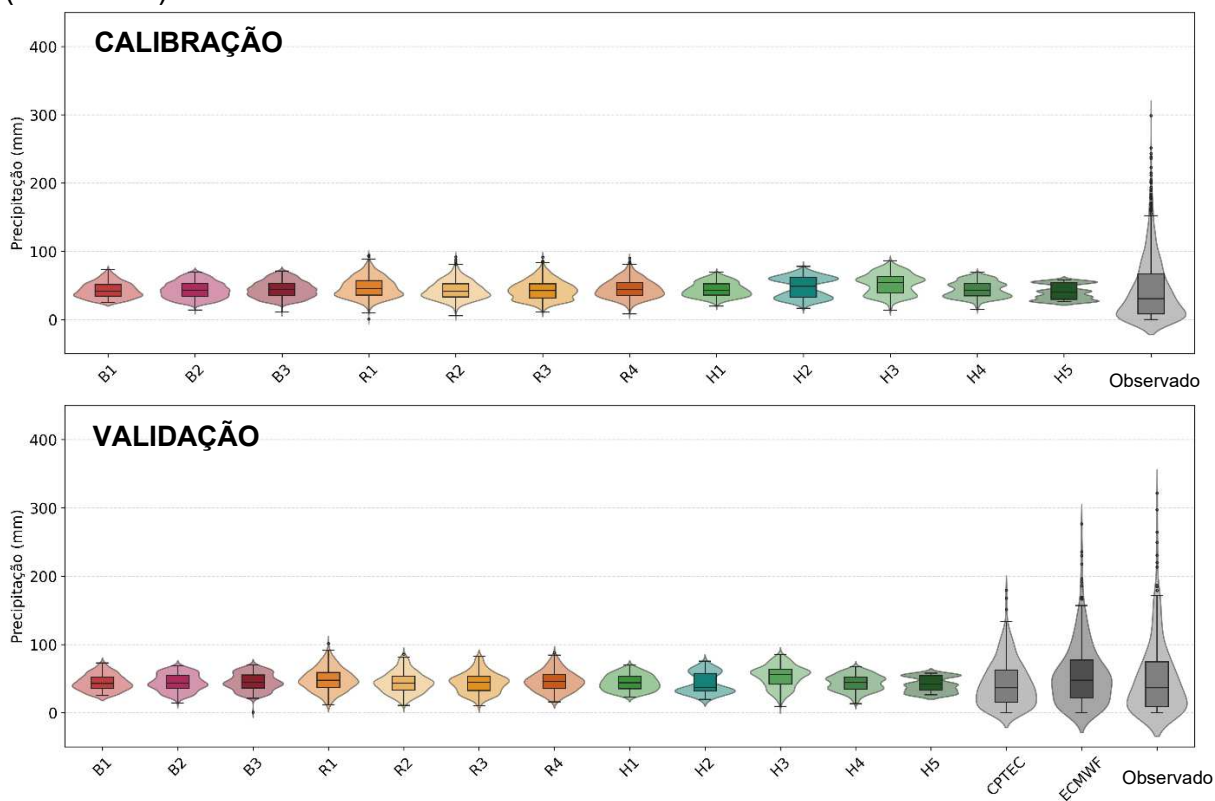
**Figura 43** – Coeficiente de determinação ( $R^2$ ) dos modelos – Validação



**Fonte:** a própria autora

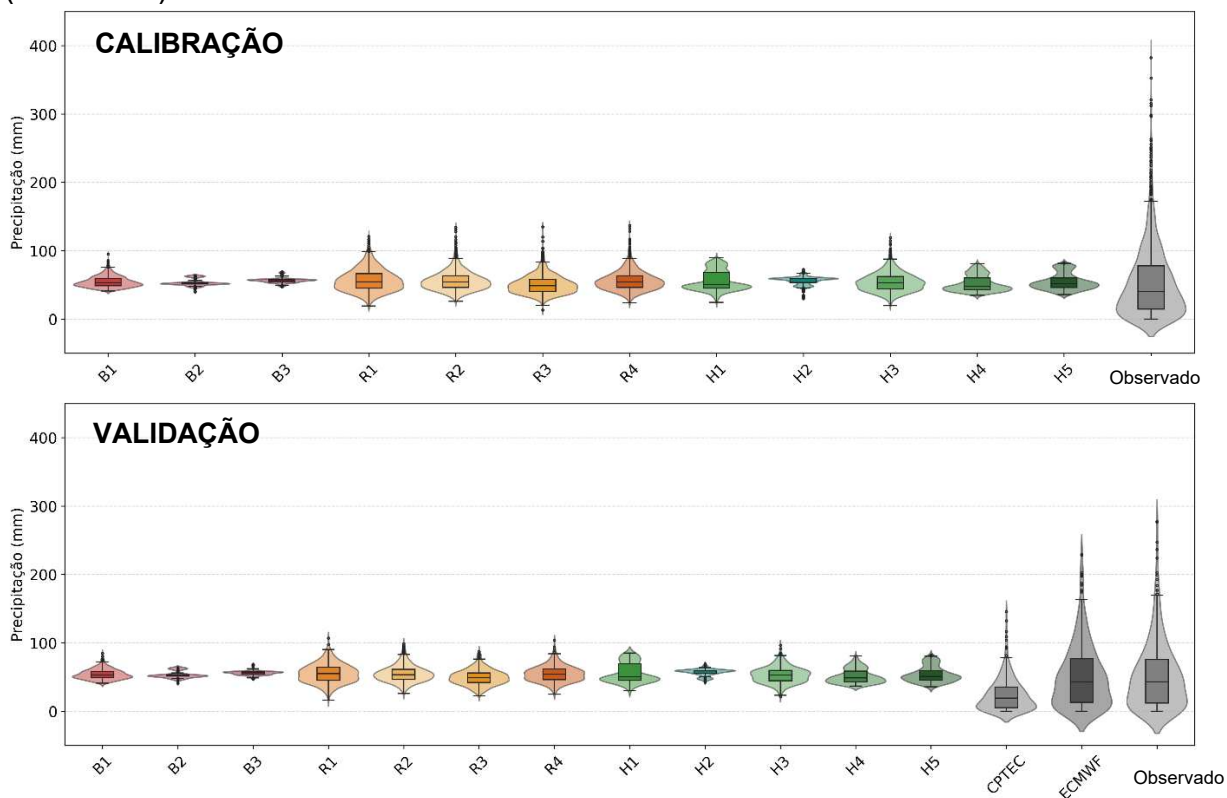
As Figura 44 e Figura 45 complementam essa análise ao apresentar a distribuição das séries observadas e previstas. Observa-se que as redes neurais comprimiram a variabilidade das previsões, concentrando os valores em torno da média, subestimando os máximos e não representando adequadamente os períodos sem precipitação. Esse comportamento foi ainda mais acentuado na Estação Colônia Vitória, cuja série completa e de calibração apresentou os maiores valores máximos e maior dispersão dos dados (Tabela 1 e Tabela 2). Essas características dificultaram o ajuste dos modelos, levando à perda da capacidade de reproduzir os extremos e à amplificação dos erros observados.

**Figura 44** – Distribuição das previsões dos modelos para a Estação Maringá (02351013)



Fonte: a própria autora

**Figura 45** – Distribuição das previsões dos modelos para a Estação Colônia Vitória (02551008)




Fonte: a própria autora

Novamente, os resultados obtidos reforçam que as estratégias de decomposição e associação de redes neurais não se mostraram alternativas eficazes para o aprimoramento da previsão de precipitação decendial, sobretudo em séries caracterizadas por elevada variabilidade. Diante desse desempenho limitado, buscou-se avaliar se as variações sazonais na capacidade preditiva dos modelos poderiam justificar o uso das estratégias de associação.

#### 4.3.2 Desempenho por estação do ano


Para a avaliação do desempenho sazonal, as previsões referentes ao período de validação foram separadas segundo as quatro estações climáticas do hemisfério sul: verão (21 de dezembro a 20 de março), outono (21 de março a 20 de junho), inverno (21 de junho a 22 de setembro) e primavera (23 de setembro a 20 de dezembro). Essa classificação foi realizada diretamente a partir das datas do conjunto de validação, sem qualquer interferência na estrutura dos modelos ou nos procedimentos de treinamento. A partir dessa separação, calcularam-se as métricas de desempenho específicas para cada estação do ano, cujos resultados detalhados estão disponíveis no Apêndice E. Uma síntese dos coeficientes de determinação ( $R^2$ ) no período de validação é apresentada graficamente na Figuras 46 e 47 permitindo observar variações no desempenho preditivo dos modelos conforme a estação do ano.

**Figura 46** – Coeficiente de determinação ( $R^2$ ) dos modelos por estação do ano – Validação – Estação Maringá (02351013)



Fonte: a própria autora

**Figura 47** – Coeficiente de determinação ( $R^2$ ) dos modelos por estação do ano – Validação – Estação Colônia Vitória (02551008)



**Fonte:** a própria autora

Em Maringá, as predições para a primavera apresentaram desempenhos mais expressivos entre os modelos de redes neurais, enquanto no verão verificou-se o resultado menos satisfatório (Figura 46). Essa diferença pode ser atribuída às características climáticas locais: o município, classificado como Cfa segundo Köppen-Geiger, apresenta clima subtropical úmido, com verões quentes e elevada irregularidade na distribuição das chuvas (Montanher; Minaki, 2020). Essa predominância de precipitações convectivas durante o verão pode justificar a maior dificuldade de predição observada. Por outro lado, nos períodos de outono e inverno, os resultados foram intermediários, refletindo o comportamento mais regular das chuvas nesses períodos mais secos e, conseqüentemente, de maior aderência aos dados observados.

Em Colônia Vitória, os resultados por estação do ano revelaram variações menos pronunciadas (Figura 47). O município está localizado em uma região classificada como Cfb, de clima subtropical com verão ameno e chuvas bem distribuídas ao longo do ano (ITCG, 2008), o que pode justificar a uniformidade do desempenho das análises. Ainda assim, ressalta-se que, novamente, a maioria dos modelos resultou em coeficientes de determinação negativos, evidenciando a dificuldade em capturar a variabilidade da precipitação decendial nessa localidade.

Embora o clima de Colônia Vitória seja caracterizado por maior regularidade na distribuição anual de chuvas, a série histórica analisada apresentou comportamento mais irregular. Para a série completa e de calibração, observou-se maior dispersão dos volumes precipitados e ocorrência de máximos mais elevados do que em Maringá, o que pode ter contribuído para as limitações dos modelos na etapa de validação.

A comparação por estação do ano também evidenciou que, em determinados


períodos, os modelos determinísticos globais apresentaram desempenho semelhante ou até inferior ao das redes neurais. Em Maringá, por exemplo, o modelo BAM (CPTEC) teve resultados comparáveis ou piores que os modelos de redes neurais no verão e no outono. Já o modelo IFS (ECMWF) manteve desempenho superior na maior parte das estações, destacando-se no inverno, período que possui menores índices de precipitação no local.

Em Colônia Vitória, as diferenças entre os grupos de modelos foram menos expressivas. O modelo do BAM do CPTEC apresentou desempenho inferior na maioria das estações do ano, enquanto o modelo IFS do ECMWF obteve desempenho superior em todas elas. Destaca-se que para a primavera, esse modelo obteve  $R^2$  próximo a 0,4, superando todos os modelos de rede neural.

De maneira geral, a análise sazonal reforça a influência das características climáticas locais e da estrutura das séries temporais sobre a qualidade das previsões. Apesar das variações sazonais, os modelos de redes neurais mantiveram desempenho insatisfatório, sobretudo na Estação Colônia Vitória. Além disso, até mesmo os modelos determinísticos globais apresentaram dificuldades relevantes, particularmente nos períodos de maior irregularidade na distribuição das chuvas.

#### 4.3.3 Tempos de Processamento e de Execução

A análise dos tempos de processamento expõe que as estratégias baseadas na decomposição e associação dos modelos resultaram em custos computacionais significativamente superior. A Figura 48 apresenta os tempos dedicados às diferentes etapas de processamento: calibração, correspondente à execução dos testes de combinação de hiperparâmetros; simulação, referente ao ajuste interno dos pesos das redes e à geração das previsões; e tempo total, correspondente à soma dessas duas etapas.

**Figura 48** – Tempo de calibração, simulação e total para os modelos

**Fonte:** a própria autora

As análises não incluíram os modelos determinísticos, uma vez que as informações de processamento não estavam disponíveis no repositório TIGGE. Porém, mesmo que esses dados estivessem acessíveis, uma comparação direta seria inadequada, dado que os modelos determinísticos operam com volume de dados e variáveis muito mais amplo, voltado à escala global, enquanto os modelos deste estudo foram direcionados exclusivamente à predição local.

Conforme apresentado na Figura 48, os tempos totais necessários para a execução dos modelos H1 a H4 foram iguais ou superiores a duas horas, refletindo a complexidade adicional imposta pelas etapas de decomposição e associação. Em contrapartida, os modelos B1 a B3, que não incorporaram essas estratégias,

demandaram tempos totais inferiores a 20 minutos, representando uma redução de até seis vezes no tempo de total dedicado.

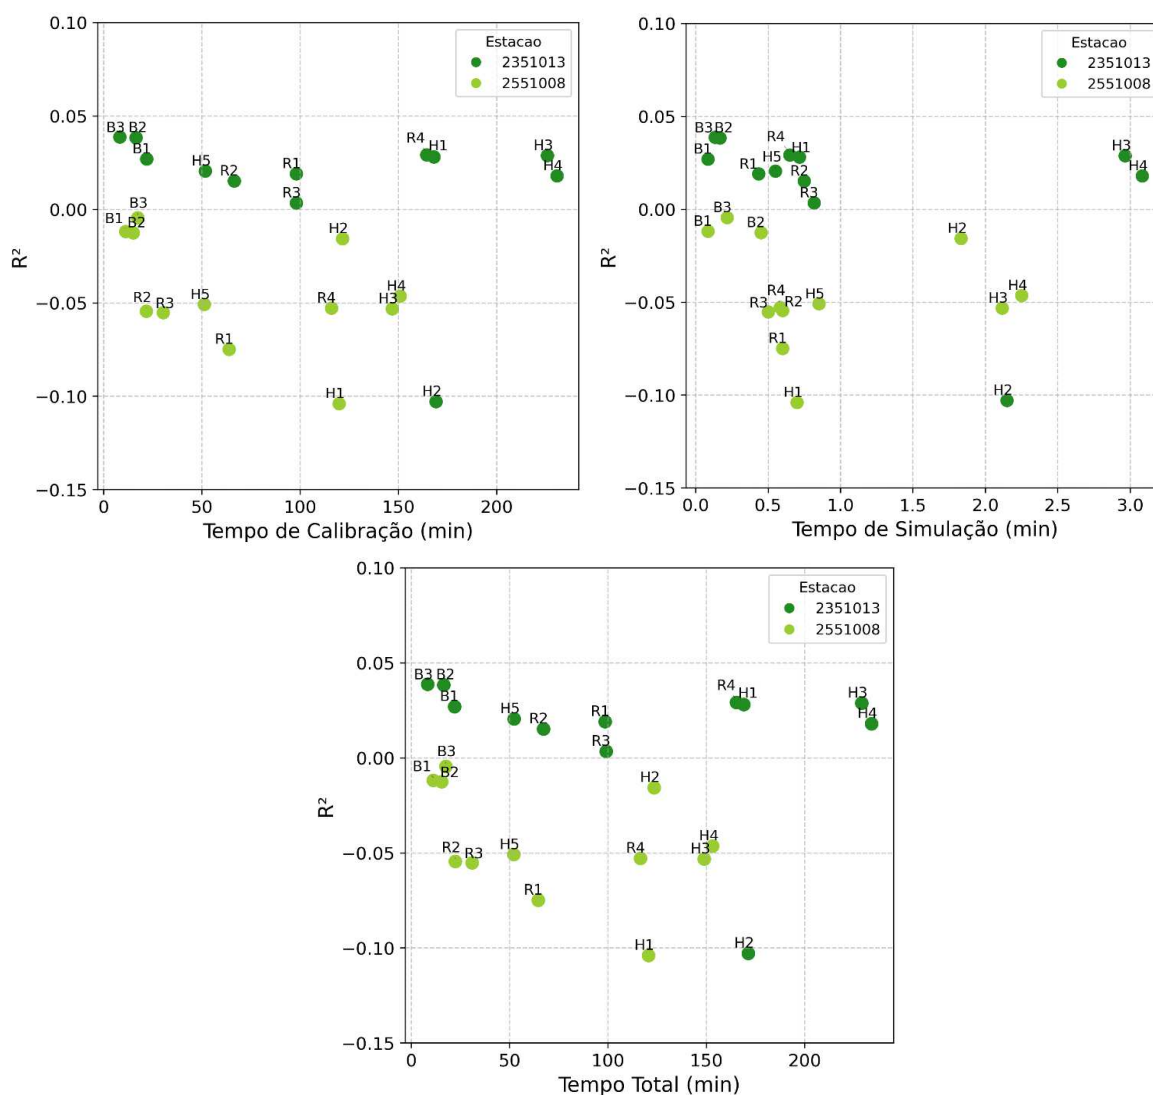
Entre os modelos com associação, destaca-se o H5, que apresentou tempo total inferior a uma hora. Essa diferença decorre do fato de que, embora o H5 incluísse a associação entre previsões, ele não utilizou a decomposição prévia da série, reduzindo o número de componentes a serem otimizadas e, conseqüentemente, o tempo de ajuste. Por outro lado, o modelo H4, que combinou decomposição e associação em dois níveis, registrou o maior tempo, evidenciando o impacto progressivo do aumento da complexidade metodológica.

Outro aspecto importante, observável na Figura 48, é a diferença de magnitude entre os tempos de calibração e simulação. A etapa de calibração concentrou o maior custo computacional, em função da realização de 50 tentativas de ajuste de hiperparâmetros para cada modelo. Em contrapartida, a simulação propriamente dita foi rápida, com tempos inferiores a quatro minutos, não representando um entrave para o uso rotineiro dos modelos de redes neurais.

Comparando as estações, observou-se que Maringá apresentou tempos de calibração superiores na maioria dos modelos. Essa diferença reflete o próprio processo de ajuste iterativo realizado pelo algoritmo Optuna, uma vez que, para Maringá, foram selecionadas combinações de hiperparâmetros mais complexas, como maior número de epochs, camadas e neurônios. Assim, tem-se que o custo computacional pode variar não apenas em função da estrutura do modelo, mas também das características específicas da série analisada.

A Figura 49 contrapõe os tempos de processamento com os coeficientes de determinação ( $R^2$ ) obtidos no período de validação. Observa-se que, de modo geral, o incremento no tempo de execução não se traduziu em ganhos expressivos de desempenho preditivo.

**Figura 49** – Relação entre coeficiente de determinação  $R^2$  e os tempos de A) Calibração, B) Simulação e C) Total dos modelos



**Fonte:** a própria autora

Em Maringá, por exemplo, o modelo H3, que incorporou decomposição e associação, demandou cerca de 3h45min e alcançou  $R^2$  de 0,0292. Esse resultado foi inferior ao obtido pelo modelo B3 ( $R_{B3}^2 = 0,039$ ), cuja estrutura mais simples exigiu menos de 10 minutos. Assim, o tempo necessário para o processamento do modelo H3 foi aproximadamente 2150% superior ao do B3, em ganho correspondente em qualidade preditiva. Situação semelhante foi observada para o modelo R4, que, mesmo exigindo mais de 2h45min de processamento, obteve  $R^2$  de 0,0288.

Em Colônia Vitória, o padrão identificado foi semelhante. O modelo H2, cuja calibração ultrapassou 2h, apresentou  $R^2$  negativo (-0,016), sendo superado pelo modelo B3, que obteve  $R^2$  de -0,005 com tempo de processamento cerca de seis

vezes menor.

