

# UFPA

PPGEC

Universidade Federal  
do Pará



Amanda de Cássia Lobato Soares

**TENDÊNCIA DE VAZÕES  
MODELADAS VIA APRENDIZADO DE  
MÁQUINA E MUDANÇAS CLIMÁTICAS  
DE BACIA HIDROGRÁFICA DA  
AMAZÔNIA**

**DISSERTAÇÃO DE MESTRADO**

Instituto de Tecnologia  
Programa de Pós-Graduação em Engenharia Civil

Orientador Prof. Claudio José Cavalcante Blanco, PhD

Belém – Pará – Brasil

2025

Amanda de Cássia Lobato Soares

**TENDÊNCIA DE VAZÕES MODELADAS VIA APRENDIZADO DE MÁQUINA E  
MUDANÇAS CLIMÁTICAS DE BACIA HIDROGRÁFICA DA AMAZÔNIA**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Civil, da Universidade Federal do Pará, como requisito para obtenção do Título de Mestre em Engenharia Civil.

Área de concentração: Engenharia Hídrica.

Orientador: Professor Claudio José Cavalcante Blanco, Ph.D.

Belém – Pará – Brasil

2025



## TENDÊNCIA DE VAZÕES MODELADAS VIA APRENDIZADO DE MÁQUINA E MUDANÇAS CLIMÁTICAS DE BACIA HIDROGRÁFICA DA AMAZÔNICA

AUTORA:

**AMANDA DE CÁSSIA LOBATO SOARES**

DISSERTAÇÃO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL DO INSTITUTO DE TECNOLOGIA DA UNIVERSIDADE FEDERAL DO PARÁ, COMO REQUISITO PARA OBTENÇÃO DO GRAU DE MESTRA EM ENGENHARIA CIVIL NA ÁREA DE RECURSOS HÍDRICOS E SANEAMENTO AMBIENTAL.

APROVADO EM: 07 / 03 / 2025.

BANCA EXAMINADORA:



Documento assinado digitalmente

**CLAUDIO JOSE CAVALCANTE BLANCO**

Data: 10/03/2025 09:37:18-0300

Verifique em <https://validar.iti.gov.br>

Prof. Claudio José Cavalcante Blanco, Ph.D.  
Orientador



Documento assinado digitalmente

**AUGUSTO CESAR DE MENDONÇA BRASIL**

Data: 10/03/2025 13:01:15-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Augusto César Mendonça Brasil  
Membro Externo (UnB)



Documento assinado digitalmente

**JOSIAS DA SILVA CRUZ**

Data: 10/03/2025 09:45:28-0300

Verifique em <https://validar.iti.gov.br>

Eng. Dr. Josias da Silva Cruz  
Membro Externo (UFPA)



Documento assinado digitalmente

**MARIANE FURTADO GONCALVES**

Data: 10/03/2025 10:03:43-0300

Verifique em <https://validar.iti.gov.br>

Profa. Dra. Mariane Furtado Gonçalves  
Membro Interno (UFPA)

Visto:

Prof. Dr. Dênio Ramam Carvalho de Oliveira  
Coordenador do PPGEC / ITEC / UFPA

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo  
com ISBD Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados**

---

S676t Soares, Amanda de Cássia Lobato.  
Tendência de Vazões Modeladas via Aprendizado de  
Máquina e Mudanças Climáticas de Bacia Hidrográfica da  
Amazônia / Amanda de Cássia Lobato Soares. — 2025.  
100 f. : il. color.

Orientador(a): Prof. Dr. Claudio José Cavalcante Blanco  
Dissertação (Mestrado) - Universidade Federal do Pará, Instituto  
de Tecnologia, Programa de Pós-Graduação em Engenharia  
Civil, Belém, 2025.

1. GCM GFDL-ESM4. 2. Rede Neural Recorrente. 3.  
NARX. 4. NEX-GDDP-CMIP6. I. Título.

CDD 333.91

---

## **AGRADECIMENTOS**

Aos meus pais, avôs, irmão e tia, obrigada pelo amor, criação e lar.

Aos meus colegas de graduação e ensino médio.

À Universidade Federal do Pará e aos membros do Laboratório de Engenharia Hídrica e Mudanças Climáticas (LEHMC), pela resistência e contribuição no avanço da ciência do país.

Ao prof. Claudio José Cavalcante Blanco, PhD, pelo incentivo e suporte à pesquisa. Seu profissionalismo será uma eterna inspiração para mim.

“A história da sociedade até aos nossos dias é a história da luta de classes.” (Karl Marx)

## RESUMO

O objetivo deste estudo é analisar a tendência das vazões modeladas via aprendizado de máquina e sob influência das mudanças climáticas de uma bacia hidrográfica localizada na Amazônia, visando identificar possíveis modificações no regime hidrológico em resposta aos cenários climáticos projetados do CMIP6. A vazão foi simulada utilizando uma Rede Neural Recorrente Não-Linear Autorregressiva com Entradas Exógenas (RNN-NARX). A análise de tendências foi realizada utilizando o teste Mann-Kendall (MK), o estimador Sen's Slope e o coeficiente de variância aplicado às vazões médias anuais de longo prazo. A precipitação observada foi obtida do banco de dados da ANA (Agência Nacional de Águas e Saneamento Básico). A precipitação projetada futura foi obtida do modelo GCM-GFDL-ESM4, sob os cenários climáticos: SSP2-4.5 (médias emissões) e SSP5-8.5 (altas emissões). As vazões máximas simuladas pela RNN-NARX no período de referência foram subestimadas. Essa subestimação ocorreu devido ao viés inerente ao GCM utilizado. Assim, o método EQM (Empirical Quantile Mapping) foi aplicado para corrigir o viés entre as vazões simuladas e observadas no período de referência. Após a correção, o desempenho geral das simulações foi classificado como confiável, bom e excelente, com FIT ( $\sim 0,9$ ) e KGE (0,74-0,75) em ambos os cenários, refletindo uma boa aderência às vazões observadas. A correção de viés também foi aplicada à simulação das vazões de longo prazo (2022 a 2100), considerando os dois cenários supramencionados, permitindo a análise de tendências das vazões resultantes. Os resultados do teste MK ( $Z = -0,57$ ;  $p\text{-valor}=0,569$ ), com um estimador de Sen's Slope ( $\beta = -0,07704$ ), não indicaram uma tendência significativa nas vazões, para o cenário SSP2-4.5. Em contraste, no cenário SSP5-8.5, foi detectada uma tendência decrescente significativa, com os resultados do teste MK ( $Z=-2,59$ ;  $p\text{-valor}=0,00968$ ) e com um estimador de Sen's Slope ( $\beta = -0,27110$ ). O que aponta para uma redução nas vazões médias anuais. Em ambos os cenários, o coeficiente de variância demonstrou uma variabilidade moderada de ( $CV = 22,11\%$  no SSP2-4.5; e  $CV = 21,76\%$  no SSP5-8.5). Porém, no cenário de altas emissões, essa variabilidade está inserida em um contexto de declínio na disponibilidade hídrica da sub-bacia hidrográfica do Rio Guamá.

**Palavras-chave:** GCM GFDL-ESM4, Rede Neural Recorrente, NARX, NEX-GDDP-CMIP6.

## ABSTRACT

The objective of this study is to analyze the trend of modeled streamflow via machine learning and under the influence of climate change in a river basin located in the Amazon, aiming to identify possible changes in the hydrological regime in response to the projected climate scenarios of CMIP6. The streamflow rate was simulated using a Nonlinear Autoregressive Recurrent Neural Network with Exogenous Inputs (RNN-NARX). Trend analysis was performed using the Mann-Kendall (MK) test, the Sen's Slope estimator and the coefficient of variance applied to the long-term mean annual flows. The observed precipitation was obtained from the ANA (National Water and Sanitation Agency) database. The projected future precipitation was obtained from the GCM-GFDL-ESM4 model, under the climate scenarios: SSP2-4.5 (medium emissions) and SSP5-8.5 (high emissions). The maximum streamflow simulated by RNN-NARX in the reference period were underestimated. This underestimation occurred due to the inherent bias of the GCM used. Thus, the EQM (Empirical Quantile Mapping) method was applied to correct the bias between the simulated and observed streamflow in the reference period. After corrections, the overall performance of the simulations was classified as reliable, good and excellent, with FIT ( $\sim 0.9$ ) and KGE (0.74-0.75) in both scenarios, reflecting a good adherence to the observed streamflow. Bias correction was also applied to the long-term streamflow simulation (2022 to 2100), considering the two scenarios, allowing the analysis of trends in the resulting flows. The results of the MK test ( $Z = -0.57$ ;  $p\text{-value} = 0.569$ ), with Sen's Slope estimator ( $\beta = -0.07704$ ), did not indicate a significant trend, for the SSP2-4.5 scenario. In contrast, in the SSP5-8.5 scenario, a significant decreasing trend was detected, with the results of the MK test ( $Z = -2.59$ ;  $p\text{-value} = 0.00968$ ) and with Sen's Slope estimator ( $\beta = -0.27110$ ), demonstrating a reduction in the mean annual streamflow. In both scenarios, the coefficient of variance demonstrated moderate variability (CV = 22.11% in SSP2-4.5; and CV = 21.76% in SSP5-8.5). However, in the high emissions scenario, this variability is inserted in a context of declining water availability in the Guamá River sub-basin.

**Keywords:** GCM GFDL-ESM4, Neural Recurrent Network, NARX, NEX-GDDP-CMIP6.

## LISTA DE FIGURAS

Figura 1: Principais fluxos e armazenamentos.....	17
Figura 2: Vazão diária média de longo prazo na saída das principais bacias hidrográficas do mundo.....	18
Figura 3: Regiões hidrográficas brasileiras .....	20
Figura 4: Unidades Hidrográficas e principais cidades da RH Tocantins-Araguaia...	22
Figura 5: temperatura média mensal da Terra ao longo das décadas .....	24
Figura 6: Mudanças projetadas de longo prazo (2081-2100) na sazonalidade da precipitação em média entre os modelos CMIP6 disponíveis (número fornecido no canto superior direito de cada painel) no cenário SSP1-2.6 (b), SSP2-4.5 (c) e SSP5-8.5 (d), respectivamente. A climatologia simulada de 1995–2014 é mostrada no painel (a).....	33
Figura 7: Hidrograma unitário triangular.....	37
Figura 8: Representação esquemática do modelo matemático de um neurônio artificial .....	40
Figura 9: Arquitetura de uma RNN, com múltiplas camadas ocultas (i.e., aprendizado profundo).....	43
Figura 10: Modo de operação NARX Open Loop (a) e; Closed Loop (b) .....	44
Figura 11: Esquerda: gráfico quantil-quantil da precipitação observada ( $P_o$ ) e projetada ( $P_m$ ), bem como uma transformação ( $P_o = h(P_m)$ ) que é usada para mapear os quantis projetados nos observados. Direita: CDF empírica da precipitação observada, projetada e transformada ( $h(P_m)$ ).....	47
Figura 12: Localização da sub-bacia hidrográfica do rio Guamá.....	54
Figura 13: Mapa do Uso e Cobertura da terra da sub-bacia hidrográfica do rio Guamá .....	55
Figura 14: Divisão das vazões diárias observadas em períodos destinados ao treinamento e validação cruzada do modelo RNN-NARX (a) e mensais (b) na estação fluviométrica Bom Jardim. ....	60
Figura 15: Divisão das precipitações observadas nas estações pluviométricas (P1 (a), P2 (b), P3 (c), e P4 (d)) em períodos destinados ao treinamento e validação cruzada do modelo RNN-NARX.....	60
Figura 16: Fluxograma da metodologia apresentada para estimar as vazões com um modelo RNN-NARX sob a influência das mudanças climáticas. ....	66

Figura 17: Coeficientes de correlação cruzada entre a vazão (Q1) e as precipitações (P1-a, P2-b, P3-c e P4-d) e coeficientes de autocorrelação parcial da vazão (e), com intervalo de confiança de 99% para o período de referência (2009-2021).....	67
Figura 18: Dispersão entre os dados observados e simulados nas etapas de treinamento e validação para o período de referência (2009-2021), resultado da parametrização.....	69
Figura 19: Dispersão das vazões diárias observadas e estimadas durante a validação da RNN-NARX para os cenários SSP2-4.5 (a) e SSP5-8.5 (b) no período de referência (2009-2021).....	71
Figura 20: Equações para a correção das vazões simuladas pelo método EQM para o cenário SSP2-4.5 (a) e SSP5-8.5 (b), no período de referência (2009-2021) .....	72
Figura 21: Curvas de vazões observadas, estimadas e corrigidas para os cenários SSP2-4.5 (a) e SSP5-8.5 (b), para o período de referência (2009-2021) .....	73
Figura 22: Vazão simulada para o cenário SSP2-4.5 para o período futuro (2022-2100) .....	75
Figura 23: Vazão simulada para o cenário SSP5-8.5 para o período futuro (2022-2100) .....	75
Figura 24: Distribuição das vazões simuladas por mês para o cenário SSP2-4.5 (a) e SSP5-8.5 (b), no período futuro (2022 a 2100) .....	76
Figura 25: Tendência das vazões médias anuais para os cenários SSP2-4.5 (a) e SSP5-8.5 (b).....	77

## LISTA DE TABELAS

Tabela 1: População, densidade demográfica, disponibilidade hídrica e disponibilidade hídrica per capita das regiões hidrográficas brasileiras.....	21
Tabela 2: Identificação, coordenadas geográficas e estações hidrometeorológicas utilizadas no estudo.....	56
Tabela 3: Métricas de desempenho .....	57
Tabela 4: Níveis de desempenho estratificados para qualificar um modelo.....	58
Tabela 5: Condições de parada antecipada por validação cruzada .....	62
Tabela 6: Vetores de entrada e os atrasos temporais da RNN-NARX treinada .....	68
Tabela 7: Métricas de desempenho da RNN-NARX no treinamento e validação cruzada .....	69
Tabela 8: Métricas de desempenho das vazões na validação da RNN-NARX sob os cenários SSP2-4.5 e SSP5-8.5 para o período de referência .....	70
Tabela 9: Valores das métricas de desempenho antes e depois da correção de viés nas vazões simuladas pela RNN-NARX, sob os cenários SSP2-4.5 e SSP5-8.5, para o período de referência (2009-2021).....	73

## **LISTA DE SIGLAS E ABREVIATURAS**

ACCESS - Australian Community Climate and Earth System Simulator

AM - Aprendizado de Máquina

ANA - Agência Nacional de Águas e Saneamento Básico

AR5 – 5° Relatório do Painel Intergovernamental sobre Mudanças Climáticas

AR6 - 6° Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas

CESM2 - Community Earth System Model, versão 2

CESM2-CAM6 - Community Atmosphere Model, versão 6

CESM2-WACCM - Whole Atmosphere Community Climate Model

CMCC - Centro Euro-Mediterraneo sui Cambiamenti Climatici

CMIP - Projeto de Intercomparação de Modelos Acoplados

CMIP3 – Coupled Model Intercomparison Project Phase 3

CMIP5 – Coupled Model Intercomparison Project Phase 5

CMIP6 – Coupled Model Intercomparison Project Phase 6

CNN - Convolutional Neural Network

COSMO - Consortium for Small-scale Modeling

DNN - Deep Neural Network

EQM - Empirical Quantile Mapping

FFNN - Feedforward Neural Network

FGOALS - Flexible Global Ocean-Atmosphere-Land System Model

FIT - Valor de Ajuste

GCM - General Circulation Model

GEEs – Gases do Efeito Estufa

GFDL - Geophysical Fluid Dynamics Laboratory

HEC-HAS - Hydrologic Engineering Center – Hydraulic Analysis System

HEC-HMS - HMS Hydrologic Engineering Center Hydrologic Modeling System

HS – Hargreaves-Samani

IA – Inteligência Artificial

INMET – Instituto Nacional de Meteorologia

IPCC - Intergovernmental Panel on Climate Change

KGE - Índice de Eficiência Kling-Gupta

MLP – Multilayer Perceptron

MPI-ESM1 - Max Planck Institute Earth System Model, versão 1

MSE - Erro Médio Quadrático

NARX - Autorregressiva Não-linear com Entrada Exógena

NASA – National Aeronautics and Space Administration

NEX-GDDP - NASA Earth Exchange Global Daily Downscaled Projections

NOAA - National Oceanic and Atmospheric Administration

ONU – Organização das Nações Unidas

$R^2$  - Coeficiente de Determinação

RBF - Radial Basis Function

RCP - Cenário de Concentração Representativa

RH – Região Hidrográfica

RNA - Rede Neural Artificial

RNN - Rede Neural Recorrente

SCS-CN - Soil Conservation Service Curve Number

SEIRH – Sistema Estadual de Informações Sobre Recursos Hídricos do Pará

SHE - Systeme Hydrologique Europeen

SSP - Cenário Socioeconômico Compartilhado

SWMM - Storm Water Management Model

WGCM - Grupo de Trabalho sobre Modelagem Acoplada

## SUMÁRIO

1	INTRODUÇÃO.....	14
1.1	OBJETIVOS .....	16
1.1.1	Geral.....	16
1.1.2	Específicos .....	16
2	FUNDAMENTAÇÃO TEÓRICA .....	17
2.1	CICLO HIDROLÓGICO.....	17
2.2	DISPONIBILIDADE HÍDRICA .....	18
2.2.1	Disponibilidade Hídrica nas Regiões Hidrográficas Brasileiras.....	19
2.2.2	Disponibilidade Hídrica no Tocantins-Araguaia .....	21
2.3	MUDANÇAS CLIMÁTICAS .....	23
2.3.1	Histórico da Ciência Climática .....	23
2.3.2	Limiar de 1,5°C no Aquecimento Global.....	23
2.3.3	Painel Intergovernamental de Mudanças Climáticas – IPCC.....	25
2.3.4	Relatórios de Avaliação do IPCC – AR.....	25
2.3.5	Projeto de Intercomparação de Modelos Acoplados – CMIP.....	26
2.3.6	Modelo de Circulação Geral - GCM.....	28
2.3.7	Cenários Climáticos de Modelos Climáticos .....	30
2.4	MODELOS HIDROLÓGICOS .....	33
2.5	MODELO CHUVA-VAZÃO .....	35
2.5.1	Método Racional.....	36
2.5.2	Hidrograma Unitário.....	36
2.6	REDES NEURAIAS ARTIFICIAIS .....	38
2.6.1	Breve Histórico .....	38
2.6.2	Conceitos Básicos .....	39
2.6.3	Perceptron de Múltiplas Camadas.....	41
2.6.4	Redes Neurais Profundas e Convolucionais .....	41