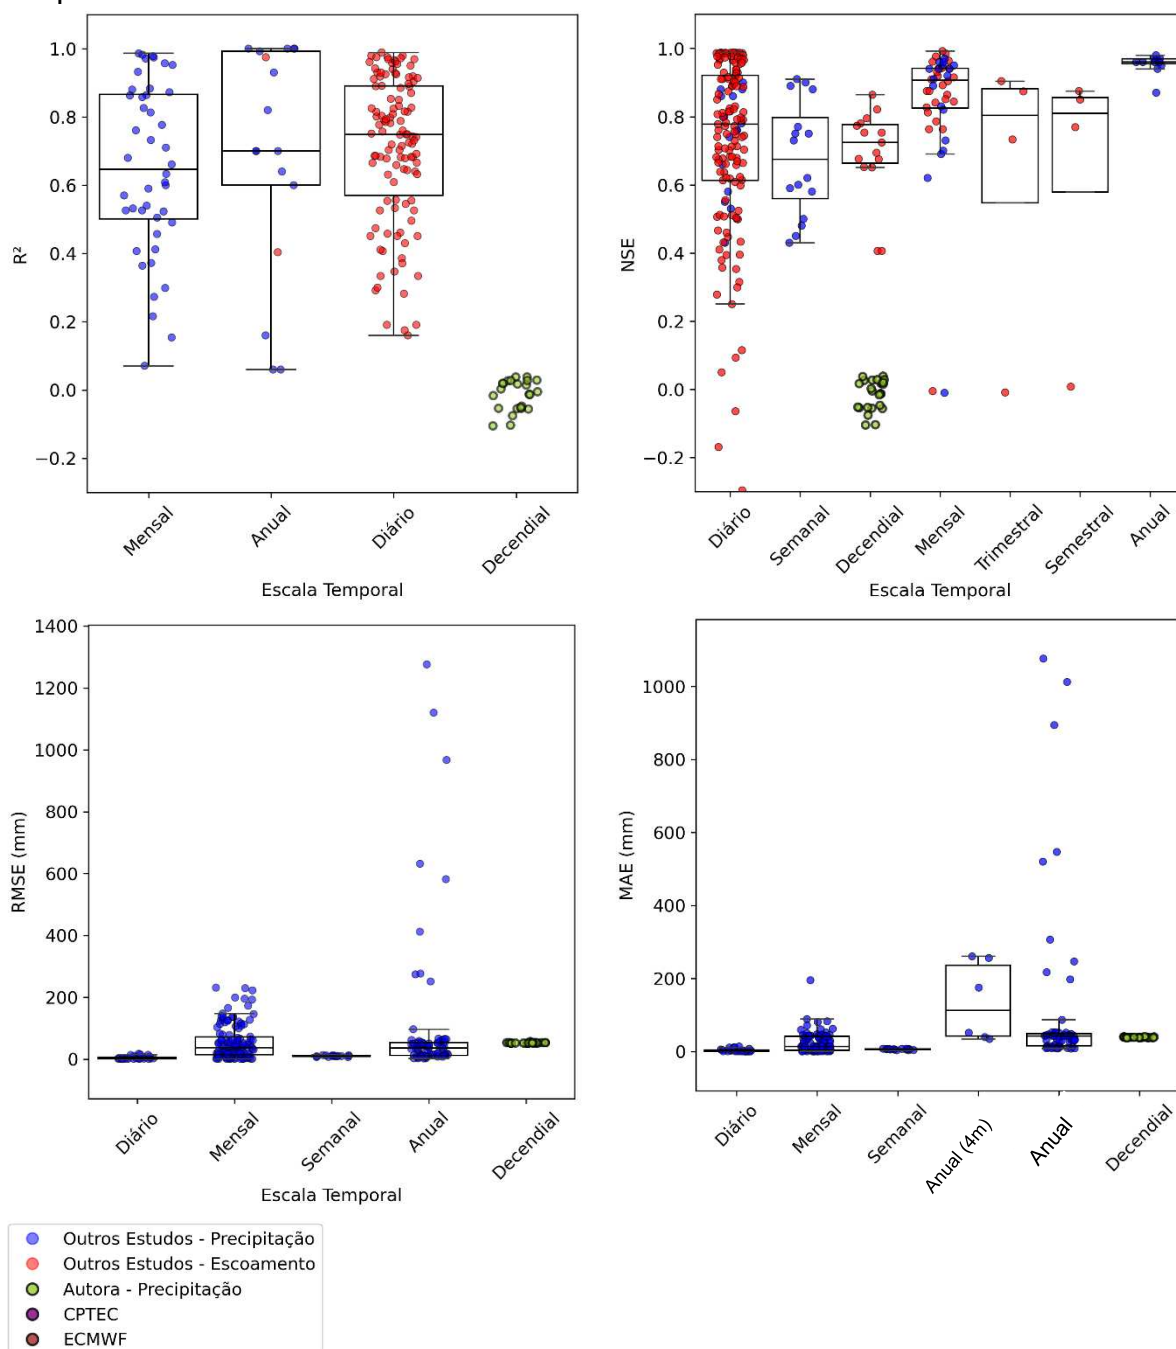
Essa análise demonstra que o incremento no tempo de processamento decorrente da inclusão de decomposição e associação não garantiu ganhos proporcionais na qualidade preditiva para as séries analisadas. Na prática, modelos mais simples, com menor custo computacional, mostraram desempenho semelhante ou superior, reforçando a necessidade de ponderação entre complexidade e eficácia na escolha da metodologia preditiva.

#### 4.3.4 Comparação com o Estado da Arte

De modo a qualificar os resultados obtidos pelas predições, realizou-se um levantamento das métricas reportadas na revisão de forma sistemática (2.5 - Estado da Arte), com o objetivo de contextualizar o desempenho dos modelos avaliados neste trabalho frente ao estado da arte.

Ressalta-se que a modelagem da precipitação em escala decenal ainda é pouco explorada, o que, embora dificulte comparações diretas, evidencia a originalidade da abordagem proposta. Considerando a influência da escala temporal na complexidade da modelagem, os resultados encontrados na revisão de forma sistemática foram agrupados por métrica e por escala. Para as métricas adimensionais  $R^2$  e NSE, foram considerados estudos de precipitação e vazão, dada a similaridade estrutural dos processos preditivos; para o RMSE e MAE, foram incluídos apenas estudos voltados à previsão de precipitação. A Figura 50 resume graficamente os achados, enquanto o Anexo A reúne as informações detalhadas sobre as publicações, os modelos e métricas obtidas.

**Figura 50** – Comparação entre as métricas calculadas para os modelos elaborados pelo presente e outros estudos semelhantes



Obs 1: a lista das publicações inclusas e métricas está disponível no Anexo A

Obs 2: Os box-plot foram calculados somente com os dados das publicações.

**Fonte:** a própria autora.

Comparando os resultados dos modelos desenvolvidos com os trabalhos compilados (Figura 50), verifica-se que os valores de  $R^2$  e NSE situaram-se abaixo das medianas e, em muitos casos, até mesmo dos menores valores relatados para

outras escalas temporais. Isso se confirma também pelas médias apresentadas na (Tabela 10), que mostram desempenho visivelmente inferior aos da literatura. Especificamente, a média do  $R^2$  obtido (-0,016) foi mais de 100% inferior à de estudos em escala mensal (0,65) e 97% inferior à média em escala diária (0,71). Para o NSE, a média também foi de -0,016, em contraste com 0,73 para séries diárias e 0,95 para séries anuais.

**Tabela 10** – Média das métricas de performance para os modelos elaborados por esse e outros estudos semelhantes

Escala Temporal	MAE (mm)	RMSE (mm)	$R^2$	NSE
<b>Decendial (Autora)</b>	39,229	53,068	-0,016	-0,016
<b>Diário</b>	3,612	4,683	0,709	0,730
<b>Semanal</b>	5,932	9,897	-	0,677
<b>Decendial</b>	-	51,601	-	0,695
<b>Mensal</b>	23,623	50,195	0,650	0,742
<b>Trimestral</b>	-	-	-	0,626
<b>Quadrimestral</b>	136,118	-	-	-
<b>Semestral</b>	-	-	-	0,626
<b>Anual</b>	111,748	101,509	0,712	0,954

Nota: MAE e RMSE calculados com modelos de previsão da precipitação;  $R^2$  e NSE incluindo estudos de precipitação e vazão.

Esse desempenho demonstra as dificuldades inerentes à modelagem da precipitação decendial, mesmo com a adoção de estratégias de decomposição e associação. Dentre os estudos revisados (Figura 50), todos os modelos apresentaram  $R^2$  positivo, inclusive aqueles voltados à previsão diária. Para o índice NSE, embora alguns estudos pontuais tenham registrado resultados inferiores ou próximos aos deste trabalho, a maioria obteve resultados superiores.

Em relação às métricas de erro, RMSE e MAE, observa-se um comportamento relativamente mais próximo ao observado na literatura. Como indicado na Tabela 10, o valor médio de RMSE foi de 53,07 mm, superior aos obtidos para séries diárias (4,68 mm), semanais (9,89 mm) e mensais (50,20 mm), mas inferior ao registrado para séries anuais (101,51 mm). Situação semelhante ocorreu para o MAE, cujo valor médio de 39,23 mm superou os das escalas menores, mas ficou abaixo dos valores reportados para séries quadrimestrais (136,11 mm) e anuais (111,75 mm).

Os resultados sugerem que, embora os modelos não tenham conseguido capturar com precisão os padrões da série — evidenciado pelos coeficientes de

determinação ( $R^2$ ) e eficiência de Nash-Sutcliffe (NSE) negativos —, os desvios absolutos mantiveram-se dentro dos limites esperados para a escala decendial. Esse contraste indica que, apesar da dificuldade em representar a variabilidade temporal da precipitação, os modelos apresentaram uma estimativa média sem grandes discrepâncias. Ainda assim, nenhum dos modelos desenvolvidos neste estudo, com ou sem o uso da decomposição e associação, foi capaz de representar de forma satisfatória a precipitação decendial.

Importante destacar que diversos estudos revisados reportaram desempenhos superiores mesmo utilizando arquiteturas semelhantes à desta pesquisa. Por exemplo, Chen *et al.* (2023) utilizaram LSTM combinada à decomposição CEEMD para prever a precipitação mensal em Zhoukou (China), alcançando  $R^2$  de 0,93 e MAE de 13,07 mm. Isso significa um MAE 66% inferior ao valor médio observado neste estudo. Shen e Ban (2023) também relataram resultados positivos em Lanzhou, com  $R^2$  superiores a 0,54 e MAE abaixo de 14,7 mm, utilizando modelos *Multilayer Perceptrons*, LSTM, CEEMDAN-LSTM e ARIMA. Para escalas diárias, como os de Song *et al.* (2021), os modelos baseados em redes neurais recorrentes do tipo Elman (ENN) superaram NSE de 0,40 em diferentes localidades, mostrando bom desempenho mesmo frente as diferentes características das séries.

Em síntese, a comparação com estudos da literatura evidencia que o desempenho obtido nesta pesquisa foi limitado, mesmo com a utilização de arquiteturas já exploradas e testadas. A hipótese de que a adoção de estratégias de decomposição e associação garantiria ganhos de desempenho não se confirmou para a escala decendial. Ao contrário, os resultados reforçam que a eficácia das estratégias baseadas em redes neurais é altamente dependente da estrutura da série, da presença de variáveis complementares e do rigor metodológico na definição do processo de modelagem.

#### 4.4 DISCUSSÃO GERAL

A avaliação dos modelos elaborados revelou limitações importantes na aplicação de estratégias por associação para a previsão da precipitação decendial. Um dos aspectos centrais refere-se à performance dos próprios modelos-base, tanto aqueles aplicados diretamente à série original (modelos B1 a B3) quanto os empregados nas componentes da série decomposta. Em ambas as condições, o

desempenho obtido foi restrito.

No caso das séries decompostas, a maior parte das predições apresentou baixa capacidade preditiva, principalmente nas componentes sazonal e residual. A tendência, embora tenha apresentado desempenho apenas moderado, destacou-se por registrar coeficientes de determinação mais elevados, variando entre 0,32 e 0,45 nas localidades analisadas. Essa vantagem relativa foi atribuída à maior regularidade e persistência da série, que, ainda que não tenha garantido uma boa representação do padrão global, tornou essa componente mais compatível com a lógica sequencial dos modelos aplicados. Esse comportamento, também identificado em outros estudos, indica que a decomposição pode ser útil não como etapa obrigatória, mas como ferramenta para identificar estruturas com maior previsibilidade (Ren; Ghazali, 2025; Tebong et al., 2023). Ainda assim, nas estratégias de associação avaliadas, o desempenho limitado dos modelos na etapa inicial de predição comprometeu os resultados, uma vez que a recomposição final apenas reproduziu as deficiências dos modelos envolvidos.

A capacidade das redes neurais em modelar séries climatológicas já foi amplamente discutida na literatura, como nas pesquisas de Chen et al. (2023), Shen e Ban (2023) e Song et al. (2021), bem como em revisões sistemáticas recentes (Ahmed; Hassan; Mstafa, 2022; Ganaie et al., 2022; Kundu et al., 2023; Shrestha; Mahmood, 2019; Sit et al., 2020). Esses trabalhos demonstram que, mesmo sem estratégias adicionais de associação ou decomposição, redes como RNN, LSTM e GRU têm sido eficazes na representação de padrões complexos. Diante disso, levanta-se a conjectura de que a combinação de modelos-base com desempenho já limitado pode ter comprometido o desempenho final das associações, impedindo a validação da hipótese principal desta pesquisa.

Os resultados obtidos pelos modelos H1 a H5 reforçam essa hipótese, ao evidenciar que a combinação entre decomposição e associação não resultou em ganhos preditivos expressivos. Em diversos casos, o desempenho final foi inferior ao dos próprios modelos-base, tanto na explicação da variabilidade quanto na representação dos extremos. Modelos como o H3, na Estação Maringá, apresentaram desvios absolutos relativamente baixos (MAE), mesmo diante de coeficientes  $R^2$  e NSE próximos de zero, sugerindo que, apesar das limitações em captar a variabilidade, houve capacidade parcial de aproximação das médias. Esse contraste entre métricas indica que, mesmo com baixa capacidade explicativa, os modelos

foram capazes de reproduzir tendências centrais da série, o que não seria captado apenas pelos coeficientes de determinação.

Nos modelos avaliados, a recomposição foi prejudicada tanto pela baixa correlação entre as componentes quanto pela fragilidade individual de cada uma. Em especial, o resíduo, sem padrão temporal claro, contribuiu para previsões instáveis e com pouca aderência à série original. Além dessa dificuldade, a semelhança estrutural entre os modelos combinados agravou o problema, possivelmente limitando a complementaridade entre as previsões. Ouyang, Ravier e Jabloun (2021) já haviam destacado a limitação de combinações compostas exclusivamente por modelos de aprendizado de máquina, indicando que esses tendem a apresentar baixa diversidade interna.

Ainda que os resultados obtidos tenham sido restritos, trabalhos recentes demonstram que, sob certas condições, estratégias de associação podem promover melhorias preditivas, mesmo a partir de modelos-base com desempenho limitado. É o caso de Khairudin et al. (2024), que avaliaram a predição de níveis médios mensais de água utilizando uma associação simples, baseada na média das predições geradas por redes neurais BPNN (*Backpropagation Neural Network*) e ELM (*Extreme Learning Machine*). Embora os modelos individuais tivessem apresentado desempenhos insatisfatórios (NSE = -2,1375 para o DWT-BPNN e NSE = 0,238 para o DWT-ELM), a associação resultou em uma melhora significativa (NSE = 0,4054 e redução do RMSE de 1,156m para 0,885m para o pior cenário avaliado).

Destaca-se que os resultados obtidos por Khairudin *et al.* (2024) foram favorecidos pelas características da variável analisada. Diferentemente da precipitação decendial, os níveis médios mensais de água exibem menor variabilidade, maior dependência temporal e menor magnitude, favorecendo a modelagem. Essas particularidades favoreceram a modelagem da série e, conseqüentemente, potencializaram os ganhos proporcionados por estratégias de associação. Assim, o trabalho de Khairudin et al. (2024) reforça que há cenários em que modelos-base podem ser favorecidos pelo emprego de estratégias de associação.

Dessa forma, com base nesse e nos resultados obtidos nesta pesquisa, propõe-se que a eficiência das estratégias por associação está mais fortemente condicionada às características da variável modelada e da série temporal do que ao nível da associação ou à aplicação de pré-processamentos como a decomposição.

Esse raciocínio também encontra respaldo nos estudos de Gu et al. (2022) e Garai et al. (2023).

No estudo de Gu et al. (2022), uma associação por média ponderada foi utilizada para a predição de precipitações mensais, combinando algoritmos *K-Nearest Neighbors* (KNN), *Extreme Gradient Boosting* (XGBoost), *Support Vector Regression* (SVR) e Redes Neurais Artificiais (ANN). Contudo, o desempenho do modelo associado não superou todos os modelos individuais. Enquanto o *Stacking* obteve  $R^2$  de 0,526, os modelos XGB e ANN apresentaram  $R^2$  de 0,532 e 0,526, respectivamente, com RMSE bastantes similares. Os autores atribuíram essa limitação ao comportamento específico da série temporal utilizada, caracterizada por alta variabilidade e divergência entre os períodos de calibração e validação.

De forma semelhante, Garai et al. (2023) reforçaram que a eficácia das associações está diretamente vinculada às propriedades estatísticas da série analisada. Na subdivisão PUNJB estudada pelos autores, por exemplo, a menor dispersão nos volumes precipitados entre as localidades avaliadas (desvio padrão de 175,2 mm) favoreceu o desempenho da associação CEEMDAN-KRR-RF, tornando-o comparável aos melhores modelos individuais. Este padrão corrobora os resultados obtidos nesta pesquisa, sugerindo que, em séries temporalmente mais estáveis, a associação entre modelos pode ser benéfica. Porém, em séries de maior variabilidade, a associação tende apenas a propagar as limitações dos modelos-base.

Com base na análise realizada, os achados deste estudo sugerem que o êxito de estratégias por associação depende, fundamentalmente, da estrutura da série modelada e da qualidade preditiva dos modelos que a compõem. Em contextos de alta variabilidade, como o da precipitação decendial, a associação entre modelos de redes neurais similares não foi suficiente para superar as limitações estruturais. Esses resultados indicam que o aprimoramento da modelagem não depende, necessariamente, da complexidade da arquitetura, mas sim da compatibilidade entre o método adotado, a série temporal analisada e o contexto de aplicação.

## 5 CONCLUSÃO

Esta pesquisa avaliou o desempenho de estratégias de associação aplicadas à previsão da precipitação decendial, combinando a decomposição da série pelo método STL e a utilização de diferentes arquiteturas de redes neurais recorrentes. Foram desenvolvidos cinco modelos híbridos com associação (H1 a H5) e múltiplos modelos comparativos baseados em redes isoladas e em recomposição direta das componentes. As avaliações foram realizadas a partir de séries históricas de duas estações pluviométricas no estado do Paraná (Maringá e Colônia Vitória), com a calibração e validação baseadas em métricas padronizadas de desempenho ( $R^2$ , NSE, RMSE e MAE).

De forma geral, observou-se que, no conjunto de dados e abordagem adotados, os modelos com associação não apresentaram desempenho superior aos modelos comparativos. O melhor modelo por associação (H3) alcançou  $R^2$  de 0,0292 em Maringá e RMSE de 53,69 mm, desempenho inferior ao modelo GRU aplicado diretamente à série (B3), que obteve  $R^2$  de 0,039.

A complexidade adicional decorrente das etapas de decomposição e recomposição não resultou em ganhos expressivos na acurácia das previsões e implicou aumento do tempo de processamento. Esses resultados não confirmaram a hipótese inicialmente proposta quanto à superioridade das estratégias de associação, evidenciando a importância da compatibilidade entre o método empregado e as características da série analisada.