2.6.5	Redes Neurais Recorrentes.....	42
2.6.6	Rede Recorrente NARX .....	43
2.6.7	Função de Ativação .....	45
2.6.8	Treinamento: Algoritmo de Retropropagação do Erro .....	46
2.7	TRANSFORMAÇÕES ESTATÍSTICAS.....	46
2.7.1	Transformações derivadas de distribuição .....	47
2.7.2	Transformações paramétricas .....	47
2.7.3	Transformações não-paramétricas .....	48
2.8	ANÁLISE DE TENDÊNCIA .....	49
2.8.1	Média Móvel e Mediana Móvel .....	50
2.8.2	Regressão Linear .....	50
2.8.3	Spearman Rho.....	51
2.8.4	Mann-Kendall.....	51
3	MATERIAL E MÉTODOS .....	53
3.1	ÁREA DE ESTUDO.....	53
3.1.1	Bacia hidrográfica do rio Capim-Guamá.....	53
3.1.2	Sub-bacia hidrográfica do rio Guamá .....	53
3.2	EXTRAÇÃO DE DADOS.....	55
3.3	MÉTRICAS DE DESEMPENHO .....	57
3.4	CORRELAÇÃO CRUZADA E AUTOCORRELAÇÃO PARCIAL .....	58
3.5	MODELO RNN-NARX.....	59
3.5.1	Divisão do conjunto de dados.....	59
3.5.2	Treinamento.....	61
3.5.3	Validação cruzada por parada antecipada .....	62
3.6	CORREÇÃO DE VIÉS DAS VAZÕES SIMULADAS .....	63
3.7	TESTE MANN-KENDALL.....	63
3.8	ESTIMADOR <i>SEN'S SLOPE</i> .....	64

3.9	COEFICIENTE DE VARIÂNCIA .....	65
4	RESULTADOS E DISCUSSÃO .....	67
4.1	CORRELAÇÃO CRUZADA E AUTOCORRELAÇÃO PARCIAL .....	67
4.2	PERÍODO DE REFERÊNCIA.....	68
4.2.1	Open Loop – treinamento e validação cruzada .....	68
4.2.2	Closed Loop – simulação de vazão .....	70
4.2.3	Correção de Viés .....	72
4.3	PERÍODO FUTURO.....	74
4.3.1	Closed Loop -Simulação das vazões sob influência das mudanças climáticas .....	74
4.4	ANÁLISE DE TENDÊNCIA NAS VAZÕES SIMULADAS .....	77
5	CONCLUSÃO .....	79
	REFERÊNCIAS.....	80

## 1 INTRODUÇÃO

As mudanças climáticas têm se manifestado de forma intensa e frequente, com impactos severos sobre os sistemas naturais e humanos em escala global. Estudos baseados em simulações climáticas indicam que a Terra está em um processo contínuo de aquecimento, resultando em uma série de eventos extremos, como secas, enchentes, tempestades e aumento do nível do mar (Abhijeet et al., 2023; Masson-Delmotte et al., 2021). A complexidade dessas mudanças exige compreensão dos impactos em diferentes setores, incluindo dos recursos hídricos, que são fundamentais para o abastecimento humano, produção de energia e agricultura (Vaidyanathan, 2024). Um dos grandes desafios para a ciência climática atual é a previsão de como os recursos hídricos, em particular a vazão dos rios, responderão às mudanças do clima (Tayal et al., 2024). Essas projeções tornam-se cada vez mais relevantes, visto que dados do Copernicus Data Space Ecosystem, da Agência Espacial Europeia (ESA), mostram que 2024 foi o primeiro ano a exceder 1,5°C acima dos níveis pré-industriais (Copernicus, 2024). Nesse contexto, a simulação da vazão dos rios permite analisar o risco de inundações e outras condições que afetam diretamente a segurança hídrica e o planejamento de políticas de mitigação e adaptação (Gharsallaoui et al., 2024).

Os Modelos de Circulação Geral (GCM's) são amplamente utilizados para projeções de variáveis climáticas, entre elas, a precipitação, que é a principal variável forçante para a simulação de variáveis hidrológicas, tal qual vazões. Assim, os GCM's podem ser utilizados para obter respostas dos sistemas hidrológicos às variações climáticas. Como por exemplo, a seca extrema que ocorreu na região amazônica, que iniciou no verão austral de 2022-23 e se estendeu até 2024. Essa seca começou mais cedo do que as anteriores (Marengo et al., 2024), tornando 2023 o ano mais quente desde 1980 em grande parte da região, devido às anomalias de temperatura de até +2,7°C. O desmatamento, somado às mudanças climáticas, ameaça empurrar a floresta amazônica para um "ponto de inflexão" irreversível, especialmente nas áreas afetadas por fragmentação florestal e degradação (Espinoza et al., 2024). Sendo assim, há a necessidade de monitorar os eventos extremos, embora haja dificuldades em manter as estações de monitoramento em pleno funcionamento.

Para solucionar esses desafios em bacias hidrográficas, especialmente em regiões tropicais, técnicas de aprendizado de máquina, como Redes Neurais Artificiais (RNAs), têm se mostrado particularmente eficazes. Visto que as RNAs são capazes

de reconhecer padrões em séries temporais, ajustando seus pesos sinápticos e bias por meio de algoritmos de treinamento, o que as torna ideais para a simulação de fenômenos naturais. Esses modelos têm a vantagem de generalizar os padrões aprendidos durante o treinamento, permitindo a projeção de eventos futuros. As Redes Neurais Recorrentes (RNNs), uma subclasse avançada das RNAs, destacam-se por sua capacidade de utilizar memórias internas (feedback), permitindo capturar e representar dinâmicas temporais complexas (Pirhooshyaran e Snyder, 2020). Dentro dessa classe, a abordagem Autorregressiva Não-linear com Entradas Exógenas (RNN-NARX) tem se consolidado como uma ferramenta eficaz para modelar sistemas de entrada e saída com não linearidades acentuadas. Essa abordagem tem sido amplamente aplicada na simulação de variáveis hidrológicas (Wang e Chen, 2022). Duas configurações de RNN-NARX são essenciais na modelagem, com dois modos de operação: Open Loop e Closed Loop. No modo open-loop (série-paralelo), os valores observados (alvo) são manualmente inseridos na entrada, utilizando uma arquitetura feedforward, onde as informações fluem em uma única direção (Menezes e Barreto, 2008). Já no modo Closed Loop (paralelo), a saída estimada do modelo é realimentada diretamente na entrada. Para simulações de longo prazo, a estrutura open-loop deve ser convertida em Closed Loop (Chang et al., 2016). Nesse formato, os valores observados na entrada são gradualmente substituídos por estimativas do próprio modelo, tornando-o autônomo, uma aplicação relevante para RNN-NARX (Mendonça et al., 2023).

Assim, objetivo é simular vazões para uma sub-bacia hidrográfica da Amazônia, considerando dois cenários climáticos do CMIP6 e analisar os impactos na disponibilidade hídrica da sub-bacia até o ano de 2100, por meio da análise de tendência. As vazões diárias foram simuladas usando RNN-NARX, tendo como entrada precipitação projetada do GCM GFDL-ESM4. A análise de tendência foi elaborada via teste Mann Kendall, estimador Sen's Slope e coeficiente de variância. A metodologia adotada contribui para a compreensão dos impactos das mudanças climáticas nos recursos hídricos, relacionando-se diretamente com os objetivos de desenvolvimento sustentável da ONU: ODS 2 (Fome Zero) e ODS 13 (Ação Climática) (ONU, 2024). A redução da disponibilidade hídrica pode afetar a segurança alimentar e a agricultura sustentável, enquanto a análise de cenários climáticos apoia ações para mitigar os efeitos das mudanças climáticas, alinhando-se às metas globais de sustentabilidade.

## 1.1 OBJETIVOS

### 1.1.1 Geral

Analisar a influência das mudanças climáticas nas vazões de uma bacia hidrográfica localizada na Amazônia brasileira, utilizando duas projeções climáticas futuras do CMIP6 até o ano de 2100. Para isso, foram realizadas análises de tendência nas vazões, visando identificar possíveis modificações no regime hidrológico da região em resposta aos cenários climáticos projetados.

### 1.1.2 Específicos

- Desenvolver um modelo de rede neural recorrente para simular vazões diárias, utilizando dados históricos;
- Avaliar o desempenho do modelo no período de referência (2009-2021), comparando vazões simuladas às observadas;
- Aplicar o modelo parametrizado para simular vazões diárias no período - futuro (2022-2100), utilizando dados projetados por um modelo de circulação geral (GCM);
- Avaliar a tendência nas vazões simuladas, conforme o teste Mann-Kendall, estimador Sen's Slope e coeficiente de variância.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 CICLO HIDROLÓGICO

O ciclo hidrológico pode ser considerado um fenômeno global de circulação fechada da água entre a superfície terrestre e a atmosfera, impulsionado pela energia solar associada à gravidade e à rotação terrestre (Figura 1). Esse intercâmbio entre as circulações ocorre em dois sentidos: i) no sentido superfície-atmosfera, onde o fluxo de água ocorre fundamentalmente na forma de vapor, como decorrência dos fenômenos de evaporação e de transpiração; ii) no sentido atmosfera-superfície, onde a transferência de água ocorre em qualquer estado físico, sendo mais significativas (em termos globais), as precipitações de chuva e neve (Tucci, 2009). O ciclo hidrológico contribui para muitos processos dinâmicos ambientais, como movimento de nutrientes, contaminação, equilíbrio de solutos e transporte de sedimentos, porém, a compreensão de todos esses processos, no tempo e espaço, é complexa (Chow et al., 1994).

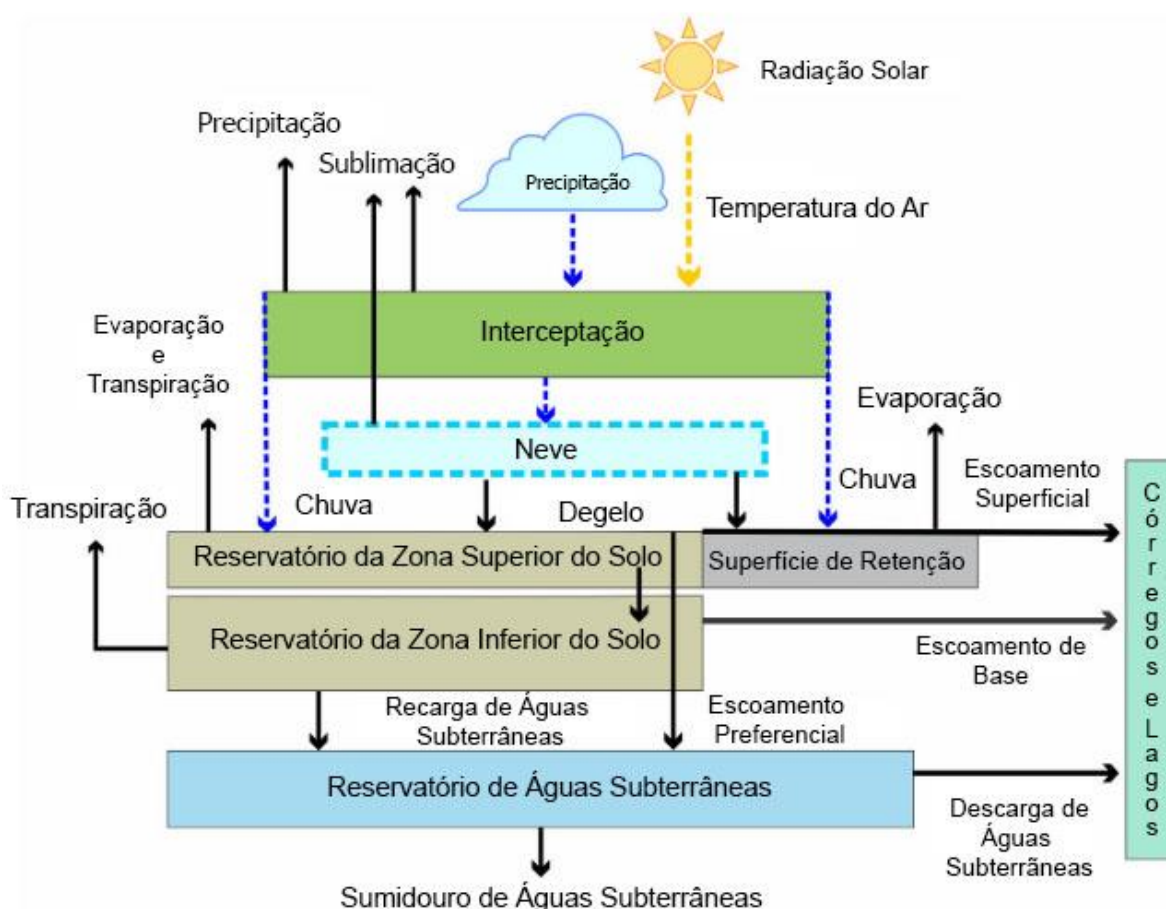


Figura 1: Principais fluxos e armazenamentos  
Fonte: Markstrom et al. (2015)

O ciclo hidrológico também pode ser representado de forma simplificada mediante o conceito de ‘sistema’ (Shiklomanov, 1998). Na escala global, o ciclo hidrológico é considerado um ‘sistema fechado’, cujo resultado indica a quantidade de água disponível no solo, rios, lagos, vegetação úmida e oceanos. Na escala local, os sistemas de água podem ser divididos em subsistemas hidrológicos. O estudo desses subsistemas, aparentemente independentes, é importante para entender as demandas existentes, na quais o elemento de análise é a bacia hidrográfica (Tucci, 2009). A Figura 2 apresenta as contribuições das principais bacias hidrográficas do mundo, em descarga diária ( $\text{m}^3/\text{s}$ ).

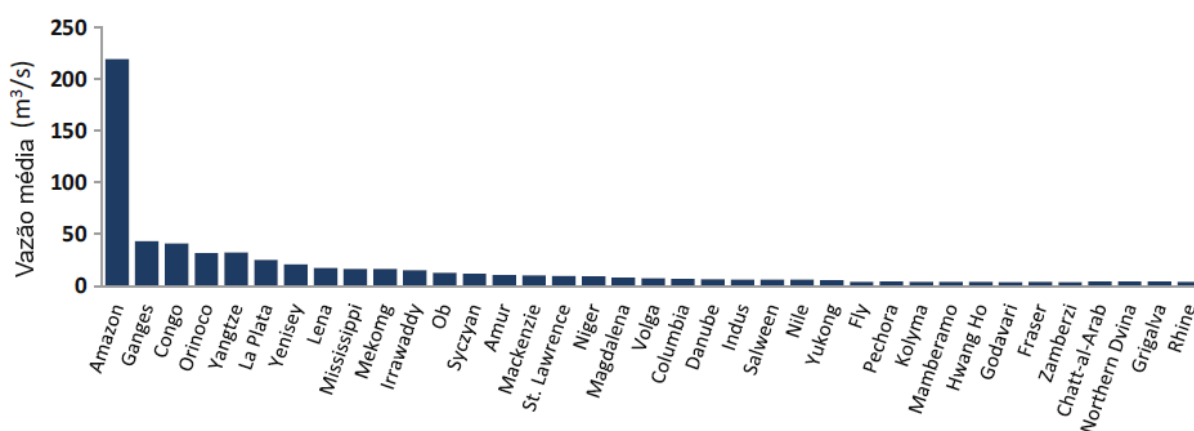


Figura 2: Vazão diária média de longo prazo na saída das principais bacias hidrográficas do mundo

Fonte: Shiklomanov (1998)

## 2.2 DISPONIBILIDADE HÍDRICA

A quantidade de água no planeta não diminuirá em escalas de tempo inferiores às geológicas devido aos ciclos hidrológicos fechados (Oki et al., 2006). Todavia, a escassez de água pode se tornar uma realidade generalizada dentro de algumas décadas (Rosegrant; Cai; Cline, 2003). A explicação mais utilizada para a pequena quantidade de água facilmente acessível, é que embora haja muita água na Terra, apenas cerca de 2,5% é água doce, porém, a maior parte dessa água é armazenada como geleiras ou águas subterrâneas profundas. No entanto, essa explicação está parcialmente correta, pois as avaliações devem se concentrar principalmente nos fluxos dos recursos hídricos, ao invés de focar no seu armazenamento. Com base nessa afirmação, expõe-se que a quantidade de água armazenada em todos os rios do mundo é cerca de  $2.000 \text{ km}^3$ , muito inferior a  $3.800 \text{ km}^3/\text{ano}$  que é retirado anualmente de água (Oki e Kanae, 2006; Shiklomanov, 1998).

Assim, apesar da abundância de água em toda a extensão do globo terrestre, a porção disponível para consumo humano representa uma parcela pequena e passível de escassez (Tucci, 2009). Portanto, os estudos voltados à análise da disponibilidade hídrica são importantes para adquirir conhecimentos necessários às soluções e/ou adequação dos recursos hídricos diante da crise climática.