Importante destacar que, no contexto da Engenharia Civil, especialmente nas áreas de Hidráulica e Saneamento, a melhoria da previsão de variáveis hidrológicas é fundamental para o projeto, planejamento e a operação múltiplas infraestruturas. Assim, ainda que os resultados obtidos nesta pesquisa tenham sido limitados, o estudo contribui para o avanço do conhecimento sobre as potencialidades e limitações da aplicação de técnicas de inteligência artificial em escalas temporais intermediárias, como a decendial.

### 5.1 LIMITAÇÕES DA PESQUISA E PROPOSTAS PARA TRABALHOS FUTUROS

Apesar dos avanços proporcionados, esta pesquisa apresenta algumas limitações que devem ser consideradas. A primeira refere-se ao método de

decomposição adotado. Embora o uso do STL com decomposição em etapas tenha garantido maior coerência temporal ao processo de modelagem, o método mostrou-se limitado na separação eficaz das subcomponentes. Para estudos futuros, recomenda-se avaliar a aplicação da decomposição em etapas com técnicas alternativas, como EEMD, CEEMDAN ou VMD, que têm se mostrado promissores na literatura em diferentes contextos de séries temporais.

Outra limitação importante diz respeito ao escopo das redes neurais empregadas. Optou-se nesta pesquisa pela utilização de redes recorrentes simples, LSTM e GRU, dada a natureza sequencial dos dados. Outras limitações incluem o uso exclusivo de séries univariadas, a ausência de variáveis climáticas complementares e a análise concentrada em duas localidades e em uma única escala temporal.

Como propostas para trabalhos futuros, destacam-se:

- i. a ampliação da análise para diferentes escalas temporais e regiões climáticas
- ii. a avaliação de métodos alternativos de decomposição em etapas, como EEMD, CEEMDAN ou VMD;
- iii. a incorporação de variáveis climáticas complementares como entradas auxiliares;
- iv. o uso de arquiteturas mais recentes baseadas em aprendizado por atenção, como Transformers, que podem lidar melhor com a variabilidade e as dependências de longo prazo
- v. a aplicação de técnicas de filtragem estatística para seleção prévia das componentes relevantes antes da associação;
- vi. a integração de previsões determinísticas com redes neurais, como as iniciativas do sistema AIFS do ECMWF (ECMWF, 2023).

Portanto, embora os resultados desta pesquisa tenham indicado que, no contexto avaliado, as estratégias de associação não proporcionaram ganhos relevantes na previsão da precipitação decendial, abrem-se caminhos importantes para a continuidade científica na área e para o aprimoramento de métodos de previsão em apoio às práticas de engenharia civil.

## REFERÊNCIAS

- AGÊNCIA NACIONAL DE ÁGUA E SANEAMENTO. **Séries Históricas de Estações**. 2024. Disponível em: <https://www.snirh.gov.br/hidroweb/serieshistoricas>. Acesso em: 11 out. 2024.
- AGGARWAL, C. An Introduction to Neural Networks. *In*: AGGARWAL, C. C. **Neural Networks and Deep Learning**. Cham: Springer International Publishing, 2023. p. 1–27. Disponível em: [https://link.springer.com/10.1007/978-3-031-29642-0\\_1](https://link.springer.com/10.1007/978-3-031-29642-0_1). Acesso em: 10 out. 2024.
- AHMED, A. A. M. *et al.* Deep Learning Forecasts of Soil Moisture: Convolutional Neural Network and Gated Recurrent Unit Models Coupled with Satellite-Derived MODIS, Observations and Synoptic-Scale Climate Index Data. **REMOTE SENSING**, v. 13, n. 4, 2021.
- AHMED, D. M.; HASSAN, M. M.; MSTAFA, R. J. A Review on Deep Sequential Models for Forecasting Time Series Data. **Applied Computational Intelligence and Soft Computing**, v. 2022, p. 1–19, 2022.
- ALEXANDERSSON, H. A homogeneity test applied to precipitation data. **Journal of Climatology**, v. 6, n. 6, p. 661–675, 1986.
- ALI, M. *et al.* Complete ensemble empirical mode decomposition hybridized with random forest and kernel ridge regression model for monthly rainfall forecasts. **JOURNAL OF HYDROLOGY**, v. 584, 2020.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ALVES, L. M. *et al.* Assessment of rainfall variability and future change in Brazil across multiple timescales. **International Journal of Climatology**, v. 41, n. S1, 2021. Disponível em: <https://rmets.onlinelibrary.wiley.com/doi/10.1002/joc.6818>. Acesso em: 12 out. 2024.
- BARGE, J. T.; SHARIF, H. O. An Ensemble Empirical Mode Decomposition, Self-Organizing Map, and Linear Genetic Programming Approach for Forecasting River Streamflow. **WATER**, v. 8, n. 6, 2016.
- BAUER, P.; THORPE, A.; BRUNET, G. The quiet revolution of numerical weather prediction. **Nature**, v. 525, n. 7567, p. 47–55, 2015.
- BHANJA, S.; DAS, A. **Impact of Data Normalization on Deep Neural Network for Time Series Forecasting**. : arXiv, 2018. Disponível em: <https://arxiv.org/abs/1812.05519>. Acesso em: 5 fev. 2025.
- BOUGEAULT, P. *et al.* The THORPEX Interactive Grand Global Ensemble. **Bulletin of the American Meteorological Society**, v. 91, n. 8, p. 1059–1072, 2010.
- BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. 2nd eded. New York: Springer, 2002. (Springer texts in statistics).

BROTZGE, J. A. *et al.* Challenges and Opportunities in Numerical Weather Prediction. **Bulletin of the American Meteorological Society**, v. 104, n. 3, p. E698–E705, 2023.

BUISHAND, T. A. Some methods for testing the homogeneity of rainfall records. **Journal of Hydrology**, v. 58, n. 1–2, p. 11–27, 1982.

CABELLO-SOLORZANO, K. *et al.* The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis. *In*: GARCÍA BRINGAS, P. *et al.* (org.). **18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023)**. Cham: Springer Nature Switzerland, 2023. (Lecture Notes in Networks and Systems). v. 750, p. 344–353. Disponível em: [https://link.springer.com/10.1007/978-3-031-42536-3\\_33](https://link.springer.com/10.1007/978-3-031-42536-3_33). Acesso em: 5 fev. 2025.

CAMPS-VALLS, G. *et al.* (org.). **Deep learning for the earth sciences: a comprehensive approach to remote sensing, climate science, and geosciences**. Hoboken, NJ Chichester, West Sussex: Wiley, 2021.

CASOLARO, A. *et al.* Deep Learning for Time Series Forecasting: Advances and Open Problems. **Information**, v. 14, n. 11, p. 598, 2023.

CHA ZHANG; MA, Y. **Ensemble Machine Learning**. : Boston, Ma Springer Us, 2012.

CHATFIELD, C. **Time-Series Forecasting**. 1st eded. London: CRC Press LLC, 2000.

CHEN, J. *et al.* Research on the Application of CEEMD-LSTM-LSSVM Coupled Model in Regional Precipitation Prediction. **Water (Switzerland)**, v. 15, n. 8, 2023. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85156225615&doi=10.3390%2fw15081465&partnerID=40&md5=94dcf99c5ceb995e4b75a3540d54a782>.

CHOLLET, F.; FRANÇOIS. **Keras**. [: : S. n.], 2015. Disponível em: <https://keras.io>.

CLEVELAND, R. B. *et al.* STL: A Seasonal-Trend Decomposition Procedure Based on Loess (with Discussion). **Journal of Official Statistics**, v. 6, p. 3–73, 1990.

DODGE, Y. **The concise encyclopedia of statistics**. Updated ed. New York, NY: Springer, 2010. (Springer reference).

DUBEY, S. R.; SINGH, S. K.; CHAUDHURI, B. B. Activation functions in deep learning: A comprehensive survey and benchmark. **Neurocomputing**, v. 503, p. 92–108, 2022.

EATWELL, J.; MILGATE, M.; NEWMAN, P. (org.). **Time Series and Statistics**. London: Palgrave Macmillan UK, 1990. Disponível em: <http://link.springer.com/10.1007/978-1-349-20865-4>. Acesso em: 27 dez. 2024.

ELY, D. F. PADRÕES ESPACIAIS DAS TENDÊNCIAS DAS PRECIPITAÇÕES SAZONAIS E MENSAIS NO ESTADO DO PARANÁ – BRASIL. **Revista Brasileira de Climatologia**, 2019. Disponível em: <https://revistas.ufpr.br/revistaabclima/article/view/66375>. Acesso em: 11 out. 2024.

FANG, J. *et al.* Ensemble learning using multivariate variational mode decomposition based on the Transformer for multi-step-ahead streamflow forecasting. **JOURNAL OF**

**HYDROLOGY**, v. 636, 2024.

FERENHOF, H. A.; FERNANDES, R. F. Desmistificando a revisão de literatura como base para redação científica: método SFF <p> DEMYSTIFYING THE LITERATURE REVIEW AS BASIS FOR SCIENTIFIC WRITING: SSF METHOD. **Revista ACB**, v. 21, n. 3, p. 550–563, 2016.

FIGUEROA, S. N. *et al.* The Brazilian Global Atmospheric Model (BAM): Performance for Tropical Rainfall Forecasting and Sensitivity to Convective Scheme and Horizontal Resolution. **Weather and Forecasting**, v. 31, n. 5, p. 1547–1572, 2016.

FIORIN, D. V. *et al.* Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, v. 33, p. 01–20, 2011.

GANAI, M. A. *et al.* Ensemble deep learning: A review. **Engineering Applications of Artificial Intelligence**, v. 115, p. 105151, 2022.

GAO, Z. *et al.* Deep Learning and the Weather Forecasting Problem: Precipitation Nowcasting. **Deep Learning for the Earth Sciences**, p. 218–239, 2021.

GARAI, S. *et al.* Machine learning algorithms for predicting rainfall in India. **Current Science**, v. 126, n. 3, p. 360–367, 2024.

GHAREHBAGHI, A. **Deep learning in time series analysis**. First edition. Boca Raton: CRC Press, 2023.

GOLDING, N. *et al.* Co-development of a seasonal rainfall forecast service: Supporting flood risk management for the Yangtze River basin. **Climate Risk Management**, v. 23, p. 43–49, 2019.

GOZUYILMAZ, S.; KUNDAKCIOGLU, O. E. Mathematical optimization for time series decomposition. **OR Spectrum**, v. 43, n. 3, p. 733–758, 2021.

GU, J. *et al.* A Stacking Ensemble Learning Model for Monthly Rainfall Prediction in the Taihu Basin, China. **Water**, v. 14, n. 3, p. 492, 2022.

GUO, S. *et al.* Research on precipitation prediction based on a complete ensemble empirical mode decomposition with adaptive noise–long short-term memory coupled model. **Water Supply**, v. 22, n. 12, p. 9061–9062, 2022.

GUO, Z. *et al.* Runoff time series prediction based on hybrid models of two-stage signal decomposition methods and LSTM for the Pearl River in China. **HYDROLOGY RESEARCH**, v. 54, n. 12, p. 1505–1521, 2023.

GUPTA, B. B. *et al.* Advance drought prediction through rainfall forecasting with hybrid deep learning model. **Scientific Reports**, v. 14, n. 1, p. 30459, 2024.

HABEN, S.; VOSS, M.; HOLDERBAUM, W. Time Series Forecasting: Core Concepts and Definitions. *In*: HABEN, S.; VOSS, M.; HOLDERBAUM, W. **Core Concepts and Methods in Load Forecasting**. Cham: Springer International Publishing, 2023. p. 55–66. Disponível em: [https://link.springer.com/10.1007/978-3-031-27852-5\\_5](https://link.springer.com/10.1007/978-3-031-27852-5_5). Acesso

em: 27 dez. 2024.

HAUPT, S. E. *et al.* Principles of meteorology and numerical weather prediction. *In: RENEWABLE ENERGY FORECASTING*. : Elsevier, 2017. p. 3–28. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780081005040000019>. Acesso em: 27 dez. 2024.

HAYKIN, S. S. **Neural networks and learning machines**. 3. eded. New York Munich: Prentice-Hall, 2009.

HE, R.; ZHANG, L.; CHEW, A. W. Z. Modeling and predicting rainfall time series using seasonal-trend decomposition and machine learning. **Knowledge-Based Systems**, p. 109125, 2022.

HUANG, S. *et al.* Short-Term Load Forecasting Based on the CEEMDAN-Sample Entropy-BPNN-Transformer. **Energies**, v. 15, n. 10, p. 3659, 2022.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. Third print editioned. Melbourne, Australia: Otexts, Online Open-Access Textbooks, 2021.

IBGE. **IBGE | Cidades@ | Paraná | Panorama**. 2024. Disponível em: <https://cidades.ibge.gov.br/brasil/pr/panorama>. Acesso em: 12 out. 2024.

INMET. **Catálogo de Estações Automáticas**. 2025a. Disponível em: <https://portal.inmet.gov.br/paginas/catalogoaut>. Acesso em: 16 jun. 2025.

INMET. **Catálogo de Estações Convencionais**. 2025b. Disponível em: <https://portal.inmet.gov.br/paginas/catalogoman>. Acesso em: 16 jun. 2025.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC) (org.). Water Cycle Changes. *In: Climate Change 2021 – The Physical Science Basis: Working Group I Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press, 2023. p. 1055–1210. Disponível em: <https://www.cambridge.org/core/books/climate-change-2021-the-physical-science-basis/water-cycle-changes/1E7F2B90411645E36048670B826F131A>. Acesso em: 9 out. 2024.

IPCC *et al.* **IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland**. : Intergovernmental Panel on Climate Change (IPCC), 2023. Disponível em: <https://www.ipcc.ch/report/ar6/syr/>. Acesso em: 9 out. 2024.

ITCG. **Clima - Estado do Paraná**. [: : S. n.], 2008. Escala 1:2.000.000. Disponível em: [https://www.iat.pr.gov.br/sites/agua-terra/arquivos\\_restritos/files/documento/2020-07/mapa\\_climas\\_a3.pdf](https://www.iat.pr.gov.br/sites/agua-terra/arquivos_restritos/files/documento/2020-07/mapa_climas_a3.pdf). Acesso em: 16 jun. 2025.

JADON, A.; PATIL, A.; JADON, S. A Comprehensive Survey of Regression-Based Loss Functions for Time Series Forecasting. *In: SHARMA, N. et al. (org.). Data Management, Analytics and Innovation*. Singapore: Springer Nature Singapore,

2024. (Lecture Notes in Networks and Systems). v. 998, p. 117–147. Disponível em: [https://link.springer.com/10.1007/978-981-97-3245-6\\_9](https://link.springer.com/10.1007/978-981-97-3245-6_9). Acesso em: 5 fev. 2025.

JIANG, X. A combined monthly precipitation prediction method based on CEEMD and improved LSTM. **PLoS ONE**, v. 18, n. 7 July, 2023. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85164845285&doi=10.1371%2fjournal.pone.0288211&partnerID=40&md5=6d6cdbc07c2b5b6584548f2f084deb23>.

JIAO, X.; HE, Z. A novel coupled rainfall prediction model based on stepwise decomposition technique. **Scientific Reports**, v. 14, n. 1, 2024. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85192730319&doi=10.1038%2fs41598-024-61855-0&partnerID=40&md5=61a14061b07a42977307031f05d26767>.

JOHNY, K.; PAI, M. L.; ADARSH, S. Adaptive EEMD-ANN hybrid model for Indian summer monsoon rainfall forecasting. **THEORETICAL AND APPLIED CLIMATOLOGY**, v. 141, n. 1–2, p. 1–17, 2020.

JOSEPH, J. *et al.* Hydrologic impacts of climate change: Comparisons between hydrological parameter uncertainty and climate model uncertainty. **Journal of Hydrology**, v. 566, p. 1–22, 2018.

JYOSTNA, B. *et al.* Multiscale rainfall forecasting using a hybrid ensemble empirical mode decomposition and LSTM model. **MODELING EARTH SYSTEMS AND ENVIRONMENT**, v. 11, n. 2, 2025.

KHAIRUDIN, N. M. *et al.* Hybrid machine learning model based on feature decomposition and entropy optimization for higher accuracy flood forecasting. **International Journal of Advances in Intelligent Informatics**, v. 10, n. 1, p. 1–12, 2024.

KIM, Y.-S. *et al.* Investigating the impact of data normalization methods on predicting electricity consumption in a building using different artificial neural network models. **Sustainable Cities and Society**, v. 118, p. 105570, 2025.

KUMAR, A.; JAIN, M. **Ensemble Learning for AI Developers: Learn Bagging, Stacking, and Boosting Methods with Use Cases**. Berkeley, CA: Apress, 2020. Disponível em: <http://link.springer.com/10.1007/978-1-4842-5940-5>. Acesso em: 10 out. 2024.

KUNDU, S. *et al.* A review on rainfall forecasting using ensemble learning techniques. **e-Prime - Advances in Electrical Engineering, Electronics and Energy**, v. 6, p. 100296–100296, 2023.

KUWAJIMA, J. I. *et al.* Climate change, water-related disasters, flood control and rainfall forecasting: a case study of the São Francisco River, Brazil. **Geological Society, London, Special Publications**, v. 488, n. 1, p. 259–276, 2019.

KYRIAKIDES, G.; MARGARITIS, K. **Hands-On Ensemble Learning with Python**. 1. ed. : Packt Publishing Ltd, 2019.

LATIFOGLU, L.; KAYA, E. High-performance prediction model combining minimum redundancy maximum relevance, circulant spectrum analysis, and machine learning methods for daily and peak streamflow. **THEORETICAL AND APPLIED CLIMATOLOGY**, 2023.

LI, F. *et al.* Decomposition-ANN Methods for Long-Term Discharge Prediction Based on Fisher's Ordered Clustering with MESA. **Water Resources Management**, v. 33, n. 9, p. 3095–3110, 2019.

LI, G. H.; MA, X.; YANG, H. A Hybrid Model for Monthly Precipitation Time Series Forecasting Based on Variational Mode Decomposition with Extreme Learning Machine. **INFORMATION**, v. 9, n. 7, 2018.

LI, F. F.; WANG, Z. Y.; QIU, J. Long-term streamflow forecasting using artificial neural network based on preprocessing technique. **JOURNAL OF FORECASTING**, v. 38, n. 3, p. 192–206, 2019.

LIU, F. P. *et al.* A New Precipitation Prediction Method Based on CEEMDAN-IWOA-BP Coupling. **WATER RESOURCES MANAGEMENT**, v. 36, n. 12, p. 4785–4797, 2022.

LIU, X. *et al.* Rainfall prediction optimization model in ten-day time step based on sliding window mechanism and zero sum game. **Journal of Water Supply: Research and Technology-Aqua**, v. 71, n. 1, p. 1–18, 2022.

MAITY, R. **Statistical Methods in Hydrology and Hydroclimatology**. : Springer Nature Singapore, 2022. (Springer Transactions in Civil and Environmental Engineering). Disponível em: Acesso em: 1 jan. 2022.

MARTÍN ABADI *et al.* **TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems**. [: : S. n.], 2015. Disponível em: <https://www.tensorflow.org/>.

MDR - MINISTÉRIO DA INTEGRAÇÃO E DO DESENVOLVIMENTO REGIONAL. **Atlas Digital de Desastres no Brasil**. 2024. Disponível em: <http://atlasdigital.mdr.gov.br/paginas/graficos.xhtml>. Acesso em: 9 out. 2024.

MLADEK, R. **Models**. 2025. Disponível em: <https://confluence.ecmwf.int/display/TIGGE/Models>. Acesso em: 5 mar. 2025.

MLADEK, R. **Total precipitation**. 2016. Disponível em: <https://confluence.ecmwf.int/display/TIGGE/Total+precipitation>. Acesso em: 5 mar. 2025.

MLADEK, R.; LOCK, S.-J. **ECMWF model description**. 2025. Disponível em: <https://confluence.ecmwf.int/display/TIGGE/ECMWF+model+description>. Acesso em: 5 mar. 2025.

MONTANHER, O. C.; MINAKI, C. Precipitação em Maringá-PR: estatísticas descritivas, tendência de longo prazo e probabilidade de eventos extremos diários. **Geography Department University of Sao Paulo**, v. 39, p. 138–153, 2020.

MOOSAVI, V.; GHEISOORI FARD, Z.; VAFAKHAH, M. Which one is more important in daily runoff forecasting using data driven models: Input data, model type, preprocessing or data length?. **Journal of Hydrology**, v. 606, 2022. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85123055296&doi=10.1016%2fj.jhydrol.2022.127429&partnerID=40&md5=123bf07ecbe5f934290008af96a54ec3>.

MOSAFFA, H. *et al.* Chapter 43 - Application of machine learning algorithms in hydrology. *In*: POURGHASEMI, H. R. (org.). **Computers in Earth and Environmental Sciences**. : Elsevier, 2022. p. 585–591. Disponível em: <https://www.sciencedirect.com/science/article/pii/B9780323898614000270>. Acesso em: 10 out. 2024.

NASKAR, P. R.; NASKAR, S. The most suitable mode decomposition technique for machine learning in meteorological time series prediction. **JOURNAL OF EARTH SYSTEM SCIENCE**, v. 132, n. 2, 2023.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION. **NOAA SCIENCE ADVISORY BOARD REPORT ON CLIMATE INFORMATION NEEDS FOR 5-10 YEAR HAZARD MITIGATION PLANNING CYCLES**. [: : S. n.], 2023. Disponível em: [https://sab.noaa.gov/wp-content/uploads/SAB\\_Report\\_Apr2023\\_CWG-ClimateInfoNeeds.pdf](https://sab.noaa.gov/wp-content/uploads/SAB_Report_Apr2023_CWG-ClimateInfoNeeds.pdf).

NG, K. W. *et al.* A review of hybrid deep learning applications for streamflow forecasting. **Journal of Hydrology**, v. 625, p. 130141, 2023.

NITSCHKE, P. R. *et al.* **Atlas Climático do Estado do Paraná**. Londrina, PR: Instituto Agrônômico do Paraná, 2019.

OUYANG, Q. *et al.* Monthly Rainfall Forecasting Using EEMD-SVR Based on Phase-Space Reconstruction. **WATER RESOURCES MANAGEMENT**, v. 30, n. 7, p. 2311–2325, 2016.

OUYANG, Z.; RAVIER, P.; JABLOUN, M. STL Decomposition of Time Series Can Benefit Forecasting Done by Statistical Methods but Not by Machine Learning Ones. *In*: INTERNATIONAL CONFERENCE ON TIME SERIES AND FORECASTING, 2021. **The 7th International Conference on Time Series and Forecasting**. : MDPI, 2021. p. 42. Disponível em: <https://www.mdpi.com/2673-4591/5/1/42>. Acesso em: 28 mar. 2025.

PAGE, M. J. *et al.* The PRISMA 2020 statement: an Updated Guideline for Reporting Systematic Reviews. **British Medical Journal**, v. 372, n. 71, 2021.

PARISOIJ, P. *et al.* Machine learning models coupled with empirical mode decomposition for simulating monthly and yearly streamflows: a case study of three watersheds in Ontario, Canada. **ENGINEERING APPLICATIONS OF COMPUTATIONAL FLUID MECHANICS**, v. 17, n. 1, 2023.

PARVIZ, L.; GHORBANPOUR, M. A hybrid EMD and MODWT models for monthly precipitation forecasting using an innovative error decomposition method. **STOCHASTIC ENVIRONMENTAL RESEARCH AND RISK ASSESSMENT**, v. 38, n. 10, p. 4107–4130, 2024.

PARVIZ, L.; RASOULI, K.; HAGHIGHI, A. T. Improving Hybrid Models for Precipitation Forecasting by Combining Nonlinear Machine Learning Methods. **Water Resources Management**, v. 37, n. 10, p. 3833–3855, 2023.

PENG, K. *et al.* Ensemble Empirical Mode Decomposition with Adaptive Noise with Convolution Based Gated Recurrent Neural Network: A New Deep Learning Model for South Asian High Intensity Forecasting. **Symmetry**, v. 13, n. 6, p. 931, 2021.

PETRY, I.; JARDIM, P.; FAN, F. M. **ANA Data Acquisition**. [: : S. n.], 2021. Disponível em: <https://github.com/HGE-IPH/ANA-Data-Acquisition>. Acesso em: 5 mar. 2025.

PETTITT, A. N. A Non-Parametric Approach to the Change-Point Problem. **Applied Statistics**, v. 28, n. 2, p. 126, 1979.

POUYANFAR, S. *et al.* A Survey on Deep Learning. **ACM Computing Surveys**, v. 51, n. 5, p. 1–36, 2018.

RAKHECHA, P. R.; SINGH, V. P. **Applied hydrometeorology**. Dordrecht ; [London]: Springer, 2009.

REN, S.; GHAZALI, K. H. Integrating Time Series Decomposition and Deep Learning: An STL-TCN-Transformer Framework for Landslide Displacement Prediction. *In*: THE 8TH MECHANICAL ENGINEERING, SCIENCE AND TECHNOLOGY INTERNATIONAL CONFERENCE, 2025. **The 8th Mechanical Engineering, Science and Technology International Conference**. : MDPI, 2025. p. 60. Disponível em: <https://www.mdpi.com/2673-4591/84/1/60>. Acesso em: 24 mar. 2025.

RIDWAN, W. M. *et al.* Rainfall forecasting model using machine learning methods: Case study Terengganu, Malaysia. **Ain Shams Engineering Journal**, 2020.

SENE, K. **Hydrometeorology**. Dordrecht: Springer Netherlands, 2010. Disponível em: <http://link.springer.com/10.1007/978-90-481-3403-8>. Acesso em: 9 out. 2024.

SERRANO-NOTIVOLI, R.; DE LUIS, M.; BEGUERÍA, S. An R package for daily precipitation climate series reconstruction. **Environmental Modelling & Software**, v. 89, p. 190–195, 2017.

SHEN, Z. Y.; BAN, W. C. Machine learning model combined with CEEMDAN algorithm for monthly precipitation prediction. **EARTH SCIENCE INFORMATICS**, 2023.

SHEN, C.; CHEN, X.; LALOY, E. Editorial: Broadening the Use of Machine Learning in Hydrology. **Frontiers in Water**, v. 3, 2021. Disponível em: <https://www.frontiersin.org/journals/water/articles/10.3389/frwa.2021.681023/full>. Acesso em: 10 out. 2024.

SHRESTHA, A.; MAHMOOD, A. Review of Deep Learning Algorithms and Architectures. **IEEE Access**, v. 7, p. 53040–53065, 2019.

SIBTAIN, M.; LI, X. S.; SALEEM, S. A Multivariate and Multistage Medium- and Long-Term Streamflow Prediction Based on an Ensemble of Signal Decomposition Techniques with a Deep Learning Network. **ADVANCES IN METEOROLOGY**, v. 2020, 2020.

SILVA, A. **Índices de detecção de mudanças climáticas na precipitação do Paraná-BR**. 2023. 126 f. Dissertação (Mestrado em Engenharia Civil) - Universidade Estadual de Londrina, Londrina, 2023.

SILVA, A. R. da; BOLONHEZ, B. F.; PINHEIRO, H. D. Homogeneity analysis of daily precipitation series in Paraná State, Southern Brazil. **Theoretical and Applied Climatology**, v. 155, n. 8, p. 8077–8088, 2024.

SILVA, M. M.; COSTA, J. P. Urban Floods and Climate Change Adaptation: The Potential of Public Space Design When Accommodating Natural Processes. **Water**, v. 10, n. 2, p. 180, 2018.

SIT, M. *et al.* A comprehensive review of deep learning applications in hydrology and water resources. **Water Science and Technology**, v. 82, n. 12, p. 2635–2670, 2020.

SOHRABBEIG, A.; ARDAKANIAN, O.; MUSILEK, P. Decompose and Conquer: Time Series Forecasting with Multiseasonal Trend Decomposition Using Loess. **Forecasting**, v. 5, n. 4, p. 684–696, 2023.

SONG, C. *et al.* Combining time varying filtering based empirical mode decomposition and machine learning to predict precipitation from nonlinear series. **Journal of Hydrology**, v. 603, p. 126914, 2021.

SONG, C.; CHEN, X. Performance comparison of machine learning models for annual precipitation prediction using different decomposition methods. **Remote Sensing**, v. 13, n. 5, p. 1–27, 2021.

SWINBANK, R. *et al.* The TIGGE Project and Its Achievements. **Bulletin of the American Meteorological Society**, v. 97, n. 1, p. 49–67, 2016.

TAN, Q.-F. *et al.* An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. **Journal of Hydrology**, v. 567, p. 767–780, 2018.

TAYYAB, M. *et al.* Application of Integrated Artificial Neural Networks Based on Decomposition Methods to Predict Streamflow at Upper Indus Basin, Pakistan. **ATMOSPHERE**, v. 9, n. 12, 2018.

TAYYAB, M. *et al.* Monthly Streamflow Forecasting Using Decomposition-Based Hybridization with Two-step Verification Method Over the Mangla Watershed, Pakistan. **IRANIAN JOURNAL OF SCIENCE AND TECHNOLOGY-TRANSACTIONS OF CIVIL ENGINEERING**, 2022.

TEBONG, N. K. *et al.* STL-decomposition ensemble deep learning models for daily reservoir inflow forecast for hydroelectricity production. **Heliyon**, v. 9, n. 6, 2023. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85160398632&doi=10.1016%2fj.heliyon.2023.e16456&partnerID=40&md5=3b5798334ecdae5191743c0f7deefc75>.

THOTTUNGAL HARILAL, G.; DIXIT, A.; QUATTRONE, G. Establishing hybrid deep learning models for regional daily rainfall time series forecasting in the United Kingdom. **Engineering Applications of Artificial Intelligence**, v. 133, p. 108581, 2024.

VAN ROSSUM, G.; DRAKE JR, F. L. **Python reference manual**. : Centrum voor Wiskunde en Informatica Amsterdam, 1995.

VON NEUMANN, J. Distribution of the Ratio of the Mean Square Successive Difference to the Variance. **The Annals of Mathematical Statistics**, v. 12, n. 4, p. 367–395, 1941.

WANG, W. C. *et al.* A Comparison of BPNN, GMDH, and ARIMA for Monthly Rainfall Forecasting Based on Wavelet Packet Decomposition. **WATER**, v. 13, n. 20, 2021.

WAQAS, M. *et al.* Artificial intelligence and numerical weather prediction models: A technical survey. **Natural Hazards Research**, p. S266659212400091X, 2024.

WEN, X. *et al.* Two-phase extreme learning machines integrated with the complete ensemble empirical mode decomposition with adaptive noise algorithm for multi-scale runoff prediction problems. **JOURNAL OF HYDROLOGY**, v. 570, p. 167–184, 2019.

WIJNGAARD, J. B.; KLEIN TANK, A. M. G.; KÖNNEN, G. P. Homogeneity of 20th century European daily temperature and precipitation series. **International Journal of Climatology**, v. 23, n. 6, p. 679–692, 2003.

WORLD METEOROLOGICAL ORGANIZATION. **Guide to meteorological instruments and methods of observation**. Geneva, Switzerland: World Meteorological Organization, 2008.

WORLD METEOROLOGICAL ORGANIZATION. Standardized Precipitation Index User Guide. v. WMO-No. 1090, 2012.

WU, F. *et al.* SDIPPWV: A novel hybrid prediction model based on stepwise decomposition-integration-prediction avoids future information leakage to predict precipitable water vapor from GNSS observations. **Science of The Total Environment**, v. 933, p. 173116, 2024.

WU, Z.; HUANG, N. E. ENSEMBLE EMPIRICAL MODE DECOMPOSITION: A NOISE-ASSISTED DATA ANALYSIS METHOD. **Advances in Adaptive Data Analysis**, v. 01, n. 01, p. 1–41, 2009.

WÜTHRICH, M. V.; MERZ, M. Recurrent Neural Networks. *In*: WÜTHRICH, M. V.; MERZ, M. **Statistical Foundations of Actuarial Learning and its Applications**. Cham: Springer International Publishing, 2023. (Springer Actuarial). p. 381–406. Disponível em: [https://link.springer.com/10.1007/978-3-031-12409-9\\_8](https://link.springer.com/10.1007/978-3-031-12409-9_8). Acesso em: 10 out. 2024.

XU, J. *et al.* A hybrid model to simulate the annual runoff of the Kaidu River in northwest China. **Hydrology and Earth System Sciences**, v. 20, n. 4, p. 1447–1457, 2016.

YADAV, D. S. P. **Towards artificial general intelligence: deep learning, neural networks, generative AI**. 1st. ed. BOSTON: De Gruyter, 2023.

YU, Y. *et al.* A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. **Neural Computation**, v. 31, n. 7, p. 1235–1270, 2019.

YU, Y. H.; ZHANG, H. B.; SINGH, V. P. Forward Prediction of Runoff Data in Data-Scarce Basins with an Improved Ensemble Empirical Mode Decomposition (EEMD) Model. **WATER**, v. 10, n. 4, 2018.

YUAN, R. F. *et al.* Daily Runoff Forecasting Using Ensemble Empirical Mode Decomposition and Long Short-Term Memory. **FRONTIERS IN EARTH SCIENCE**, v. 9, 2021.

ZHANG, X. *et al.* A new rainfall prediction model based on ICEEMDAN-WSD-BiLSTM and ESN. **Environmental Science and Pollution Research**, v. 30, n. 18, p. 53381–53396, 2023a.

ZHANG, X. K. *et al.* A Novel Hybrid Data-Driven Model for Daily Land Surface Temperature Forecasting Using Long Short-Term Memory Neural Network Based on Ensemble Empirical Mode Decomposition. **INTERNATIONAL JOURNAL OF ENVIRONMENTAL RESEARCH AND PUBLIC HEALTH**, v. 15, n. 5, 2018.

ZHANG, A. *et al.* **Dive into Deep Learning**. : arXiv, 2021. Disponível em: <https://arxiv.org/abs/2106.11342>. Acesso em: 10 out. 2024.

ZHANG, X. *et al.* Precipitation forecast based on CEEMD–LSTM coupled model. **Water Supply**, v. 21, n. 8, p. 4641–4657, 2021.

ZHANG, X. *et al.* Precipitation prediction based on CEEMDAN-VMD-BiLSTM combined quadratic decomposition model. **Water Supply**, v. 23, n. 9, p. 3597–3613, 2023b.

ZHANG, X. Q.; ZHENG, Z. J.; WU, X. Y. A novel regional annual precipitation predicting model. **DESALINATION AND WATER TREATMENT**, v. 191, p. 100–109, 2020.

ZHAO, J. *et al.* A novel approach to precipitation prediction using a coupled CEEMDAN-GRU-Transformer model with permutation entropy algorithm. **Water Science and Technology**, v. 88, n. 4, p. 1015–1038, 2023.

ZHAO, L. *et al.* Prediction of soil moisture using BiGRU-LSTM model with STL decomposition in Qinghai–Tibet Plateau. **PeerJ**, v. 11, p. e15851, 2023.

ZHAO, J. W.; NIE, G. Z.; WEN, Y. H. Monthly precipitation prediction in Luoyang city based on EEMD-LSTM-ARIMA model. **WATER SCIENCE AND TECHNOLOGY**, v. 87, n. 1, p. 318–335, 2023.

ZOUNEMAT-KERMANI, M. *et al.* Ensemble machine learning paradigms in hydrology: A review. **Journal of Hydrology**, v. 598, p. 126266, 2021.

## APÊNDICES

## APÊNDICE A

### Análise Exploratória da Normalização e Funções de Ativação

#### A.1 OBJETIVOS E FUNDAMENTAÇÃO

Para definir a função de ativação e o tipo de normalização a serem adotados ao longo da pesquisa, foram realizados testes preliminares. Esses avaliaram os efeitos de diferentes métodos de normalização (sem normalização, e normalização padrão) e funções de ativação (*tanh* e *LeakyReLU*).

No que se refere à normalização, o objetivo foi analisar o impacto das diferentes transformações tanto no treinamento do modelo quanto na qualidade das previsões (Bhanja; Das, 2018; Cabello-Solorzano *et al.*, 2023; Kim *et al.*, 2025). O uso de dados brutos, sem normalização, permite avaliar a capacidade do modelo de lidar com a magnitude natural da série. No entanto, oscilações e amplitudes elevadas podem comprometer o desempenho da rede neural. Para mitigar esses efeitos, testou-se também a normalização padrão (*Standard*), que centraliza os valores na média e os escala pelo desvio padrão, promovendo maior estabilidade no treinamento (Equação A.1) (Aggarwal, 2023; Gharehbaghi, 2023).

$$x_{normalizado} = \frac{x - \bar{x}}{s_x} \quad (A.2)$$

em que  $x$  é a variável de entrada,  $\bar{x}$  é a média da série e  $s_x$  é o desvio padrão amostral da série.

Na análise das funções de ativação, a escolha da *tanh* baseou-se em sua capacidade de gerar saídas simétricas em torno de zero, no intervalo de -1 a 1, o que favorece a representação de oscilações positivas e negativas nas séries (Ahmed; Hassan; Mstafa, 2022; Dubey; Singh; Chaudhuri, 2022; Haykin, 2009). Já a *LeakyReLU*, uma variação da ReLU, permite a passagem de valores negativos com leve inclinação, evitando o problema de "neurônios mortos". Essa característica a torna particularmente vantajosa para componentes da série que apresentem valores negativos eventuais (Aggarwal, 2023; Haykin, 2009; Parisouj *et al.*, 2023). Sua condição de operação está representada na Equação A2.

$$\text{LeakyReLU}(x) = \begin{cases} x, & \text{se } x \geq 0 \\ \alpha \cdot x & \text{se } x < 0 \end{cases} \quad (A.2)$$

## A.2 METODOLOGIA

Os testes propostos foram realizados utilizando a componente da tendência da série de precipitação decedial da Estação Maringá. A série de tendencias apresentava dimensão de 1643 valores, e foi segmentada para a criação dos pares de dados  $(\mathbf{T}_x, \mathbf{T}_y)_{cal}$  e  $(\mathbf{T}_x, \mathbf{T}_y)_{val}$ , como indicado na seção 3.1 - Tratamento e decomposição da série temporal.

Em seguida, foram modeladas quatro formulações distintas utilizando redes LSTM, variando a abordagem de normalização e a função de ativação. As formulações testadas foram:

- A. LSTM com dados brutos e função de ativação Tanh
- B. LSTM com dados brutos e função de ativação LeakyReLU
- C. LSTM com normalização padrão (Z-score) e função de ativação Tanh
- D. LSTM com normalização padrão (Z-score) e função de ativação LeakyReLU

A modelagem foi implementada em Python, utilizando TensorFlow/Keras para a construção das redes LSTM e o módulo Optuna para a calibração dos hiperparâmetros (50 tentativas de ajuste com *random state* = 37). O processo de otimização explorou diferentes combinações de hiper parâmetros, cujos valores testados estão apresentados no Quadro 3. A atualização dos pesos da rede neural foi conduzida com base na função de perda Erro Quadrático Médio (MSE), visando minimizar os erros de predição. O treinamento das redes foi realizado utilizando o otimizador Adam, enquanto a avaliação dos resultados seguiu as métricas descritas na Seção 3.5.