A partir da nota técnica N° 16/2016/SPR, a Agência Nacional de Águas e Saneamento Básico (ANA) estabeleceu o conceito geral para disponibilidade hídrica, que deve ser entendida como a quantidade de água que serve de referência para contabilização do balanço entre oferta e demanda. O documento destaca que esta disponibilidade representa uma condição de oferta bruta de água sobre a qual define-se o quanto desse recurso ainda poderia ser alocado para diversos fins ou para mensurar possíveis estresses hídricos.

#### 2.2.1 Disponibilidade Hídrica nas Regiões Hidrográficas Brasileiras

O Brasil é rico no que se refere à disponibilidade de recursos hídricos, mas apresenta uma grande variação espacial e temporal na quantidade de água disponível para consumo. Essas variações de regimes fluviométricos, tanto espaciais como temporais, devem-se à combinação das variadas condições climáticas com as características morfológicas das bacias hidrográficas brasileiras. Com base nisso, para a gestão das águas no Brasil, têm-se as bacias hidrográficas, no âmbito do planejamento territorial, como a unidade básica de análise para o desenvolvimento de medidas com o objetivo de promover a integração entre a gestão dos recursos hídricos e a gestão ambiental (ANA, 2024).

Este recorte territorial elaborado a partir de divisores de águas foi instituído através da Política Nacional de Recursos Hídrico (Lei nº 9.433, de 8 de janeiro de 1997), que dividiu o país em 12 Regiões Hidrográficas (RH), são elas: Amazônica, Tocantins-Araguaia, Atlântico Nordeste Ocidental, Parnaíba, Atlântico Nordeste Oriental, São Francisco, Atlântico Leste, Paraguai, Paraná, Atlântico Sudeste, Uruguai e Atlântico Sul (Figura 3) (BRASIL, 1997).

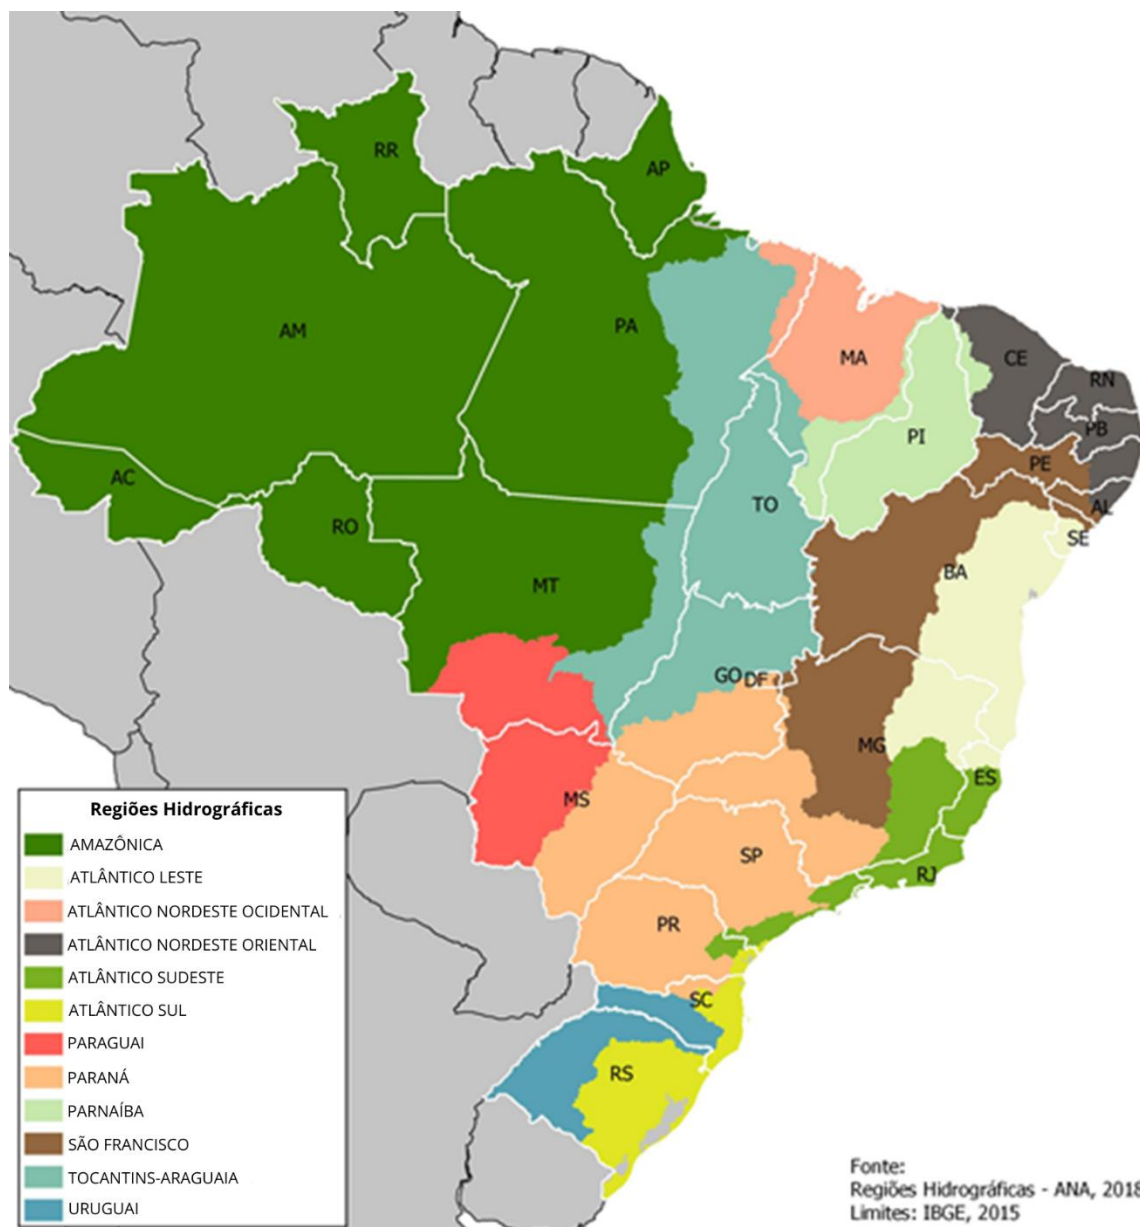


Figura 3: Regiões hidrográficas brasileiras  
Fonte: ANA (2024)

Apesar da elevada disponibilidade hídrica média por habitante no Brasil, que é de aproximadamente 13.000 m<sup>3</sup>/habitante/ano, as disparidades regionais são significativas quando analisadas por região hidrográfica. Na região amazônica, por exemplo, a disponibilidade hídrica per capita supera 213.445 m<sup>3</sup>/hab/ano, refletindo a abundância de recursos hídricos na área (ANA, 2015). No entanto, na maioria das regiões hidrográficas (RHs), a disponibilidade é drasticamente inferior à média nacional, como é o caso das regiões do Parnaíba, Atlântico Nordeste Ocidental e Atlântico Nordeste Ocidental Oriental, como pode ser observado na Tabela 1. Essa desigualdade evidencia os desafios relacionados à distribuição desigual dos recursos

hídricos no país, com algumas regiões enfrentando escassez relativa em comparação com outras.

Tabela 1: População, densidade demográfica, disponibilidade hídrica e disponibilidade hídrica per capita das regiões hidrográficas brasileiras

Região Hidrográfica	Área de drenagem (km <sup>2</sup> )	População (ano-base 2010)	Densidade populacional (habitante/km <sup>2</sup> )	Disponibilidade de hídrica (m <sup>3</sup> /s)	Disponibilidade de hídrica per capita (m <sup>3</sup> /habitante/ano)
Amazônica	3.879.207	9.694.728	2,5	65.617	213.445,7
Tocantins-Araguaia	920.087	8.572.716	9,3	3.098	11.396,4
Parnaíba	333.056	4.152.865	12,5	325	2.468,0
Atlântico Nordeste Ocidental	274.350	6.244.419	22,8	397	2.005,0
Atlântico Nordeste Oriental	286.761	24.077.328	84,0	218	285,5
São Francisco	638.466	14.289.953	22,4	875	1.931,0
Atlântico Leste	388.160	15.066.543	38,8	271	567,2
Paraná	879.873	61.290.272	69,7	4.390	2.258,8
Paraguai	363.445	2.165.938	6,0	1.023	14.894,9
Uruguai	174.801	3.922.873	22,4	550	4.421,5
Atlântico Sudeste	214.629	28.236.436	131,6	1.325	1.479,8
Atlântico Sul	186.673	12.976.554	69,5	513	1.246,7
Brasil	8.539.508	190.690.625	22,3	78.602	12.999,0
Média por RH	711.626	15.890.885	41	6.550	21.366,7

Fonte: ANA (2015)

### 2.2.2 Disponibilidade Hídrica no Tocantins-Araguaia

A região hidrográfica Tocantins-Araguaia (Figura 4), delimitada a leste pela bacia Amazônica e a oeste pela bacia Atlântico Nordeste Ocidental, abrange uma área de aproximadamente 920 mil km<sup>2</sup>, o que corresponde a 10,8% do território nacional. Essa região estende-se por seis unidades federativas: Goiás (21%), Tocantins (30%), Pará (30%), Maranhão (4%), Mato Grosso (15%) e Distrito Federal (0,1%). A maior parte de sua área está localizada na região Centro-Oeste, desde as nascentes dos