Os códigos-fonte da programação elaborados para a calibração e simulação utilizada para os testes estão disponíveis para acesso na pasta “Testes” em <https://drive.google.com/drive/folders/1nAog9l-kkqEu74v12kWVjDr6Cxjzq8Ck?usp=sharing>

## A.3 RESULTADOS E DISCUSSÃO


Considerando a metodologia proposta, inicialmente cada configuração foi submetida a um processo de calibração dos hiper parâmetros com o módulo Optuna. A Tabela A1 apresenta a melhor configuração identificada para a rede neural LSTM em cada teste, selecionada dentre 50 tentativas. A partir das configurações

otimizadas, os modelos foram ajustados para a calibração interna dos seus neurônios e, posteriormente, empregados na predição das tendências. Os resultados dessas predições são apresentados na Figura A1.

**Tabela A1** – Configuração dos testes

Teste	Camadas Ocultas	Neurônios	Taxa de Aprendizado	Tamanho do Batch	Epochs	Normalização	Função de ativação
<b>A</b>	2	50	0,01	64	200	Ausente	Tanh
<b>B</b>	1	100	0,01	64	100	Ausente	LeakyReLU
<b>C</b>	1	50	0,001	256	50	Standard	Tanh
<b>D</b>	1	50	0,001	256	50	Standard	LeakyReLU

**Figura A1** – Comparação das predições geradas pelos testes A, B, C e D



Fonte: a própria autora

A partir das previsões geradas, observa-se que todos os modelos apresentaram certa dificuldade na estimativa de máximos e mínimos, resultando em uma suavização da série de tendência prevista. A análise das métricas de desempenho (Tabela A2) reforça essa condição, indicando que, embora visualmente as previsões se assemelhem aos valores observados, a correspondência ainda não é ideal. O coeficiente de determinação obtido na validação permaneceu em um nível mediano ( $R^2 \leq 0,45$ ), enquanto o erro médio absoluto na previsão da tendência variou entre 15 e 16 mm.

**Tabela A2** – Métricas de performance dos testes

Teste	Calibração					Validação				
	MAE	R <sup>2</sup>	MSE	RMSE	NSE	MAE	R <sup>2</sup>	MSE	RMSE	NSE
A	12,92	0,466	259,6	16,11	0,466	16,20	0,420	424,7	20,61	0,420
B	12,91	0,462	261,9	16,18	0,462	16,17	0,407	434,8	20,85	0,407
C	13,31	0,442	271,6	16,48	0,442	15,56	0,455	399,0	19,98	0,455
D	13,39	0,437	274,1	16,56	0,437	15,72	0,445	406,4	20,16	0,445

Apesar da limitada capacidade preditiva observada, a comparação entre os testes indicou que as configurações que empregaram a normalização padrão apresentaram os melhores resultados na validação. Os resultados obtidos corroboram estudos hidrológicos, como os de Parisouj et al. (2023) e Wen et al. (2019), nos quais a normalização padrão foi empregada na modelagem. Esses estudos justificam a escolha da normalização principalmente com base na sua capacidade de reduzir o risco de o modelo priorizar variáveis de maior escala durante a calibração, contribuindo para maior estabilidade no treinamento

Quanto ao tipo de função de ativação, os modelos que utilizaram *tanh* demonstraram um desempenho superior em relação àqueles que empregaram *LeakyReLU*. Esse padrão de desempenho se manteve mesmo entre os modelos dos Testes C e D, que possuíam configurações idênticas (Tabela A1), diferindo apenas na função de ativação. Esse resultado sugere que a escolha da função de ativação teve influência direta na capacidade preditiva do modelo.

Dubey, Singh e Chaudhuri (2022), que avaliaram o desempenho de 18 funções de ativação em diferentes arquiteturas de redes neurais, o fator mais determinante no aprendizado profundo é garantir que a complexidade da rede esteja ajustada à

complexidade do conjunto de dados.

#### A.4 CONCLUSÃO

Os testes realizados permitiram avaliar o impacto da normalização e da função de ativação na predição da tendência hidrológica utilizando redes LSTM. Os resultados indicaram que a normalização padrão contribuiu para um melhor desempenho na validação e que os modelos que empregaram a função tanh superaram aqueles que utilizaram LeakyReLU.

## APÊNDICE B

### Configuração dos modelos e tempos de processamento

**Quadro B1** – Configurações do equipamento e dos softwares utilizados

<b>Hardware do computador</b>	Processador AMD Ryzen 7 5700X; 32 GB RAM DDR4-3596 MHz (2x16 GB); GPU NVIDIA RTX 3060 T; Placa-Mãe B550M Aorus Elite; SSD NV2 1 TB
<b>Sistema Operacional</b>	Windows 11 PRO, Versão 24H2, Compilação 26100.3476
<b>Python e módulos principais</b>	Python (v. 3.10.14); TensorFlow (v. 2.10.0); Scikit-learn (v. 1.3.0); Optuna (3.3.0); Pandas (v. 2.1.4); Numpy (v. 1.26.4); Matplotlib (v. 3.8.4); Statsmodels (v. 0.14.0); Xarray (v. 2025.1.2); ECMWF API (v. 1.6.3); tqdm (v. 4.65.0)

**Tabela B1** – Configurações e processamento dos modelos – Estação Maringá (02351013)

Modelo	Nº Camadas	Nº Neurônios	Batch	Epoch	Taxa de Aprendizado	Tempo Calibração (h:mm:ss)	Tempo Simulação (h:mm:ss)	Tempo Total (h:mm:ss)
<b>Decomposição em etapas</b>	-	-	-	-	-	-	0:00:09	0:00:09
<b>RNN<sub>TEND.</sub></b>	2	100	256	50	0,001	0:22:29,8	0:00:04,6	0:22:34,4
<b>RNN<sub>SAZON.</sub></b>	3	100	128	100	0,01	0:39:30,0	0:00:12,5	0:39:42,5
<b>RNN<sub>RESÍD.</sub></b>	2	25	64	50	0,01	0:36:01,1	0:00:09,1	0:36:10,2
<b>LSTM<sub>TEND.</sub></b>	2	50	128	200	0,001	0:26:47,7	0:00:12,3	0:27:00,0
<b>LSTM<sub>SAZON.</sub></b>	2	25	64	50	0,1	0:24:07,0	0:00:17,7	0:24:24,7
<b>LSTM<sub>RESÍD.</sub></b>	2	50	128	50	0,01	0:15:26,8	0:00:15,3	0:15:42,2
<b>GRU<sub>TEND.</sub></b>	1	100	64	200	0,1	0:07:56,5	0:00:30,2	0:08:26,8
<b>GRU<sub>SAZON.</sub></b>	1	50	128	50	0,1	0:05:44,3	0:00:06,7	0:05:51,0
<b>GRU<sub>RESÍD.</sub></b>	2	50	64	100	0,001	0:10:02,0	0:00:12,4	0:10:14,4
<b>B1</b>	1	100	256	100	0,01	0:21:49	0:00:05	0:21:55
<b>B2</b>	3	25	256	200	0,001	0:16:23	0:00:10	0:16:33
<b>B3</b>	1	25	125	200	0,001	0:08:06	0:00:08	0:08:14
<b>R1</b>	-	-	-	-	-	1:38:01	0:00:26	1:38:36
<b>R2</b>	-	-	-	-	-	1:06:22	0:00:45	1:07:16
<b>R3</b>	-	-	-	-	-	1:38:01	0:00:49	1:38:59
<b>R4</b>	-	-	-	-	-	2:44:22	0:00:39	2:45:11
<b>H1</b>	2	25	256	100	0,001	2:48:03	0:00:43	2:48:55
<b>H2</b>	2	25	256	100	0,1	2:49:01	0:02:09	2:51:19
<b>H3</b>	-	-	-	-	-	3:45:44	0:02:58	3:48:51
<b>H3<sub>TEND.</sub></b>	2	100	64	100	0,1	0:26:28	00:09,7	0:26:38,0
<b>H3<sub>TEND.</sub></b>	2	25	128	200	0,1	0:11:42	00:11,0	0:11:52,6
<b>H3<sub>TEND.</sub></b>	2	25	64	400	0,01	0:23:12	00:36,6	0:23:48,5
<b>H4</b>	1	25	256	100	0,001	3:50:40	0:03:05	3:53:53
<b>H5</b>	2	50	256	200	0,1	0:51:40	0:00:33	0:52:13

**Tabela B2 – Configurações e processamento dos modelos – Estação Colônia Vitória (02551008)**

Modelo	Nº Camadas	Nº Neurônios	Batch	Epoch	Taxa de Aprendizado	Tempo Calibração (h:mm:ss)	Tempo Simulação (h:mm:ss)	Tempo Total (h:mm:ss)
<b>Decomposição em etapas</b>	-	-	-	-	-	-	0:00:04	0:00:04
<b>RNN<sub>TEND.</sub></b>	3	50	128	200	0,001	0:38:24	00:20,4	0:38:44
<b>RNN<sub>SAZON</sub></b>	2	50	256	100	0,001	0:08:34	00:05,2	0:08:39
<b>RNN<sub>RESÍD.</sub></b>	3	25	128	100	0,01	0:16:52	00:10,6	0:17:03
<b>LSTM<sub>TEND.</sub></b>	3	50	128	50	0,001	0:07:49	00:19,8	0:08:09
<b>LSTM<sub>SAZON</sub></b>	2	25	256	50	0,001	0:08:20	00:04,3	0:08:24
<b>LSTM<sub>RESÍD</sub></b>	1	25	256	50	0,01	0:05:30	0:00:12	0:05:42
<b>GRU<sub>TEND.</sub></b>	3	50	128	100	0,001	0:15:00	00:10,1	0:15:10
<b>GRU<sub>SAZON.</sub></b>	1	25	256	50	0,001	0:06:42	00:03,2	0:06:45
<b>GRU<sub>RESÍD.</sub></b>	1	100	64	200	0,1	0:08:40	00:16,4	0:08:57
<b>B1</b>	1	25	256	200	0,001	0:11:08	0:00:05	0:11:13
<b>B2</b>	3	25	128	50	0,1	0:14:58	0:00:27	0:15:25
<b>B3</b>	1	25	256	200	0,001	0:17:17	0:00:13	0:17:30
<b>R1</b>	-	-	-	-	-	1:03:50	0:00:36	1:04:30
<b>R2</b>	-	-	-	-	-	0:21:39	0:00:36	0:22:20
<b>R3</b>	-	-	-	-	-	0:30:22	0:00:30	0:30:56
<b>R4</b>	-	-	-	-	-	1:55:51	0:00:35	1:56:30
<b>H1</b>	3	50	128	100	0,1	1:59:49	0:00:42	2:00:35
<b>H2</b>	3	25	128	50	0,1	2:01:30	0:01:50	2:03:24
<b>H3</b>	-	-	-	-	-	2:26:45	0:02:07	2:28:56
<b>H3<sub>TEND.</sub></b>	1	50	32	100	0,001	0:11:25	00:09,9	0:11:35
<b>H3<sub>TEND.</sub></b>	1	25	64	100	0,001	0:09:37	00:05,4	0:09:42
<b>H3<sub>TEND.</sub></b>	1	100	64	200	0,01	0:09:35	00:10,2	0:09:45
<b>H4</b>	2	50	64	50	0,01	2:30:54	0:02:15	2:33:13
<b>H5</b>	3	50	256	100	0,01	0:51:11	0:00:51	0:52:02

## APÊNDICE C

Análises descritivas das séries observadas e previstas

**Tabela C1 – Análise descritiva dos modelos das componentes – Calibração – Estação Maringá (02351013)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Tendência Observada</b>	44,05	22,07	2,00	26,90	42,65	59,16	116,94
<b>RNN<sub>TEND.</sub></b>	44,17	15,52	5,73	32,00	42,06	54,79	93,14
<b>LSTM<sub>TEND.</sub></b>	44,42	14,49	10,57	33,04	42,51	54,20	92,42
<b>GRU<sub>TEND.</sub></b>	44,49	15,25	20,70	32,01	43,41	54,20	88,54
<b>Sazonalidade Observada</b>	0,01	7,14	-14,95	-5,69	-0,54	5,02	19,98
<b>RNN<sub>SAZON.</sub></b>	1,07	2,19	-4,75	-0,08	0,67	2,05	8,72
<b>LSTM<sub>SAZON.</sub></b>	-0,66	2,18	-11,50	-1,55	-0,39	0,00	11,18
<b>GRU<sub>SAZON.</sub></b>	-1,01	2,12	-7,83	-2,24	-0,98	0,11	10,53
<b>Resíduo Observado</b>	0,01	36,38	-85,40	-23,40	-6,87	15,23	199,55
<b>RNN<sub>RESÍD.</sub></b>	-0,42	6,75	-35,95	-2,75	1,69	4,33	8,04
<b>LSTM<sub>RESÍD.</sub></b>	-0,20	6,60	-36,54	-2,78	2,20	4,48	6,91
<b>GRU<sub>RESÍD.</sub></b>	1,90	5,31	-14,21	-1,32	2,42	6,26	9,35

**Tabela C2 – Análise descritiva das componentes observadas e previstas – Validação – Estação Maringá (02351013)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Tendência Observada</b>	51,23	27,11	3,12	29,58	46,24	69,39	132,09
<b>RNN<sub>TEND.</sub></b>	46,99	17,12	12,34	34,52	45,01	58,14	100,47
<b>LSTM<sub>TEND.</sub></b>	47,16	16,14	15,75	35,38	45,08	57,48	98,69
<b>GRU<sub>TEND.</sub></b>	46,79	15,49	20,62	35,81	45,80	57,85	91,10
<b>Sazonalidade Observada</b>	0,05	12,10	-23,60	-7,24	-2,73	7,65	26,28
<b>RNN<sub>SAZON.</sub></b>	1,23	2,40	-4,47	-0,23	1,25	2,79	8,33
<b>LSTM<sub>SAZON.</sub></b>	-0,36	2,67	-6,67	-1,48	-0,35	0,56	11,26
<b>GRU<sub>SAZON.</sub></b>	-0,71	3,11	-11,31	-2,34	-0,57	0,88	10,81
<b>Resíduo Observado</b>	-0,11	43,18	-114,65	-26,51	-7,67	18,28	195,11
<b>RNN<sub>RESÍD.</sub></b>	0,67	5,36	-13,67	-2,35	1,11	4,72	9,20
<b>LSTM<sub>RESÍD.</sub></b>	-2,32	8,20	-36,23	-5,53	0,41	3,52	8,07
<b>GRU<sub>RESÍD.</sub></b>	-2,06	8,37	-40,53	-5,14	0,62	3,97	6,76

**Tabela C3 – Análise descritiva dos modelos das componentes – Calibração – Estação Colônia Vitória (02551008)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Tendência Observada</b>	54,25	23,81	4,04	36,99	51,29	67,54	182,38
<b>RNN<sub>TEND.</sub></b>	54,23	16,63	22,09	41,11	51,30	64,43	124,63
<b>LSTM<sub>TEND.</sub></b>	54,44	14,94	28,12	44,07	51,86	61,68	150,71
<b>GRU<sub>TEND.</sub></b>	54,23	15,10	28,59	43,24	51,92	62,00	145,84
<b>Sazonalidade Observada</b>	0,01	10,41	-20,84	-6,37	-1,20	4,48	47,94
<b>RNN<sub>SAZON.</sub></b>	0,78	3,37	-15,66	-1,75	0,80	2,84	15,19
<b>LSTM<sub>SAZON.</sub></b>	0,05	1,91	-3,02	-1,22	-0,31	0,77	16,74
<b>GRU<sub>SAZON.</sub></b>	0,03	2,24	-8,48	-1,22	0,15	1,36	11,39
<b>Resíduo Observado</b>	0,03	43,96	-113,60	-29,32	-7,37	20,34	254,28
<b>RNN<sub>RESÍD.</sub></b>	1,77	6,21	-22,21	0,97	3,92	5,36	9,06
<b>LSTM<sub>RESÍD.</sub></b>	1,68	7,62	-46,70	-1,46	2,79	6,42	21,07
<b>GRU<sub>RESÍD.</sub></b>	-3,67	6,37	-40,48	-5,69	-2,11	0,93	2,12

**Tabela C4 – Análise descritiva dos modelos das componentes – Validação – Estação Colônia Vitória (02551008)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Tendência Observada</b>	52,81	20,24	5,74	39,34	51,09	66,83	111,67
<b>RNN<sub>TEND.</sub></b>	53,60	15,01	21,94	41,99	51,86	62,82	100,09
<b>LSTM<sub>TEND.</sub></b>	53,67	12,70	27,82	44,52	52,03	59,96	98,91
<b>GRU<sub>TEND.</sub></b>	53,64	13,19	28,30	43,52	52,71	60,99	99,64
<b>Sazonalidade Observada</b>	0,07	10,74	-24,28	-3,73	1,28	6,94	19,37
<b>RNN<sub>SAZON.</sub></b>	0,66	3,17	-5,84	-1,89	0,14	2,99	9,35
<b>LSTM<sub>SAZON.</sub></b>	-0,04	1,73	-2,22	-1,30	-0,55	0,70	5,85
<b>GRU<sub>SAZON.</sub></b>	0,04	1,98	-4,89	-1,38	-0,23	1,33	5,22
<b>Resíduo Observado</b>	-0,02	43,00	-112,11	-31,12	-5,67	20,14	191,79
<b>RNN<sub>RESÍD.</sub></b>	1,17	6,53	-21,33	-0,15	3,60	4,69	9,15
<b>LSTM<sub>RESÍD.</sub></b>	1,37	7,59	-30,74	-1,59	2,22	6,28	16,11
<b>GRU<sub>RESÍD.</sub></b>	-3,85	5,99	-30,41	-5,83	-2,28	0,85	2,22

**Tabela C5 – Análise descritiva da série de precipitação decendial observada e prevista pelos modelos – Calibração – Estação Maringá (02351013)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Observado</b>	44,07	45,54	0,00	8,20	30,60	66,88	299,00
<b>B1</b>	43,17	11,13	25,31	34,58	41,96	51,21	73,54
<b>B2</b>	43,62	11,98	14,01	34,01	43,15	52,90	69,69
<b>B3</b>	44,46	11,86	11,12	35,05	43,98	53,36	71,15
<b>R1</b>	47,14	14,67	0,90	35,88	45,56	57,31	94,12
<b>R2</b>	43,35	13,19	5,74	33,49	41,47	52,45	91,91
<b>R3</b>	43,28	13,92	11,16	31,89	42,44	52,58	91,66
<b>R4</b>	45,30	13,26	8,43	35,49	44,00	54,27	89,87
<b>H1</b>	44,23	10,40	19,69	35,85	43,03	52,45	69,82
<b>H2</b>	47,05	15,14	16,84	32,86	48,87	61,93	77,79
<b>H3</b>	52,29	14,97	13,88	39,09	54,26	63,27	86,29
<b>H4</b>	44,26	11,31	15,03	34,64	43,31	53,02	69,23
<b>H5</b>	39,94	10,83	26,50	29,63	40,23	53,79	58,12

**Tabela C6 – Análise descritiva da série de precipitação decendial observada e prevista pelos modelos – Validação – Estação Maringá (02351013)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Observado</b>	51,17	54,56	0,00	8,95	36,55	74,73	321,76
<b>B1</b>	44,29	11,74	25,32	35,35	42,77	52,19	73,01
<b>B2</b>	44,52	12,33	14,51	35,75	43,80	54,58	68,90
<b>B3</b>	45,18	12,46	0,92	36,15	44,30	55,30	70,27
<b>R1</b>	48,88	16,41	11,99	37,05	47,51	59,25	101,51
<b>R2</b>	44,47	15,03	10,89	33,27	43,69	53,63	85,57
<b>R3</b>	44,02	14,95	10,17	32,40	44,61	53,28	82,64
<b>R4</b>	46,32	14,67	16,18	35,35	46,04	56,27	87,91
<b>H1</b>	44,36	11,33	23,16	35,27	43,85	53,31	69,67
<b>H2</b>	43,04	15,29	19,57	31,86	37,35	57,50	75,79
<b>H3</b>	53,02	15,76	9,25	41,64	56,03	63,38	85,78
<b>H4</b>	43,84	11,65	13,38	34,83	44,19	52,24	67,66
<b>H5</b>	40,89	10,80	26,50	32,99	41,62	54,41	58,02
<b>CPTEC</b>	43,34	33,56	0,00	15,51	36,53	62,83	179,48
<b>ECMWF</b>	56,23	45,93	0,00	21,80	47,81	77,29	276,70