## 2.3 MUDANÇAS CLIMÁTICAS

### 2.3.1 Histórico da Ciência Climática

As bases científicas para o estudo da ciência climática remontam ao século XIX. O físico francês Joseph Fourier foi pioneiro ao propor, em 1824, a ideia de que a atmosfera terrestre retém calor, comparando-a a uma estufa. Ele sugeriu que a atmosfera age como uma barreira que mantém a superfície do planeta aquecida (Fourier, 1824). Posteriormente, o cientista britânico John Tyndall avançou nessa compreensão ao descobrir, em 1859, que certos gases, como o dióxido de carbono ( $\text{CO}_2$ ) e o vapor d'água, têm a capacidade de absorver e reemitir calor. Seus experimentos foram fundamentais para elucidar o papel desses gases na regulação da temperatura terrestre (Tyndall, 1859). Em 1896, o químico sueco Svante Arrhenius quantificou o impacto do  $\text{CO}_2$  no clima. Seus resultados demonstraram que a duplicação das concentrações de  $\text{CO}_2$  na atmosfera poderia elevar a temperatura média da Terra de 5 a 6°C. Arrhenius também sugeriu que a queima de combustíveis fósseis poderia contribuir para o aumento das concentrações desse gás e, consequentemente, para o aquecimento global (Arrhenius, 1896).

No século XX, o consenso científico e ações globais evoluíram significativamente. O Painel Intergovernamental sobre Mudanças Climáticas (IPCC) foi estabelecido pela Organização das Nações Unidas (ONU), em 1988, para avaliar e sintetizar o conhecimento científico relacionado ao clima. Desde seu primeiro relatório, publicado em 1990, o IPCC tornou-se a principal autoridade global no tema, fornecendo avaliações abrangentes e atualizadas sobre as causas, impactos e soluções para o aquecimento global (IPCC, 1990). No século XXI, os esforços internacionais para combater as mudanças climáticas ganharam impulso com o Acordo de Paris, adotado em 2015 no âmbito da ONU. Esse acordo estabeleceu a meta de limitar o aumento da temperatura média global a menos de 2°C acima dos níveis pré-industriais, com esforços adicionais para restringir o aquecimento a 1,5°C.

### 2.3.2 Limiar de 1,5°C no Aquecimento Global

O aquecimento global refere-se ao aumento gradual da temperatura média da atmosfera e dos oceanos próximos à superfície da Terra, um fenômeno amplamente documentado pela ciência climática (Masson-Delmotte, 2021). O limiar de 1,5°C estabelecido pela comunidade internacional no Acordo de Paris refere-se a um aquecimento médio global sustentado ao longo do tempo, e não a variações anuais,

que podem apresentar flutuações acima ou abaixo da tendência de longo prazo (Nações Unidas, 2015). Nesse contexto, estudos para o ano de 2022 demonstram que as temperaturas atingiram 1,3°C acima dos níveis pré-industriais (Jones, 2023). No ano seguinte, os valores mensais também registraram pelo menos 1,2 °C acima da média correspondente ao período de 1850 a 1900. Embora o início de 2023 tenha apresentado temperaturas semelhantes às de 2021 e 2022, o fim do evento La Niña marcou o início de uma trajetória distinta. Na segunda metade do ano, as temperaturas tornaram-se mais extremas, impulsionadas pelo fortalecimento do El Niño. Os últimos sete meses de 2023 estabeleceram novos recordes de temperatura, incluindo julho, que registrou a maior média absoluta já medida na Terra, e setembro, com a maior anomalia mensal já documentada. Grande parte da variação de temperatura entre 2022 e 2023 foi atribuída à transição de La Niña para El Niño, combinada com outros fatores de variabilidade natural, como o aquecimento do Atlântico Norte, além de contribuições modestas de outros elementos. Em 2024, o El Niño continuou a influenciar o aumento de temperaturas no primeiro semestre (Figura 5), antes de enfraquecer em junho (Berkeley Earth, 2024).

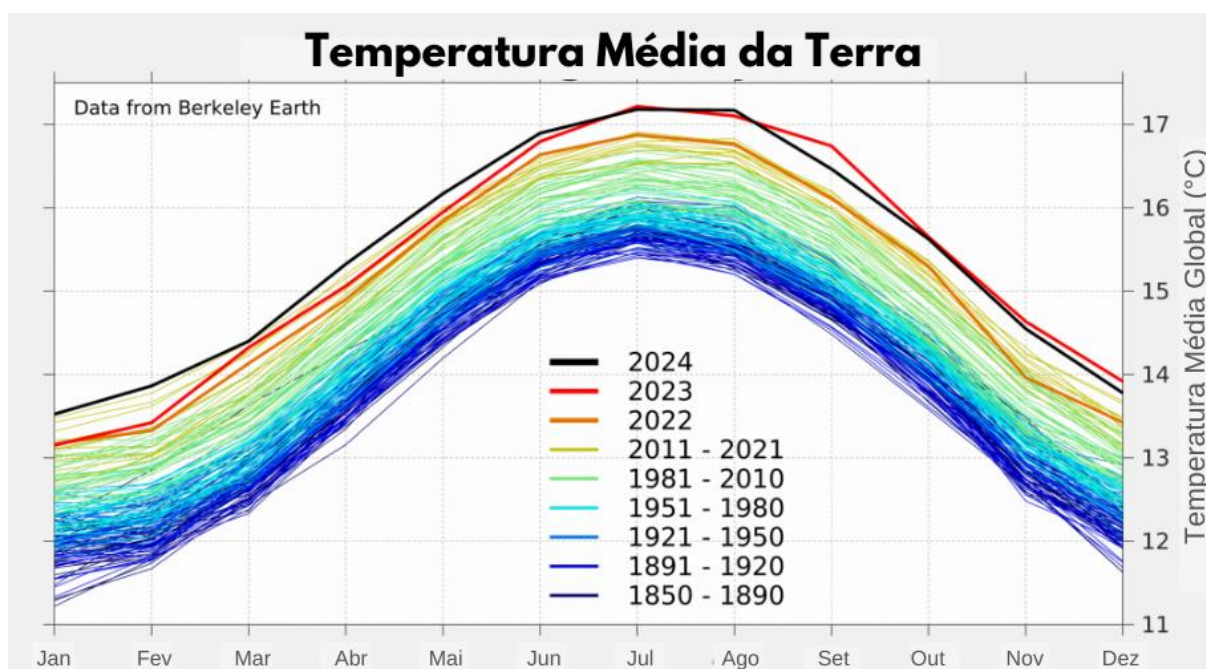


Figura 5: temperatura média mensal da Terra ao longo das décadas

Fonte: Berkeley Earth (2024)

A longo prazo, o aquecimento global induzido pelas atividades humanas tem elevado gradualmente as temperaturas à taxa de aproximadamente 0,2°C por década (Berkeley Earth, 2024). A relevância dessas tendências intensifica-se com os dados do Copernicus Data Space Ecosystem, que indicam que 2024 foi o primeiro ano a ultrapassar a marca de 1,5°C acima dos níveis pré-industriais, sendo as emissões de gases de efeito estufa as principais responsáveis por esse aquecimento (Tollefson, 2025).

### 2.3.3 Painel Intergovernamental de Mudanças Climáticas – IPCC

O termo ‘mudanças climáticas’ foi popularizado em 1998 pela Organização Meteorológica Mundial (OMM) e pelo Programa das Nações Unidas para o Meio Ambiente (PNUMA), com o apoio da comunidade científica e o endosso da Assembleia Geral da ONU. Outrossim, o Painel Intergovernamental sobre Mudanças Climáticas (IPCC) foi criado com a missão de fornecer avaliações objetivas e cientificamente embasadas sobre o conhecimento existente a respeito das mudanças climáticas. Para isso, o IPCC reúne, analisa e sintetiza pesquisas científicas de todo o mundo, produzindo relatórios de avaliação abrangentes que servem como referências para governos, formuladores de políticas públicas e cientistas na compreensão desse desafio global.

### 2.3.4 Relatórios de Avaliação do IPCC – AR

O Primeiro Relatório de Avaliação do IPCC (FAR), lançado em 1990, estabeleceu as bases científicas para a compreensão das mudanças climáticas, destacando o aumento das concentrações de gases de efeito estufa (GEE's) na atmosfera e a correlação com o aquecimento global. O Segundo Relatório (SAR), publicado em 1995, reforçou a influência humana no clima e forneceu subsídios para o Protocolo de Kyoto, que estabeleceu metas de redução de emissões para países desenvolvidos. Já o Terceiro Relatório (TAR), em 2001, introduziu cenários futuros e destacou a necessidade de ações robustas, enquanto o Quarto Relatório (AR4), em 2007, consolidou a certeza científica sobre a influência humana no clima, sendo um dos pilares para o Prêmio Nobel da Paz concedido ao IPCC naquele ano.