**Tabela C7 – Análise descritiva da série de precipitação decendial observada e prevista pelos modelos – Calibração – Estação Colônia Vitória (02551008)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Observado</b>	54,29	53,33	0,00	14,40	40,40	77,80	382,40
<b>B1</b>	54,61	8,01	41,11	48,85	53,18	59,60	95,03
<b>B2</b>	53,37	4,77	40,03	51,31	51,83	53,60	63,35
<b>B3</b>	56,47	3,74	47,35	54,41	56,68	57,79	69,07
<b>R1</b>	56,77	16,34	19,31	45,00	54,77	66,56	121,09
<b>R2</b>	56,17	14,22	26,04	46,35	54,39	63,48	134,12
<b>R3</b>	50,58	13,67	13,50	40,50	48,91	57,89	134,87
<b>R4</b>	56,26	14,47	23,59	46,32	54,33	63,47	136,71
<b>H1</b>	56,09	14,41	24,40	45,19	50,52	68,36	89,67
<b>H2</b>	56,53	5,67	30,55	53,68	59,17	59,17	72,38
<b>H3</b>	54,17	13,83	19,75	44,11	53,06	62,32	119,29
<b>H4</b>	52,09	11,53	34,78	42,90	48,17	60,24	81,12
<b>H5</b>	54,45	11,64	35,78	46,16	51,79	60,35	82,04

**Tabela C8 – Análise descritiva da série de precipitação decendial observada e prevista pelos modelos – Validação – Estação Colônia Vitória (02551008)**

Modelo	Média	Desvio Padrão	Mínimo	25%	50%	75%	Máximo
<b>Observado</b>	52,87	51,00	0,00	11,98	43,25	75,65	277,50
<b>B1</b>	54,23	7,50	41,10	49,13	52,83	58,47	85,01
<b>B2</b>	53,35	5,00	40,96	51,23	51,80	53,61	63,35
<b>B3</b>	56,05	3,26	47,40	54,03	56,43	57,56	68,52
<b>R1</b>	55,43	13,94	16,42	44,98	54,90	64,34	106,91
<b>R2</b>	55,00	12,01	26,04	46,50	53,70	61,35	99,02
<b>R3</b>	49,83	11,32	22,65	42,30	49,03	56,22	87,54
<b>R4</b>	54,80	11,71	24,88	46,28	54,46	61,49	103,59
<b>H1</b>	55,86	14,33	30,04	45,20	50,18	69,26	85,22
<b>H2</b>	57,00	5,06	42,70	55,50	59,17	59,17	69,20
<b>H3</b>	53,13	11,64	21,40	44,62	52,86	59,95	96,65
<b>H4</b>	51,23	10,24	37,00	43,11	48,66	58,66	80,68
<b>H5</b>	53,91	11,27	35,78	45,50	51,04	59,59	81,99
<b>CPTEC</b>	24,52	24,27	0,00	5,50	19,36	35,51	146,14
<b>ECMWF</b>	51,55	46,70	0,00	13,09	43,16	76,76	229,34

## APÊNDICE D

### Comparação entre as performances dos modelos

**Tabela D1 – Variação do coeficiente de determinação ( $\Delta R^2$ ) – Validação – Estação Maringá (02351013)**

Modelo						
	<u>R<sup>2</sup></u>	H1	H2	H3	H4	H5
		<u>0,028</u>	<u>-0,103</u>	<u>0,029</u>	<u>0,018</u>	<u>0,021</u>
<b>B1</b>	<u>0,027</u>	-0,001 (-3,32%)	0,13 (-126,34%)	-0,002 (-6,04%)	0,009 (51,08%)	0,006 (31,3%)
<b>B2</b>	<u>0,038</u>	0,01 (36,88%)	0,141 (-137,29%)	0,01 (33,02%)	0,02 (113,9%)	0,018 (85,88%)
<b>B3</b>	<u>0,039</u>	0,011 (38,39%)	0,142 (-137,7%)	0,01 (34,48%)	0,021 (116,25%)	0,018 (87,93%)
<b>R1</b>	<u>0,019</u>	-0,009 (-31,56%)	0,122 (-118,64%)	-0,01 (-33,49%)	0,001 (6,95%)	-0,001 (-7,06%)
<b>R2</b>	<u>0,015</u>	-0,013 (-45,49%)	0,118 (-114,85%)	-0,014 (-47,03%)	-0,003 (-14,82%)	-0,005 (-25,98%)
<b>R3</b>	<u>0,003</u>	-0,025 (-87,76%)	0,106 (-103,33%)	-0,025 (-88,11%)	-0,015 (-80,88%)	-0,017 (-83,38%)
<b>R4</b>	<u>0,029</u>	0,001 (4,17%)	0,132 (-128,38%)	0,0003 (1,23%)	0,011 (62,78%)	0,009 (41,46%)
<b>CPTEC</b>	<u>0,117</u>	0,089 (319,14%)	0,22 (1233,24%)	0,089 (307,31%)	0,099 (554,96%)	0,097 (469,18%)
<b>ECMWF</b>	<u>0,198</u>	0,17 (606,44%)	0,301 (1461,36%)	0,169 (586,5%)	0,18 (1003,91%)	0,177 (859,34%)

Nota: valores positivos de variação ( $\Delta R^2$ ) indicam melhora na predição

**Tabela D2 – Variação do coeficiente de determinação ( $\Delta R^2$ ) – Validação – Estação Colônia Vitória (02551008)**

Modelo						
	<u>R<sup>2</sup></u>	H1	H2	H3	H4	H5
		<u>-0,104</u>	<u>-0,016</u>	<u>-0,053</u>	<u>-0,046</u>	<u>-0,051</u>
<b>B1</b>	<u>-0,012</u>	0,092 (-88,72%)	0,004 (-25,03%)	0,041 (-77,95%)	0,035 (-74,73%)	0,039 (-76,94%)
<b>B2</b>	<u>-0,012</u>	0,092 (-87,99%)	0,003 (-20,19%)	0,041 (-76,52%)	0,034 (-73,1%)	0,038 (-75,46%)
<b>B3</b>	<u>-0,005</u>	0,1 (-95,67%)	0,011 (-71,24%)	0,049 (-91,54%)	0,042 (-90,31%)	0,046 (-91,15%)
<b>R1</b>	<u>-0,075</u>	0,029 (-28,01%)	-0,059 (378,38%)	-0,022 (40,72%)	-0,028 (61,22%)	-0,024 (47,12%)
<b>R2</b>	<u>-0,054</u>	0,05 (-47,65%)	-0,039 (247,89%)	-0,001 (2,33%)	-0,008 (17,25%)	-0,004 (6,99%)
<b>R3</b>	<u>-0,055</u>	0,049 (-46,94%)	-0,04 (252,63%)	-0,002 (3,73%)	-0,009 (18,84%)	-0,004 (8,45%)
<b>R4</b>	<u>-0,053</u>	0,051 (-49,21%)	-0,037 (237,53%)	0 (-0,71%)	-0,006 (13,76%)	-0,002 (3,8%)
<b>CPTEC</b>	<u>-0,19</u>	-0,088 (84,52%)	-0,176 (1126,21%)	-0,139 (260,7%)	-0,145 (313,26%)	-0,141 (277,1%)
<b>ECMWF</b>	<u>0,03</u>	0,135 (-30,19%)	0,047 (-300,6%)	0,085 (-159,01%)	0,078 (-167,61%)	0,082 (-161,69%)

Nota: valores positivos de variação ( $\Delta R^2$ ) indicam melhora na predição

**Tabela D3 – Variação da raiz do erro quadrático médio ( $\Delta$ RMSE) – Validação – Estação Maringá (02351013)**

Modelo	H1 H2 H3 H4 H5					
	RMSE	53,71	57,21	53,68	53,98	53,91
<b>B1</b>	<u>53,74</u>	0,026 (0,05%)	-3,476 (-6,08%)	0,048 (0,09%)	-0,252 (-0,47%)	-0,178 (-0,33%)
<b>B2</b>	<u>53,42</u>	-0,286 (-0,53%)	-3,788 (-6,62%)	-0,264 (-0,49%)	-0,564 (-1,05%)	-0,49 (-0,91%)
<b>B3</b>	<u>53,41</u>	-0,298 (-0,55%)	-3,799 (-6,64%)	-0,275 (-0,51%)	-0,576 (-1,07%)	-0,502 (-0,93%)
<b>R1</b>	<u>53,95</u>	0,244 (0,45%)	-3,258 (-5,69%)	0,266 (0,5%)	-0,034 (-0,06%)	0,04 (0,07%)
<b>R2</b>	<u>54,06</u>	0,351 (0,65%)	-3,15 (-5,51%)	0,373 (0,7%)	0,073 (0,14%)	0,147 (0,27%)
<b>R3</b>	<u>54,39</u>	0,675 (1,26%)	-2,826 (-4,94%)	0,698 (1,3%)	0,397 (0,74%)	0,471 (0,87%)
<b>R4</b>	<u>53,68</u>	-0,032 (-0,06%)	-3,534 (-6,18%)	-0,01 (-0,02%)	-0,31 (-0,57%)	-0,236 (-0,44%)
<b>CPTEC</b>	<u>51,55</u>	-2,161 (-4,02%)	-5,662 (-9,9%)	-2,139 (-3,98%)	-2,439 (-4,52%)	-2,365 (-4,39%)
<b>ECMWF</b>	<u>48,79</u>	-4,919 (-9,16%)	-8,421 (-14,72%)	-4,897 (-9,12%)	-5,197 (-9,63%)	-5,123 (-9,5%)

Nota: percentuais positivos indicam piora na predição

**Tabela D4 – Variação da raiz do erro quadrático médio ( $\Delta$ RMSE) – Validação – Estação Colônia Vitória (02551008)**

Modelo	H1 H2 H3 H4 H5					
	RMSE	53,501	51,315	52,255	52,087	52,198
<b>B1</b>	<u>51,216</u>	-2,285 (-4,27%)	-0,099 (-0,19%)	-1,039 (-1,99%)	-0,871 (- 1,67%)	-0,982 (-1,88%)
<b>B2</b>	<u>51,235</u>	-2,266 (-4,23%)	-0,08 (-0,16%)	-1,02 (-1,95%)	-0,852 (- 1,64%)	-0,963 (-1,84%)
<b>B3</b>	<u>51,033</u>	-2,468 (-4,61%)	-0,282 (-0,55%)	-1,223 (-2,34%)	-1,055 (- 2,02%)	-1,165 (-2,23%)
<b>R1</b>	<u>52,790</u>	-0,711 (-1,33%)	1,475 (2,87%)	0,535 (1,02%)	0,703 (1,35%)	0,592 (1,13%)
<b>R2</b>	<u>52,286</u>	-1,215 (-2,27%)	0,971 (1,89%)	0,031 (0,06%)	0,199 (0,38%)	0,088 (0,17%)
<b>R3</b>	<u>52,305</u>	-1,196 (-2,24%)	0,989 (1,93%)	0,049 (0,09%)	0,217 (0,42%)	0,107 (0,2%)
<b>R4</b>	<u>52,246</u>	-1,255 (-2,35%)	0,931 (1,81%)	-0,009 (-0,02%)	0,159 (0,3%)	0,048 (0,09%)
<b>CPTEC</b>	<u>55,950</u>	2,45 (4,58%)	4,636 (9,03%)	3,696 (7,07%)	3,864 (7,42%)	3,753 (7,19%)
<b>ECMWF</b>	<u>50,110</u>	-3,389 (-6,33%)	-1,203 (-2,34%)	-2,143 (-4,1%)	-1,975 (-3,79%)	-2,086 (-4%)

Nota: percentuais positivos indicam piora na predição

**Tabela D5 – Variação da raiz do erro médio absoluto ( $\Delta$ MAE) – Validação – Estação Maringá (02351013)**

Modelo	H1 H2 H3 H4 H5					
	MAE	38,539	41,310	40,354	38,654	37,565
<b>B1</b>	<u>38,557</u>	0,018 (0,05%)	-2,753 (-6,66%)	-1,797 (-4,45%)	-0,097 (-0,25%)	0,993 (2,64%)
<b>B2</b>	<u>38,336</u>	-0,203 (-0,53%)	-2,974 (-7,2%)	-2,019 (-5%)	-0,318 (-0,82%)	0,771 (2,05%)
<b>B3</b>	<u>38,552</u>	0,013 (0,03%)	-2,758 (-6,68%)	-1,802 (-4,47%)	-0,102 (-0,26%)	0,988 (2,63%)
<b>R1</b>	<u>39,695</u>	1,156 (3%)	-1,615 (-3,91%)	-0,659 (-1,63%)	1,041 (2,69%)	2,131 (5,67%)
<b>R2</b>	<u>39,051</u>	0,513 (1,33%)	-2,258 (-5,47%)	-1,303 (-3,23%)	0,397 (1,03%)	1,487 (3,96%)
<b>R3</b>	<u>38,936</u>	0,397 (1,03%)	-2,374 (-5,75%)	-1,419 (-3,52%)	0,281 (0,73%)	1,371 (3,65%)
<b>R4</b>	<u>38,979</u>	0,44 (1,14%)	-2,331 (-5,64%)	-1,376 (-3,41%)	0,325 (0,84%)	1,414 (3,76%)
<b>CPTEC</b>	<u>38,613</u>	0,074 (0,19%)	-2,697 (-6,53%)	-1,741 (-4,32%)	-0,041 (-0,11%)	1,048 (2,79%)
<b>ECMWF</b>	<u>34,893</u>	-3,646 (-9,46%)	-6,417 (-15,53%)	-5,462 (-13,53%)	-3,761 (-9,73%)	-2,672 (-7,11%)

Nota: percentuais positivos indicam piora na predição

**Tabela D6 – Variação da raiz do erro médio absoluto ( $\Delta$ MAE) – Validação – Estação Colônia Vitória (02551008)**

Modelo	H1 H2 H3 H4 H5					
	MAE	40,662	39,541	39,489	38,802	39,236
<b>B1</b>	<u>38,672</u>	-1,991 (-4,9%)	-0,87 (-2,2%)	-0,817 (-2,07%)	-0,13 (-0,34%)	-0,564 (-1,44%)
<b>B2</b>	<u>38,630</u>	-2,032 (-5%)	-0,911 (-2,3%)	-0,859 (-2,18%)	-0,172 (-0,44%)	-0,606 (-1,54%)
<b>B3</b>	<u>39,053</u>	-1,61 (-3,96%)	-0,488 (-1,23%)	-0,436 (-1,1%)	0,251 (0,65%)	-0,183 (-0,47%)
<b>R1</b>	<u>40,384</u>	-0,278 (-0,68%)	0,843 (2,13%)	0,895 (2,27%)	1,582 (4,08%)	1,148 (2,93%)
<b>R2</b>	<u>39,769</u>	-0,893 (-2,2%)	0,228 (0,58%)	0,28 (0,71%)	0,968 (2,49%)	0,534 (1,36%)
<b>R3</b>	<u>38,809</u>	-1,854 (-4,56%)	-0,733 (-1,85%)	-0,68 (-1,72%)	0,007 (0,02%)	-0,427 (-1,09%)
<b>R4</b>	<u>39,933</u>	-0,729 (-1,79%)	0,392 (0,99%)	0,444 (1,12%)	1,131 (2,92%)	0,697 (1,78%)
<b>CPTEC</b>	<u>38,613</u>	-2,049 (-5,04%)	-0,928 (-2,35%)	-0,876 (-2,22%)	-0,189 (-0,49%)	-0,623 (-1,59%)
<b>ECMWF</b>	<u>34,893</u>	-5,769 (-14,19%)	-4,648 (-11,76%)	-4,596 (-11,64%)	-3,909 (-10,07%)	-4,343 (-11,07%)

Nota: percentuais positivos indicam piora na predição

**APÊNDICE E – Performance dos modelos por estação do ano**

**Tabela E1 – Performance dos modelos por estações do ano – Validação – Estação Maringá (02351013)**

Modelo	Verão					Outono				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>B1</b>	49,09	4735,72	68,82	-0,223	-0,223	32,30	1599,88	40,00	-0,064	-0,064
<b>B2</b>	49,10	4695,82	68,53	-0,212	-0,212	31,67	1570,49	39,63	-0,045	-0,045
<b>B3</b>	49,11	4667,80	68,32	-0,205	-0,205	31,77	1568,79	39,61	-0,043	-0,043
<b>R1</b>	48,38	4469,24	66,85	-0,154	-0,154	34,12	1770,59	42,08	-0,178	-0,178
<b>R2</b>	48,72	4664,09	68,29	-0,204	-0,204	33,13	1691,52	41,13	-0,125	-0,125
<b>R3</b>	49,27	4820,56	69,43	-0,245	-0,245	32,94	1693,97	41,16	-0,127	-0,127
<b>R4</b>	48,26	4574,83	67,64	-0,181	-0,181	33,17	1685,25	41,05	-0,121	-0,121
<b>H1</b>	47,96	4699,57	68,55	-0,213	-0,213	32,18	1598,90	39,99	-0,063	-0,063
<b>H2</b>	50,38	5489,46	74,09	-0,417	-0,417	34,41	1758,36	41,93	-0,170	-0,170
<b>H3</b>	46,41	4130,48	64,27	-0,066	-0,066	35,54	1939,54	44,04	-0,290	-0,290
<b>H4</b>	47,23	4695,30	68,52	-0,212	-0,212	33,32	1720,45	41,48	-0,144	-0,144
<b>H5</b>	49,33	4924,26	70,17	-0,271	-0,271	30,77	1531,50	39,13	-0,019	-0,019
<b>CPTEC</b>	47,11	4286,78	65,47	-0,099	-0,099	29,27	1631,22	40,39	-0,018	-0,018
<b>ECMWF</b>	41,90	3289,75	57,36	0,151	0,151	31,25	1676,30	40,94	-0,115	-0,115

Modelo	Inverno					Primavera				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>B1</b>	37,01	2429,70	49,29	-0,055	-0,055	36,21	2878,01	53,65	0,040	0,040
<b>B2</b>	36,52	2404,07	49,03	-0,044	-0,044	36,48	2838,47	53,28	0,053	0,053
<b>B3</b>	37,08	2430,84	49,30	-0,055	-0,055	36,66	2834,67	53,24	0,054	0,054
<b>R1</b>	39,83	2598,24	50,97	-0,128	-0,128	36,68	2882,52	53,69	0,038	0,038
<b>R2</b>	37,38	2458,53	49,58	-0,067	-0,067	37,36	2967,71	54,48	0,010	0,010
<b>R3</b>	37,52	2472,42	49,72	-0,073	-0,073	36,36	2937,63	54,20	0,020	0,020
<b>R4</b>	38,30	2492,88	49,93	-0,082	-0,082	36,49	2856,35	53,44	0,047	0,047
<b>H1</b>	37,55	2434,89	49,34	-0,057	-0,057	36,82	2898,64	53,84	0,033	0,033
<b>H2</b>	38,75	2565,77	50,65	-0,114	-0,114	42,22	3400,95	58,32	-0,135	-0,135
<b>H3</b>	42,14	2666,13	51,63	-0,158	-0,158	37,42	2853,90	53,42	0,048	0,048
<b>H4</b>	37,39	2391,48	48,90	-0,038	-0,038	37,01	2944,72	54,27	0,018	0,018
<b>H5</b>	35,28	2366,83	48,65	-0,028	-0,028	35,33	2907,01	53,92	0,030	0,030
<b>CPTEC</b>	26,91	2173,16	46,62	0,097	0,097	40,11	2756,79	52,51	0,093	0,093
<b>ECMWF</b>	26,23	1749,82	41,83	0,240	0,240	38,34	2887,51	53,74	0,037	0,037