O Quinto Relatório (AR5), publicado em 2014, reforçou a urgência de limitar o aquecimento global a 2°C acima dos níveis pré-industriais e serviu como base científica para o Acordo de Paris, em 2015. Por fim, o Sexto Relatório (AR6), divulgado

entre 2021 e 2023, trouxe conclusões ainda mais alarmantes, afirmando que a influência humana no clima é "inequívoca" e que o aquecimento global já atingiu 1,1°C acima dos níveis pré-industriais. O relatório ressaltou a necessidade de cortes profundos e imediatos nas emissões para limitar o aquecimento a 1,5°C, evitando os piores impactos, como eventos climáticos extremos, elevação do nível do mar e perda de biodiversidade (<https://www.ipcc.ch/about/history/>).

### 2.3.5 Projeto de Intercomparação de Modelos Acoplados – CMIP

O objetivo do Coupled Model Intercomparison Project (CMIP) é entender melhor as mudanças climáticas passadas, presentes e futuras decorrentes da variabilidade natural, não forçada ou em resposta a mudanças na força radiativa em um contexto multimodelo. Este entendimento inclui avaliações do desempenho dos modelos durante o período histórico e quantificações das causas do spread (dispersão) em projeções futuras (<https://www.wcrp-climate.org/wgcm-cmip>). O grau de dispersão nas projeções climáticas futuras ocorre em algumas regiões, devido a uma combinação de variações na sensibilidade climática que determina a magnitude da resposta global média, e grandes variações nos padrões espaciais de mudança – particularmente para a precipitação (McSweeney e Jones, 2016). O projeto CMIP é realizado em várias fases, chamadas de fases de modelagem, que ocorrem em intervalos regulares. Durante cada fase, os centros de modelagem participantes executam seus modelos climáticos acoplados com base em cenários de emissão específicos, como os cenários de emissão do IPCC (<https://wcrp-cmip.org/cmip-overview/>).

O CMIP começou em 1995 sob os auspícios do *Working Group on Coupled Modelling* (WGCM). O primeiro conjunto de experimentos comuns envolveu a comparação da resposta do modelo a uma força idealizada - uma taxa constante de aumento que foi realizada usando um aumento de CO<sub>2</sub> de 1% ao ano composto. Desde então, vários experimentos CMIP foram desenvolvidos. Os experimentos continuam a incluir integrações usando forçantes idealizadas para facilitar o entendimento. Eles agora incluem integrações forçadas com estimativas das mudanças nas forçantes radiativas históricas, bem como estimativas das mudanças futuras.

A primeira fase (CMIP1) ocorreu entre 1995 e 1999 com a premissa de melhorar a compreensão do clima global e seus processos por meio da comparação

de modelos climáticos. A segunda fase do (CMIP2) ocorreu entre 1999 e 2004, em que foram realizadas simulações abrangentes e aprimoradas de modelos climáticos, comparando as respostas desses modelos a diferentes forçantes climáticas. Nessas duas primeiras fases, o CMIP envolveu a operação de 18 GCM's em duas configurações diferentes: uma "operação de controle" sob condições pré-industriais constantes e uma "operação perturbada", na qual o dióxido de carbono atmosférico aumentou 1% ao ano durante 80 anos.

Entre 2005 e 2006, o CMIP3 expandiu significativamente os resultados de dados do projeto, contando com a participação de 25 modelos. Esta trajetória ascendente continuou com o CMIP5 e o CMIP6, cada um envolvendo mais modelos e mais experimentos do que seu antecessor. O CMIP6 é a fase mais recente, e consiste nas "execuções" de cerca de 100 modelos climáticos, sendo produzidos em 49 grupos de modelagem distintos. Foram produzidos cenários para diferentes faixas de emissão de carbono na atmosfera. Os cenários, já atualizados, são chamados de SSP1-2.6, SSP2-4.5, SSP4-6.0 e SSP5-8.5. Esses cenários foram produzidos e distribuídos através da Earth System Grid Federation, incluindo variáveis sociais, como o aumento populacional, econômico e bioecológico. As execuções dos GCM's do CMIP6 foram desenvolvidas em apoio ao 6º Relatório de Avaliação do IPCC (Painel Intergovernamental sobre Mudanças Climáticas) (WCRP, 2024).

No contexto do CMIP6, o período "historical" refere-se ao intervalo de tempo de 1850 a 2014, durante o qual os modelos climáticos são calibrados e validados em relação aos dados observados. Isso permite a avaliação da precisão dos modelos em reproduzir o clima passado. Além disso, o CMIP6 utiliza cenários SSP (Shared Socioeconomic Pathways), que são projeções futuras que combinam diferentes trajetórias de desenvolvimento socioeconômico com diversos níveis de mitigação de gases de efeito estufa (GEE's). Esses cenários ajudam a explorar uma ampla gama de possíveis futuros climáticos, considerando variáveis como crescimento populacional, desenvolvimento econômico, avanço tecnológico e políticas ambientais, facilitando a análise dos impactos e adaptações potenciais frente às mudanças climáticas (IPCC, 2021).

Os resultados dessas simulações são compartilhados e compilados em um banco de dados central para análise. Os resultados do CMIP são amplamente utilizados na comunidade científica para entender as mudanças climáticas, examinar a variabilidade climática, avaliar os impactos das emissões de gases de efeito estufa

e informar políticas relacionadas ao clima. Esses dados também são usados no desenvolvimento dos relatórios de avaliação do IPCC, fornecendo uma base científica sólida para as conclusões e recomendações apresentadas nos relatórios.

#### 2.3.6 Modelo de Circulação Geral - GCM

A previsibilidade atmosférica possui um limite teórico de aproximadamente duas semanas, devido à natureza caótica da atmosfera terrestre. Para superar essa limitação e realizar projeções climáticas de longo prazo, são utilizados os Modelos de Circulação Geral (GCM's). Os GCM's são modelos climáticos que possibilitam o cálculo do movimento atmosférico em escala hemisférica e global (McWilliams, 2019). Esses modelos são compostos por dois componentes principais: um núcleo dinâmico, responsável por simular o movimento de fluidos em grande escala por meio de equações primitivas, e um modelo físico, que representa processos climáticos significativos, como transferência radiativa, formação de nuvens e convecção, além de incorporar um conjunto de condições de contorno (Edwards, 2011; Calvin et al., 2023).

A história de modelos climáticos remonta ao início do século XX, por volta de 1904, quando o cientista Vilhelm Bjerknes desenvolveu o "teorema da circulação generalizada". Ele propôs que a atmosfera pode ser entendida como um sistema de circulação de massa de ar, impulsionado pela radiação solar e defletido pela rotação da Terra. Ademais, esse sistema era expresso mediante as diferenças locais de velocidade, densidade, pressão, temperatura e umidade do ar (Gramelsberger, 2010).

Em 1922, Lewis Richardson publicou um sistema numérico para previsão do tempo, usando versões simplificadas das equações de Bjerknes. A proposição do trabalho consistiu em dividir um território em uma grade de células, cada uma contendo dados específicos sobre pressão do ar, temperatura e outras variáveis meteorológicas (Gleditsch, 2020). Richardson aplicou seu método numérico para calcular mudanças na pressão atmosférica e nos ventos em duas localidades da Europa Central. Entretanto, devido à complexidade dos cálculos para a época, os resultados foram incertos e não realistas (Costa, 2021).

Somente na década de 1930, matemáticos identificaram as falhas no método numérico usado de Richardson, particularmente em relação ao equilíbrio entre o campo de pressão e vento nas condições iniciais do modelo previsor. O matemático John Von Neumann iniciou o desenvolvimento do Electronic Numerical Integrator and

Computer (ENIAC) no Instituto de Estudos Avançados de Princeton, nos Estados Unidos. O ENIAC, concluído ao final da Segunda Guerra Mundial, foi inicialmente utilizado para cálculos complexos relacionados ao desenvolvimento de armas nucleares. Após a guerra, von Neumann direcionou o uso do computador para a previsão meteorológica, retomando as pesquisas de Bjerknes (Balaji, 2015).

Ao final da década de 1940, as primeiras previsões computadorizadas foram efetuadas a partir dos estudos de von Neumann em conjunto com o meteorologista Jule Charney. Eles simplificaram modelos matemáticos complexos, permitindo que os computadores da época realizassem previsões eficientes. O grupo obteve resultados realistas, destacando-se um experimento em que modelaram os efeitos de uma extensa cadeia de montanhas sobre o fluxo de ar em um continente (Weart, 2010).

Os primeiros modelos meteorológicos eficientes foram projetados para prever o clima em um período de até três dias. Em 1956, Norman Phillips realizou a primeira simulação de longo prazo, cobrindo um mês. Phillips baseou sua simulação em um fluxo de ar ao longo das linhas de latitude da Terra, introduzindo pequenas perturbações aleatórias e uma onda com comprimento de 6.000 km. Os resultados mostraram uma correspondência entre as trocas de energia simuladas da onda e os dados observados na atmosfera real (Phillips, 1956).