**Tabela E2 – Performance dos modelos por estações do ano – Validação – Estação Colônia Vitória (02551008)**

Modelo	Verão					Outono				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>B1</b>	30,86	1640,33	40,50	-0,100	-0,100	41,02	2694,20	51,91	-0,054	-0,054
<b>B2</b>	29,73	1605,01	40,06	-0,077	-0,077	40,59	2618,20	51,17	-0,025	-0,025
<b>B3</b>	29,59	1558,99	39,48	-0,046	-0,046	41,31	2608,29	51,07	-0,021	-0,021
<b>R1</b>	31,65	1643,05	40,53	-0,102	-0,102	42,53	2901,11	53,86	-0,135	-0,135
<b>R2</b>	30,33	1602,62	40,03	-0,075	-0,075	42,83	2871,98	53,59	-0,124	-0,124
<b>R3</b>	30,99	1673,35	40,91	-0,123	-0,123	40,82	2807,34	52,98	-0,099	-0,099
<b>R4</b>	30,80	1579,53	39,74	-0,060	-0,060	42,36	2868,29	53,56	-0,123	-0,123
<b>H1</b>	32,69	1772,16	42,10	-0,189	-0,189	41,98	2769,80	52,63	-0,084	-0,084
<b>H2</b>	28,97	1476,70	38,43	0,009	0,009	41,68	2617,91	51,17	-0,025	-0,025
<b>H3</b>	30,58	1602,28	40,03	-0,075	-0,075	41,75	2838,25	53,28	-0,111	-0,111
<b>H4</b>	31,11	1660,31	40,75	-0,114	-0,114	40,51	2739,66	52,34	-0,072	-0,072
<b>H5</b>	32,22	1778,14	42,17	-0,193	-0,193	41,42	2764,63	52,58	-0,082	-0,082
<b>CPTEC</b>	34,83	1922,65	43,85	-0,165	-0,165	40,03	3395,01	58,27	-0,324	-0,324
<b>ECMWF</b>	37,54	2577,60	50,77	-0,729	-0,729	39,22	2971,07	54,51	-0,163	-0,163

Modelo	Inverno					Primavera				
	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE	MAE (mm)	MSE (mm <sup>2</sup> )	RMSE (mm)	R <sup>2</sup>	NSE
<b>B1</b>	41,22	2852,25	53,41	-0,004	-0,004	41,35	3296,11	57,41	-0,019	-0,019
<b>B2</b>	42,49	2954,84	54,36	-0,041	-0,041	41,40	3310,46	57,54	-0,024	-0,024
<b>B3</b>	43,10	2991,97	54,70	-0,054	-0,054	41,89	3241,64	56,94	-0,002	-0,002
<b>R1</b>	42,73	2963,88	54,44	-0,044	-0,044	44,41	3632,98	60,27	-0,123	-0,123
<b>R2</b>	42,39	2935,98	54,18	-0,034	-0,034	43,26	3515,05	59,29	-0,087	-0,087
<b>R3</b>	40,41	2851,37	53,40	-0,004	-0,004	42,86	3611,18	60,09	-0,117	-0,117
<b>R4</b>	42,47	2926,67	54,10	-0,031	-0,031	43,86	3534,91	59,46	-0,093	-0,093
<b>H1</b>	43,93	3285,74	57,32	-0,157	-0,157	43,82	3609,23	60,08	-0,116	-0,116
<b>H2</b>	44,63	3148,78	56,11	-0,109	-0,109	42,50	3266,04	57,15	-0,010	-0,010
<b>H3</b>	41,85	2892,41	53,78	-0,019	-0,019	43,55	3584,77	59,87	-0,108	-0,108
<b>H4</b>	40,62	2840,52	53,30	0,000	0,000	42,82	3613,80	60,11	-0,117	-0,117
<b>H5</b>	41,25	2926,08	54,09	-0,030	-0,030	41,86	3423,81	58,51	-0,059	-0,059
<b>CPTEC</b>	35,16	3200,24	56,57	-0,100	-0,100	44,16	3857,46	62,11	-0,271	-0,271
<b>ECMWF</b>	30,22	2387,35	48,86	0,159	0,159	32,64	2088,44	45,70	0,354	0,354

**ANEXOS**

## ANEXO A

## Métricas de performance de estudos semelhantes

## Convenções e notações utilizadas

- Notação para a variável prevista: P= Precipitação; Q= Vazão; T=Temperatura
- Notação para a escala de tempo: D=dias, S= semana; M=mês; A= ano
- Uso de modelos repetidos: Quando um modelo aparece mais de uma vez na mesma publicação, significa que ele foi aplicado em diferentes localidades.

Quadro A1 – Resumo das métricas de desempenho de modelos de previsão nos estudos identificados na revisão de forma sistemática

Autor	Variável	Escala	Modelo (RMSE; MAE; NSE; R <sup>2</sup> )
(Ali <i>et al.</i> , 2020)	P	M	Standalone RF (8.99; 6.24; ; 0.826), Standalone KRR (linear) (17.2; 10.68; ; 0.154), Standalone KRR (polinomial) (19.82; 12.91; ; 0.071), Standalone KRR (gausiana) (14.25; 9.95; ; 0.364), CEEMD-RF (3.86; 2.95; ; 0.974), CEEMD-RF-KRR (linear) (5.54; 4.04; ; 0.952), CEEMD-RF-KRR (polinomial) (2.52; 1.98; ; 0.986), CEEMD-RF-KRR (gausiana) (5.22; 3.43; ; 0.982), Standalone RF (60.7; 44.79; ; 0.858), Standalone KRR (linear) (124.3; 88.67; ; 0.273), Standalone KRR (polinomial) (222.07; 195.18; ; 0.216), Standalone KRR (gausiana) (99.43; 71.4; ; 0.372), CEEMD-RF (35.51; 25.03; ; 0.957), CEEMD-RF-KRR (linear) (55.67; 42.99; ; 0.883), CEEMD-RF-KRR (polinomial) (25.76; 19.99; ; 0.971), CEEMD-RF-KRR (gausiana) (37.28; 25.03; ; 0.978), Standalone RF (39.04; 29.08; ; 0.88), Standalone KRR (linear) (72.6; 51.88; ; 0.457), Standalone KRR (polinomial) (106.22; 82.72; ; 0.299), Standalone KRR (gausiana) (63.6; 47.34; ; 0.505), CEEMD-RF (22.22; 16.46; ; ), CEEMD-RF-KRR (linear) (51.6; 40.35; ; ), CEEMD-RF-KRR (polinomial) (16.58; 13.65; ; ), CEEMD-RF-KRR (gausiana) (22.94; ; )
(Chen <i>et al.</i> , 2023)	P	M	LSTM ( ; ; 0.813), LSSVM ( ; ; 0.633), CEEMD-LSTM ( ; ; 0.864), CEEMD-LSTM-LSSVM ( ; ; 0.932), LSTM (38.92; 22.46; ; ), LSSVM (38.92; 31.06; ; ), CEEMD-LSTM (23.66; 17.86; ; ), CEEMD-LSTM-LSSVM (16.77; 13.07; ; )
(Fang <i>et al.</i> , 2024)	Q	1D	MVMD-Transformer ( ; ; 0.986 ), VMD-Transformer ( ; ; 0.966 ), CEEMDAN-Transformer ( ; ; 0.966 ); Transformer ( ; ; 0.798 ), LSTM ( ; ; 0.511; )
(Garai <i>et al.</i> , 2024)	P	A	ARIMA (36.83; 31; ; ), GARCH (36.85; 31.02; ; ), ANN (30.73; 26.66; ; ), CEEMDAN_ANN (18.47; 15.34; ; ), SVR (35.22; 26.93; ; ), CEEMDAN_SVR (14.9; 13.01; ; ), RF (35.26; 29.11; ; ), CEEMDAN_RF (21.21; 18.71; ; ), KRR_Lk (52.05; 45.1; ; ), KRR_Pk (53.81; 46.61; ; ), KRR_Rk (49.93; 42.62; ; ), KRR_Sk (49.55; 42.54; ; ), CEEMDAN_KRR_RF_Lk (39.65; 33.38; ; ), CEEMDAN_KRR_RF_Pk (51.65; 44.57; ; ), CEEMDAN_KRR_RF_Rk (50.34; 43.19; ; ), CEEMDAN_KRR_RF_Sk (48.91; 41.82; ; ), ARIMA (59.29; 45.92; ; ), GARCH (64.32; 51.52; ; ), ANN (61.76; 48.06; ; ), CEEMDAN_ANN (43.99; 35.06; ; ), SVR (66.1; 52.68; ; ), CEEMDAN_SVR (43.15; 33.48; ; ), RF (62.68; 49.52; ; ), CEEMDAN_RF (40.21; 33.17; ; ), KRR_Lk (58.54; 51.81; ; ), KRR_Pk (49.12; 44.2; ; ), KRR_Rk (51.91; 42.86; ; ), KRR_Sk (54.32; 44.56; ; ), CEEMDAN_KRR_RF_Lk (65.2; 52.6; ; ), CEEMDAN_KRR_RF_Pk (52.06; 42.82; ; ), CEEMDAN_KRR_RF_Rk (53.14; 43.37; ; ), CEEMDAN_KRR_RF_Sk (54.32; 43.82; ; ), ARIMA (15.1; 12.75; ; ), GARCH (15.11; 12.76; ; ), ANN (15.46; 13.64; ; ), CEEMDAN_ANN (34.1; 33.45; ; ), SVR (12.94; 11.83; ; ), CEEMDAN_SVR (30.62; 29.88; ; ), RF (15.5; 14.33; ; ), CEEMDAN_RF (32.58; 31.77; ; ), KRR_Lk (12.8; 9.65; ; ), KRR_Pk (10.86; 7.88; ; ), KRR_Rk (11.26; 8.29; ; ), KRR_Sk (11.79; 8.65; ; ), CEEMDAN_KRR_RF_Lk (13.57; 10.28; ; ), CEEMDAN_KRR_RF_Pk (11.56; 8.36; ; ), CEEMDAN_KRR_RF_Rk (11.69; 8.53; ; ), CEEMDAN_KRR_RF_Sk (11.84; 8.7; ; ),
(Gu <i>et al.</i> , 2022)	P	M	KNN (68.72; 46.34; ; 0.407), XGB (61.57; 42.41; ; 0.526), SVR (61.65; 43.16; ; 0.523), ANN (60.92; 42.47; ; 0.532), Stack (61.51; 41.65; ; 0.526),
(Guo <i>et al.</i> , 2022)	P	A	LSTM ( ; ; 0.4837), EEMD-LSTM ( ; ; 0.5274), CEEMD-LSTM ( ; ; 0.7348), CEEMDAN-ARIMA ( ; ; 0.9424), CEEMDAN-RNN ( ; ; 0.9722), CEEMDAN-LSTM ( ; ; 0.9863), LSTM (80.36; ; ; ), EEMD-LSTM (74.62; ; ; ), CEEMD-LSTM (50.79; ; ; ), CEEMDAN-ARIMA (35.55; ; ; ), CEEMDAN-RNN (20.43; ; ; ), CEEMDAN-LSTM (17.37; ; ; )
(Guo <i>et al.</i> , 2023)	Q	1D	CEEMDAN-WT-LSTM ( ; ; 0.614; 0.721), CEEMDAN-WT-LSTM ( ; ; 0.889; 0.889), CEEMDAN-WT-LSTM ( ; ; 0.891; 0.891), CEEMDAN-WT-LSTM ( ; ; 0.76; 0.782), CEEMDAN-WT-LSTM ( ; ; 0.636; 0.789), CEEMDAN-WT-LSTM ( ; ; 0.91; 0.911), CEEMDAN-WT-LSTM ( ; ; 0.916; 0.919), CEEMDAN-WT-LSTM ( ; ; 0.824; 0.827), CEEMDAN-WT-LSTM ( ; ; 0.929; 0.93), CEEMDAN-WT-LSTM ( ; ; 0.744; 0.748), CEEMDAN-WT-LSTM ( ; ; 0.83; 0.832), CEEMDAN-WT-LSTM ( ; ; 0.929; 0.95), CEEMDAN-WT-LSTM ( ; ; 0.813; 0.815), CEEMDAN-WT-LSTM ( ; ; 0.679; 0.682), CEEMDAN-WT-LSTM ( ; ; 0.85; 0.853), CEEMDAN-WT-LSTM ( ; ; 0.874; 0.885), CEEMDAN-WT-LSTM ( ; ; 0.896; 0.904), CEEMDAN-WT-LSTM ( ; ; 0.791; 0.798), CEEMDAN-WT-LSTM ( ; ; 0.887; 0.89), CEEMDAN-WT-LSTM ( ; ; 0.749; 0.749), CEEMDAN-WT-LSTM ( ; ; 0.713; 0.76), CEEMDAN-WT-LSTM ( ; ; 0.677; 0.679), CEEMDAN-WT-LSTM ( ; ; 0.772; 0.788), CEEMDAN-WT-LSTM ( ; ; 0.811; 0.824), CEEMDAN-WT-LSTM ( ; ; 0.712; 0.715), CEEMDAN-WT-LSTM ( ; ; 0.772; 0.777), CEEMDAN-WT-LSTM ( ; ; 0.703; 0.703), CEEMDAN-

Autor	Variável	Escala	Modelo (RMSE; MAE; NSE; R <sup>2</sup> )
			WT-LSTM ( ; 0.658; 0.659), CEEMDAN-WT-LSTM ( ; 0.682; 0.683), CEEMDAN-WT-LSTM ( ; 0.618; 0.647), CEEMDAN-WT-LSTM ( ; 0.748; 0.749), CEEMDAN-WT-LSTM ( ; 0.524; 0.555), CEEMDAN-WT-LSTM ( ; 0.674; 0.678), CEEMDAN-WT-LSTM ( ; 0.25; 0.292), CEEMDAN-WT-LSTM ( ; 0.394; 0.407), CEEMDAN-WT-LSTM ( ; 0.499; 0.16), CEEMDAN-WT-LSTM ( ; 0.466; 0.496), CEEMDAN-WT-LSTM ( ; 0.379; 0.334), VMD-WT-LSTM ( ; 0.923; 0.925), VMD-WT-LSTM ( ; 0.985; 0.989), VMD-WT-LSTM ( ; 0.965; 0.966), VMD-WT-LSTM ( ; 0.977; 0.979), VMD-WT-LSTM ( ; 0.973; 0.975), VMD-WT-LSTM ( ; 0.969; 0.969), VMD-WT-LSTM ( ; 0.973; 0.975), VMD-WT-LSTM ( ; 0.939; 0.942), VMD-WT-LSTM ( ; 0.976; 0.979), VMD-WT-LSTM ( ; 0.958; 0.961), VMD-WT-LSTM ( ; 0.952; 0.955), VMD-WT-LSTM ( ; 0.969; 0.972), VMD-WT-LSTM ( ; 0.937; 0.94), VMD-WT-LSTM ( ; 0.919; 0.925), VMD-WT-LSTM ( ; 0.955; 0.958), VMD-WT-LSTM ( ; 0.966; 0.969), VMD-WT-LSTM ( ; 0.958; 0.962), VMD-WT-LSTM ( ; 0.927; 0.928), VMD-WT-LSTM ( ; 0.914; 0.916), VMD-WT-LSTM ( ; 0.904; 0.918), VMD-WT-LSTM ( ; 0.901; 0.914), VMD-WT-LSTM ( ; 0.889; 0.897), VMD-WT-LSTM ( ; 0.789; 0.801), VMD-WT-LSTM ( ; 0.782; 0.785), VMD-WT-LSTM ( ; 0.815; 0.816), VMD-WT-LSTM ( ; 0.866; 0.87), VMD-WT-LSTM ( ; 0.701; 0.751), VMD-WT-LSTM ( ; 0.797; 0.803), VMD-WT-LSTM ( ; 0.74; 0.743), VMD-WT-LSTM ( ; 0.598; 0.665), VMD-WT-LSTM ( ; 0.74; 0.741), VMD-WT-LSTM ( ; 0.623; 0.631), VMD-WT-LSTM ( ; 0.447; 0.458), VMD-WT-LSTM ( ; 0.05; 0.282), VMD-WT-LSTM ( ; 0.395; 0.411), VMD-WT-LSTM ( ; 0.115; 0.191), VMD-WT-LSTM ( ; 0.093; 0.334), VMD-WT-LSTM ( ; -0.296; 0.451), LMD-WT-LSTM ( ; 0.608; 0.609), LMD-WT-LSTM ( ; 0.613; 0.64), LMD-WT-LSTM ( ; 0.661; 0.686), LMD-WT-LSTM ( ; 0.503; 0.533), LMD-WT-LSTM ( ; 0.807; 0.808), LMD-WT-LSTM ( ; 0.815; 0.815), LMD-WT-LSTM ( ; 0.664; 0.666), LMD-WT-LSTM ( ; 0.702; 0.703), LMD-WT-LSTM ( ; 0.778; 0.93), LMD-WT-LSTM ( ; 0.46; 0.474), LMD-WT-LSTM ( ; 0.681; 0.686), LMD-WT-LSTM ( ; 0.315; 0.85), LMD-WT-LSTM ( ; 0.638; 0.644), LMD-WT-LSTM ( ; -0.064; 0.347), LMD-WT-LSTM ( ; 0.713; 0.725), LMD-WT-LSTM ( ; 0.729; 0.731), LMD-WT-LSTM ( ; 0.822; 0.825), LMD-WT-LSTM ( ; 0.756; 0.757), LMD-WT-LSTM ( ; 0.792; 0.793), LMD-WT-LSTM ( ; 0.506; 0.545), LMD-WT-LSTM ( ; 0.433; 0.461), LMD-WT-LSTM ( ; 0.299; 0.451), LMD-WT-LSTM ( ; 0.357; 0.554), LMD-WT-LSTM ( ; 0.665; 0.682), LMD-WT-LSTM ( ; 0.555; 0.557), LMD-WT-LSTM ( ; 0.682; 0.683), LMD-WT-LSTM ( ; 0.707; 0.719), LMD-WT-LSTM ( ; -0.169; 0.3), LMD-WT-LSTM ( ; -0.775; 0.175), LMD-WT-LSTM ( ; 0.621; 0.632), LMD-WT-LSTM ( ; 0.669; 0.692), LMD-WT-LSTM ( ; 0.512; 0.526), LMD-WT-LSTM ( ; 0.507; 0.526), LMD-WT-LSTM ( ; 0.353; 0.386), LMD-WT-LSTM ( ; 0.41; 0.43), LMD-WT-LSTM ( ; -0.32; 0.191), LMD-WT-LSTM ( ; 0.431; 0.451), LMD-WT-LSTM ( ; 0.278; 0.371)
(Jiang, 2023)	P	M	LSTM (77.92; 59.17; ;), ANN (108.08; 80.79; ;), SVM (79.08; 60.96; ;), BPNN (81.9; 62.19; ;), EMD-LSTM (60.76; 45.84; ;), EEMD-LSTM (54.43; 43.4; ;), CEEMD-LSTM (52.39; 42.99; ;), PSO-LSTM (65.59; 49.95; ;), CEEMD-PSO-LSTM (49.02; 39.39; ;)
(Jiao; He, 2024)	P	7D	PSO-BiLSTM (10.94; 6.3; 0.45; ;), IPSO-BiLSTM (10.3; 6.13; 0.59; ;), VMD-PSO-BiLSTM (9.54; 5.32; 0.73; ;), VMD-IPSO-BiLSTM (6.63; 3.44; 0.88; ;), PSO-BiLSTM (11.37; 7.27; 0.5; ;), IPSO-BiLSTM (9.66; 6.32; 0.62; ;), VMD-PSO-BiLSTM (8.91; 5.88; 0.75; ;), VMD-IPSO-BiLSTM (6.36; 3.43; 0.9; ;), PSO-BiLSTM (12.99; 7.65; 0.43; ;), IPSO-BiLSTM (11.81; 6.97; 0.6; ;), VMD-PSO-BiLSTM (9.72; 6.88; 0.77; ;), VMD-IPSO-BiLSTM (6.98; 5.12; 0.89; ;), PSO-BiLSTM (12.23; 7.57; 0.48; ;), IPSO-BiLSTM (11.91; 6.76; 0.58; ;), VMD-PSO-BiLSTM (9.1; 5.93; 0.75; ;), VMD-IPSO-BiLSTM (3.94; 0.91; ;)
(Johny; Pai; Adarsh, 2020)	P	4M	EEMD(Hindcast)-ANN ( ; 174.86; ;), EEMD(Forecast)-ANN ( ; 256.23; ;), AEEMD-ANN ( ; 260.53; ;), EEMD(Hindcast)-ANN ( ; 51.35; ;), EEMD(Forecast)-ANN ( ; 39.46; ;), AEEMD-ANN ( ; 34.28; ;),
(Jyostna <i>et al.</i> , 2025)	P	M	SARIMA (230.87; ; ;), GARCH (229.35; ; ;), ANN (192.22; ; ;), LSTM (172.57; ; ;), EEMD-SARIMA (199.03; ; ;), EEMD-GARCH (195.2; ; ;), EEMD-ANN (165.37; ; ;), EEMD-LSTM (136.23; ; ;), SARIMA (136.4; ; ;), GARCH (128.79; ; ;), ANN (126.91; ; ;), LSTM (124.7; ; ;), EEMD-SARIMA (125.03; ; ;), EEMD-GARCH (124.35; ; ;), EEMD-ANN (121.15; ; ;), EEMD-LSTM (113.41; ; ;), SARIMA (54.64; ; ;), GARCH (53.48; ; ;), ANN (40.76; ; ;), LSTM (38.89; ; ;), EEMD-SARIMA (38.45; ; ;), EEMD-GARCH (28.1; ; ;), EEMD-ANN (23.89; ; ;), EEMD-LSTM (17.68; ; ;), SARIMA (147.19; ; ;), GARCH (138.07; ; ;), ANN (118.82; ; ;), LSTM (115.25; ; ;), EEMD-SARIMA (145.7; ; ;), EEMD-GARCH (137.52; ; ;), EEMD-ANN (112.13; ; ;), EEMD-LSTM (102.95; ; ;)
(Khairudin <i>et al.</i> , 2024)	Q (NA)	M	BPNN (1.3748; 1.0502; -6.4678; ;), ELM (1.1428; 0.8365; -0.6184; ;), Ensemble Neural Networks (1.0817; 0.7498; -1.6688; ;)
(Li <i>et al.</i> , 2019)	Q	10D	EMD-ANN (183.78; 153.98; 0.406; ;), EMD-ANN (190.73; 144.27; 0.675; ;), EMD-ANN (588.44; 358.72; 0.652; ;), EMD-ANN (290.77; 152.83; 0.676; ;), EEMD-ANN (118.47; 97.33; 0.753; ;), EEMD-ANN (175.63; 136.99; 0.724; ;), EEMD-ANN (422.56; 285.8; 0.821; ;), EEMD-ANN (282.49; 208.55; 0.694; ;), STL-ANN (107.86; 94.88; 0.795; ;), STL-ANN (157.02; 120.25; 0.78; ;), STL-ANN (475.2; 258.24; 0.773; ;), STL-ANN (188.38; 103.8; 0.864; ;)
(Li <i>et al.</i> , 2019)	Q	M	EMD-ANN (160.31; 138.85; 0.763; ;), EMD-ANN (142.77; 117.49; 0.941; ;), EMD-ANN (435.36; 301.83; 0.827; ;), EMD-ANN (242.89; 149.19; 0.786; ;), EEMD-ANN (116.21; 96.62; 0.875; ;), EEMD-ANN (141.46; 102.69; 0.942; ;), EEMD-ANN (324.54; 221.19; 0.904; ;), EEMD-ANN (207.3; 155.43; 0.844; ;), STL-ANN (93.82; 84.85; 0.919; ;), STL-ANN (110.87; 91.95; 0.964; ;), STL-ANN (386.35; 187.9; 0.864; ;), STL-ANN (152.84; 94.35; 0.915; ;)
(Li; Ma; Yang, 2018)	P	M	BPNN (49.7006; 33.0841; ;), ENN (47.2576; 32.7371; ;), ELM (43.6451; 30.5377; ;), EMD-ELM (32.7755; 24.4135; ;), VMD-ELM (20.3605; 15.2966; ;), BPNN (50.876; 37.4068; ;), ENN (49.2296; 35.3464; ;), ELM (48.6962; 34.2236; ;), EMD-ELM (38.2472; 29.3452; ;), VMD-ELM (16.7612; 13.5179; ;)

Autor	Variável	Escala	Modelo (RMSE; MAE; NSE; R <sup>2</sup> )
(Li; Wang; Qiu, 2019)	Q	10D	DWT-ANN (254.93; ; 0.651; ), EMD-ANN (183.78; ; 0.406; ), EEMD-ANN (118.47; ; 0.753; )
(Liu, F. P. <i>et al.</i> , 2022)	P	A	CEEMDAN-BPNN ( ; ; 0.9922), CEEMDAN-GA-BPNN ( ; ; 0.99995), CEEMDAN-PSO-BPNN ( ; ; 0.99995), CEEMDAN-WOA-BPNN ( ; ; 0.99995), CEEMDAN-IWOA-BPNN ( ; ; 0.99996), CEEMDAN-BPNN (38.445; ; ; ), CEEMDAN-GA-BPNN (2.337; ; ; ), CEEMDAN-PSO-BPNN (2.625; ; ; ), CEEMDAN-WOA-BPNN (2.432; ; ; ), CEEMDAN-IWOA-BPNN (2.061; ; ; )
(Ouyang <i>et al.</i> , 2016)	P	M	EEMD-SVR ( ; 0.83; ), EEMD-ANN ( ; -0.01; ), EEMD-ARIMA ( ; 0.62; ), SVR ( ; 0.69; )
(Parisouj <i>et al.</i> , 2023)	Q	A	SVR (13.62; ; ; ), ANN-BPNN (17.3; ; ; ), CNN (12.33; ; ; ), Ensemble (11.43; ; ; ), SVR (196.04; ; ; ), ANN-BPNN (298.07; ; ; ), CNN (232.46; ; ; ), Ensemble (187.45; ; ; ), SVR (15.19; ; ; ), CNN (21.98; ; ; ), Ensemble (11.94; ; ; ), SVR (0.34; ; ; ), ANN-BPNN (-0.06; ; ; ), CNN (0.46; ; ; ), Ensemble (0.54; ; ; ), SVR (0.5; ; ; ), ANN-BPNN (-0.17; ; ; ), CNN (0.6; ; ; ), Ensemble (0.54; ; ; ), SVR (0.72; ; ; ), ANN-BPNN (-0.35; ; ; ), CNN (0.11; ; ; ), Ensemble (0.43; ; ; )
(Parisouj <i>et al.</i> , 2023)	Q	M	ANN-BPNN (54.76; ; ; ), CNN (43.23; ; ; ), Ensemble (36.27; ; ; ), SVR (543.86; ; ; ), ANN-BPNN (398.2; ; ; ), CNN (490.7; ; ; ), Ensemble (329.46; ; ; ), SVR (84.31; ; ; ), ANN-BPNN (111.97; ; ; ), CNN (79.03; ; ; ), Ensemble (34.29; ; ; ), ANN-BPNN (-0.36; ; ; ), CNN (0.26; ; ; ), Ensemble (0.45; ; ; ), SVR (-0.53; ; ; ), ANN-BPNN (0.28; ; ; ), CNN (0.25; ; ; ), Ensemble (0.44; ; ; ), SVR (0.59; ; ; ), ANN-BPNN (-0.2; ; ; ), CNN (0.68; ; ; ), Ensemble (0.5; ; ; )
(Parviz; Ghorbanpour, 2024)	P	M	Híbrido (1.66; 1.33; ; ), Híbrido-EMD (1.16; 0.78; ; ), Híbrido (0.9; 0.825; ; ), Híbrido-EMD (0.43; 0.38; ; ), Híbrido (0.91; 0.78; ; ), Híbrido-EMD (0.53; 0.36; ; ), Híbrido (5.07; 3.41; ; ), Híbrido-EMD (4.17; 2.4; ; ), Híbrido (7.46; 3.21; ; ), Híbrido-EMD (2.19; 1.21; ; ), Híbrido (1.531; 0.76; ; ), Híbrido-EMD (1.003; 0.3; ; ), Híbrido (0.88; 0.73; ; ), Híbrido-EMD (0.48; 0.38; ; ), Híbrido (0.981; 1.09; ; ), Híbrido-EMD (0.483; 0.38; ; ), Híbrido (5.7; 5.4; ; ), Híbrido-EMD (4.2; 3.7; ; ), Híbrido (7.18; 3.8; ; ), Híbrido-EMD (1.58; 1.23; ; )
(Parviz; Rasouli; Haghighi, 2023)	P	M	SARIMA+ SVR (20.02; ; 0.92; ), SARIMA+GEP (30.51; ; 0.82; ), SARIMA + GMDH (24.22; ; 0.89; ), lv + SSE (15.92; ; 0.95; ), MSEI+SSE (17.2; ; 0.94; ), lv + SMAPE (16.52; ; 0.95; ), MSEI + SMAPE (18.08; ; 0.94; ), SVR (13.03; ; 0.96; ), GA (11.48; ; 0.97; ), LSR (14.37; ; 0.96; ), ANN (17.7; ; 0.94; )
(Parviz; Rasouli; Haghighi, 2023)	P	A	ARIMA+SVR (11.88; ; 0.94; ), ARIMA + GEP (17.59; ; 0.87; ), ARIMA + GMDH (9.87; ; 0.95; ), lv + SSE (8.81; ; 0.96; ), MSEI+SSE (7.36; ; 0.97; ), lv+ SMAPE (7.73; ; 0.97; ), MSEI + SMAPE (8.91; ; 0.96; ), SVR (5.57; ; 0.98; ), GA (9.39; ; 0.96; ), LSR (9.01; ; 0.96; ), ANN (7.64; ; 0.97; )
(Peng <i>et al.</i> , 2021)	P	1D	MLP (17.22; 13.74; ; ), RNN (14.64; 11.53; ; ), GRU (13.7; 10.91; ; ), ConvGRU (13.4; 10.66; ; ), CEEMDAN-ConvGRU (9.7; 7.61; ; )
(Shen; Ban, 2023)	P	M	LSTM (21.5; 14.13; ; 0.6), ARIMA (21.69; 14.29; ; 0.59), BPNN (22.17; 14.31; ; 0.57), SCM (21; 12.69; ; 0.54), CEEMDAN-LSTM (18.09; 12.43; ; 0.71), CEEMDAN-SVM (19.07; 14.21; ; 0.68)
(Sibtain; Li; Saleem, 2020)	Q	M	RBF (57.504; 39.52; 0.841; ), SVR (47.482; 30.748; 0.892; ), RFR (43.588; 28.692; 0.909; ), GRU (37.813; 25.464; 0.931; ), LSTM (35.091; 23.252; 0.941; ), ICEEMDAN-LSTM (22.162; 15.502; 0.976; ), VMD-LSTM (17.478; 11.579; 0.985; ), IVL-ICEEMDAN-VMD-LSTM (12.553; 7.083; 0.992; )
(Song <i>et al.</i> , 2021)	P	1D	TVF-EMD-ENN (5.97; 3.93; 0.8; ), WT-ENN (3.54; 2.59; 0.78; ), CEEMD-ENN (3.73; 2.36; 0.43; ), TVF-EMD-ENN (7.68; 5.54; 0.93; ), WT-ENN (2.83; 2.94; 0.86; ), CEEMD-ENN (4.05; 3.93; 0.5; ), TVF-EMD-ENN (0.76; 0.91; 0.88; ), WT-ENN (1.25; 0.81; 0.74; ), CEEMD-ENN (1.1; 0.77; 0.66; ), TVF-EMD-ENN (0.07; 0.06; 0.86; ), WT-ENN (0.13; 0.07; 0.76; ), CEEMD-ENN (0.11; 0.06; 0.55; ), TVF-EMD-ENN (1.54; 1.13; 0.9; ), WT-ENN (1.1; 0.67; 0.76; ), CEEMD-ENN (0.72; 0.56; 0.53; ), TVF-EMD-ENN (2.02; 1.01; 0.88; ), WT-ENN (1.39; 0.68; 0.8; ), CEEMD-ENN (1.06; 0.6; 0.58; )
(Song; Chen, 2021)	P	A	CEEMD-ENN (411.89; 306.26; ; 0.7), EEMD-ENN (581.6; 519.9; ; 0.7), EMD-ENN (1276; 1076; ; 0.06), ENN (1120; 1012; ; 0.6), ESMD-ENN (273.88; 217.12; ; 0.64), LSTM (631.4; 546.5; ; 0.16), RBFNN (967.1; 893.9; ; 0.06), REMD-ENN (250.85; 197.42; ; 0.7), TVF-EMD-ENN (96.48; 86.58; ; 0.93), WT-ENN (276.42; 246.5; ; 0.82)
(Tayyab <i>et al.</i> , 2018)	Q	M	BPNN (0.59; ; ; ), BPNN (0.62; ; ; ), RBF (0.64; ; ; ), RBF (0.67; ; ; ), DWT-BPNN (0.7; ; ; ), DWT-BPNN (0.73; ; ; ), DWT-RBF (0.71; ; ; ), DWT-RBF (0.76; ; ; ), EEMD-BPNN (0.78; ; ; ), EEMD-BPNN (0.81; ; ; ), EEMD-RBF (0.83; ; ; ), EEMD-RBF (0.85; ; ; ), BPNN (0.67; ; ; ), RBF (0.65; ; ; ), RBF (0.69; ; ; ), DWT-BPNN (0.71; ; ; ), DWT-BPNN (0.72; ; ; ), DWT-RBF (0.73; ; ; ), DWT-RBF (0.75; ; ; ), EEMD-BPNN (0.79; ; ; ), EEMD-BPNN (0.81; ; ; ), EEMD-RBF (0.84; ; ; ), EEMD-RBF (0.86; ; ; ), BPNN (0.64; ; ; ), RBF (0.66; ; ; ), RBF (0.69; ; ; ), DWT-BPNN (0.73; ; ; ), DWT-BPNN (0.77; ; ; ), DWT-RBF (0.78; ; ; ), DWT-RBF (0.81; ; ; ), EEMD-BPNN (0.79; ; ; ), EEMD-BPNN (0.83; ; ; ), EEMD-RBF (0.85; ; ; ), EEMD-RBF (0.87; ; ; )
(Tebong <i>et al.</i> , 2023)	Q	1D	Dense ( ; 0.987; ), Conv1D ( ; 0.986; ), LSTM ( ; 0.986; ), Multivariate dense ( ; 0.987; ), Multivariate Conv1D ( ; 0.986; ), Multivariate LSTM ( ; 0.987; ), STL-Dense ( ; 0.988; ), STL-Conv1D ( ; 0.986; ), STL-LSTM ( ; 0.986; ), STL-Dense-LSTM-Conv1D ( ; 0.987; ), STL-LSTM multivariate ( ; 0.987; ), STL-Conv1D multivariate ( ; 0.987; ), STL-Dense multivariate model ( ; 0.988; )

Autor	Variável	Escala	Modelo (RMSE; MAE; NSE; R <sup>2</sup> )
(Wang <i>et al.</i> , 2021)	P	M	ARIMA (46.474; 27.792; 0.191; ), WPD-ARIMA (8.224; 6.06; 0.975; ), BPNN (45.775; 29.204; 0.215; ), WPD-BPNN (4.054; 2.912; 0.994; ), GMDH (41.844; 24.575; 0.344; ), WPD-GMDH (13.734; 11.171; 0.929; ), ARIMA (53.689; 31.856; 0.263; ), WPD-ARIMA (7.97; 6.415; 0.984; ), BPNN (50.37; 31.846; 0.352; ), WPD-BPNN (3.705; 2.889; 0.996; ), GMDH (48.271; 30.439; 0.405; )
(Wen <i>et al.</i> , 2019)	Q	M	CEEMDAN-VMD-ELM (9.209; 6.679; 0.961; ), ELM (18.002; 12.403; 0.851; ), ARIMA (46.593; 36.413; -0.005; )
(Xu <i>et al.</i> , 2016)	Q	A	Híbrido ( ; ; ; 0.9747), BPNN ( ; ; ; 0.4037)
(Yuan <i>et al.</i> , 2021)	Q	1D	RBF ( ; ; 0.91; ), EEMD-RBF ( ; ; 0.98; ), LSTM ( ; ; 0.91; ), EEMD-LSTM ( ; ; 0.98; ), GM-EEMD-LSTM ( ; ; 0.97; )
(Zhang <i>et al.</i> , 2018)	T	1D	RNN (1.7963; 1.3431; 0.9549; ), LSTM (1.8044; 1.3521; 0.9545; ), EMD-RNN (1.3045; 0.9572; 0.9762; ), EMD-LSTM (1.3938; 1.003; 0.9728; ), EEMD-RNN (0.7601; 0.5603; 0.9919; ), EEMD-LSTM (0.7098; 0.5336; 0.993; ), RNN (1.8944; 1.4234; 0.946; ), LSTM (1.8734; 1.4156; 0.9472; ), EMD-RNN (1.0209; 0.7668; 0.9843; ), EMD-LSTM (1.0683; 0.8114; 0.9828; ), EEMD-RNN (0.7564; 0.5494; 0.9914; ), EEMD-LSTM (0.683; 0.4873; 0.993; )
(Zhang <i>et al.</i> , 2023a)	P	M	ICEEMDAN-ESN ( ; ; 0.7; ), ICEEMDAN-BILSTM ( ; ; 0.73; ), ICEEMDAN-WSD-BILSTM/ESD ( ; ; 0.91; )
(Zhang <i>et al.</i> , 2023b)	P	M	CEEMD-LSTM ( ; 7.93; 0.75; ), CEEMD-BILSTM ( ; 6.04; 0.78; ), CEEMDAN-BILSTM ( ; 3.52; 0.76; ), CEEMDAN-VMD-BILSTM ( ; 1.32; 0.92; ),
(Zhang, X. <i>et al.</i> , 2021)	P	M	CEEMD-LSTM (0.153; ; 0.95; ), CEEMD-BPNN (0.581; ; 0.9; ), LSTM (0.967; ; 0.83; ), BPNN (0.998; ; 0.78; )
(Zhang; Zheng; Wu, 2020)	P	A	CWE (81.28; 71.5; ; ), CEEMD-ENN (84.54; 76.18; ; ), EEMD-ENN (106.48; 87.54; ; ), EMD-ENN (112.69; 89.72; ; ), ENN (154.59; 135.18; ; )
(Zhao, J. <i>et al.</i> , 2023)	P	M	CEEMDAN-GRU-Transformer (6.25; 4.7708; ; 0.8628), CEEMDAN-GRU (10.59; 7.766; ; 0.7765), EEMD-GRU-Transformer (13.11; 9.3211; ; 0.7321), CEEMDAN-Transformer (16.11; 11.76; ; 0.6608), CEEMDAN-LSTM (18.502; 13.56; ; 0.6085)
(Zhao; Nie; Wen, 2023)	P	M	LSTM ( ; ; 0.49072), ARIMA ( ; ; 0.412), EEMD-LSTM ( ; ; 0.76066), EEMD-LSTM-ARIMA ( ; ; 0.87221), LSTM (42.41; ; ; ), ARIMA (48.88; ; ; ), EEMD-LSTM (21.28; ; ; ), EEMD-LSTM-ARIMA (11.27; ; ; )