A partir dessa contextualização, ao longo das últimas décadas, os GCMs evoluíram significativamente, com avanços na capacidade de simulação do sistema climático global. Entre os modelos mais utilizados, destacam-se o ACCESS (Australian Community Climate and Earth System Simulator), o CESM2 (Community Earth System Model, versão 2), o CMCC (Centro Euro-Mediterraneo sui Cambiamenti Climatici), o FGOALS (Flexible Global Ocean-Atmosphere-Land System Model), o MPI-ESM1 (Max Planck Institute Earth System Model, versão 1) e o GFDL (Geophysical Fluid Dynamics Laboratory). Cada um desses modelos possui múltiplas versões e variações, adaptadas para diferentes aplicações e melhorias em processos físicos.

O ACCESS possui várias versões, como o ACCESS-CM2 e o ACCESS-ESM1.5, desenvolvidos pelo Bureau of Meteorology da Austrália em colaboração com a CSIRO. O ACCESS-CM2 é focado em simulações climáticas, com melhorias na representação de processos atmosféricos e oceânicos, enquanto o ACCESS-ESM1.5 inclui um módulo de sistema terrestre para simular o ciclo do carbono (Scoccimarro et al., 2022).

O CESM2 é uma evolução do CESM1, com versões como o CESM2-WACCM (Whole Atmosphere Community Climate Model) e o CESM2-CAM6 (Community Atmosphere Model, versão 6). O CESM2-WACCM inclui a simulação da atmosfera superior, sendo útil para estudos de química atmosférica e interações estratosfera-troposfera. Já o CESM2-CAM6 apresenta melhorias na parametrização de nuvens e aerossóis, além de uma representação mais precisa do ciclo hidrológico (Danabasoglu et al., 2020).

O CMCC possui versões como o CMCC-CM2 e o CMCC-ESM2. O CMCC-CM2 é focado em simulações climáticas de alta resolução, com melhorias na representação de processos oceânicos e atmosféricos. O CMCC-ESM2 inclui um módulo de sistema terrestre para simular interações entre o clima e o ciclo do carbono, sendo utilizado em estudos de impactos climáticos na região do Mediterrâneo (Lovato et al., 2022).

O FGOALS possui versões como o FGOALS-g3 e o FGOALS-s3. O FGOALS-g3 é uma versão de grade grossa, utilizada para simulações climáticas de longo prazo, enquanto o FGOALS-s3 é uma versão espectral com maior resolução, adequada para estudos de variabilidade climática regional. Ambas as versões incluem melhorias na representação do acoplamento oceano-atmosfera e na simulação de monções (Bao et al., 2013; Li et al., 2020).

O MPI-ESM1 possui versões como o MPI-ESM1-2-HR (alta resolução) e o MPI-ESM1-2-LR (baixa resolução). O MPI-ESM1-2-HR é utilizado para simulações climáticas de alta resolução, com foco em processos regionais, enquanto o MPI-ESM1-2-LR é mais adequado para simulações de longo prazo e estudos de variabilidade climática global. Ambas as versões incluem melhorias na representação de processos oceânicos e atmosféricos (Gutjahr et al., 2019).

O GFDL possui versões como o GFDL-ESM4 e o GFDL-CM4. O GFDL-ESM4 inclui um módulo de sistema terrestre para simular o ciclo do carbono e sua interação com o clima, enquanto o GFDL-CM4 é focado em simulações climáticas de alta resolução, com melhorias na representação de gelo marinho e aerossóis. Essas versões têm sido amplamente utilizadas em projeções climáticas globais e regionais (Dunne et al., 2020; Held et al., 2019).

### 2.3.7 Cenários Climáticos de Modelos Climáticos

Os modelos climáticos do CMIP1 foram forçados com concentrações de GEE's específicas selecionadas para representar um estado de equilíbrio próximo às

condições pré-industriais. Já no CMIP2 e CMIP3, foram utilizados cenários específicos desenvolvidos pelo IPCC, denominados *Special Report on Emissions Scenarios* (SRES), que representam diferentes trajetórias de emissões de GEE e outros forçantes climáticos, baseando-se em pressupostos variados de desenvolvimento humano, tecnologia, população e políticas. Esses cenários dividem-se em quatro famílias principais: A1 (rápido crescimento econômico com emissões atingindo o pico por volta de 2050 e depois diminuindo rapidamente), A2 (desenvolvimento desigual com aumento contínuo das emissões e falta de cooperação global para mitigação), B1 (desenvolvimento sustentável com redução gradual das emissões, resultando em baixas emissões de GEE), e B2 (desenvolvimento regionalizado com foco em sustentabilidade local e conservação de recursos, representando um cenário intermediário entre A1 e B1).

Para o CMIP5, os cenários não foram desenvolvidos pelo IPCC, ao invés disso, o IPCC catalisou o desenvolvimento de novos cenários pela comunidade científica, com a intenção de que os cenários e as pesquisas sustentassem o AR5. Desse modo, foram selecionadas quatro vias de concentrações representativas (RCP's), sendo nomeados, conforme os níveis alvos de forçamento radioativos até 2100, os quatro RCP's selecionados foram considerados representativos da literatura e incluíram um cenário de mitigação levando a um nível de forçamento muito baixo (RCP2.6), dois cenários de estabilização média (RCP4.5/RCP6.0) e um cenário de emissão de linha de base muito alto (RCP8.5). O RCP2.6 é um cenário de mitigação que representa um futuro de baixas emissões; RCP4.5 e RCP6.0 são cenários intermediários que representam um futuro de emissões moderadas; RCP8.5 representa um futuro com altas emissões de GEE, em que as políticas de mitigação são inexistentes (Van Vuuren et al., 2011).

As simulações do CMIP6 foram baseadas nos cenários de Caminhos Socioeconômicos Compartilhados (SSP's), que consistem em cinco trajetórias principais, combinadas com os cenários RCP's. SSP1 - Sustentabilidade (baixos desafios para mitigação e adaptação): o mundo avança rumo a um desenvolvimento sustentável, priorizando inclusão social e limites ambientais. SSP2 - Caminho Intermediário (desafios médios para mitigação e adaptação): segue tendências históricas sem mudanças significativas. SSP3 - Desigualdade Regional (altos desafios para mitigação e adaptação): nacionalismo e conflitos regionais reduzem a cooperação global, com foco em questões domésticas. SSP5 - Desenvolvimento

Movido a Combustíveis Fósseis (altos desafios para mitigação, baixos para adaptação): prioriza crescimento econômico acelerado, inovação tecnológica e dependência de combustíveis fósseis, com forte integração global de mercados (Riahi et al., 2017).

Os cenários de simulação utilizados no CMIP6 combinam os SSP's (Caminhos Socioeconômicos Compartilhados) com os RCPs (Cenários de Concentração Representativa), resultando em quatro trajetórias principais:

- 1) SSP1-2.6 (corresponde ao RCP2.6): Um cenário de mitigação com redução significativa das emissões, resultando em baixos níveis de concentração de gases de efeito estufa (GEE) na atmosfera.
- 2) SSP2-4.5 (corresponde ao RCP4.5): Um cenário em que as emissões aumentam, mas são estabilizadas posteriormente, com concentrações de GEE atingindo o pico em meados do século e diminuindo gradualmente.
- 3) SSP3-7.0 (corresponde ao RCP6.0): Um cenário com emissões relativamente altas ao longo do século XXI, resultando em concentrações atmosféricas de GEE mais elevadas do que no RCP4.5.
- 4) SSP5-8.5 (corresponde RCP8.5): Um cenário de altas emissões, com aumento rápido e contínuo das concentrações de GEE na atmosfera, representando um futuro de alto aquecimento global.

Para analisar as mudanças climáticas com precisão, é necessário adotar um período de referência (*historical*), que serve para caracterizar a sensibilidade da área de estudo ao clima atual. Segundo o IPCC (1992), esse período deve ser representativo do clima médio recente da região e ter duração suficiente para abranger uma variedade de variações climáticas, incluindo eventos extremos, como secas severas ou estações frias. Essa abordagem permite uma avaliação robusta das mudanças climáticas futuras (Calvin et al., 2023).

No AR6, foram apresentadas projeções de mudanças de longo prazo para diversas variáveis climáticas, como a precipitação, em relação ao período de referência (1995-2014). Essas projeções foram representadas em mapas por meio de cores e hachuras (Figura 6). As cores indicam regiões com alta relação sinal-ruído, onde há uma resposta robusta e consistente entre a maioria dos modelos climáticos, tornando as projeções mais confiáveis, tanto na direção (sinal) quanto na magnitude das mudanças. Já as hachuras destacam áreas com baixa relação sinal-ruído, onde

há maior incerteza, pois os modelos podem divergir na direção ou na intensidade das mudanças, refletindo a complexidade e a variabilidade natural do clima. A seleção estratégica de GCM's para estudos de impacto climático é, portanto, um elemento crucial do desenho experimental, considerando também o desempenho dos modelos (McSweeney e Jones, 2016).

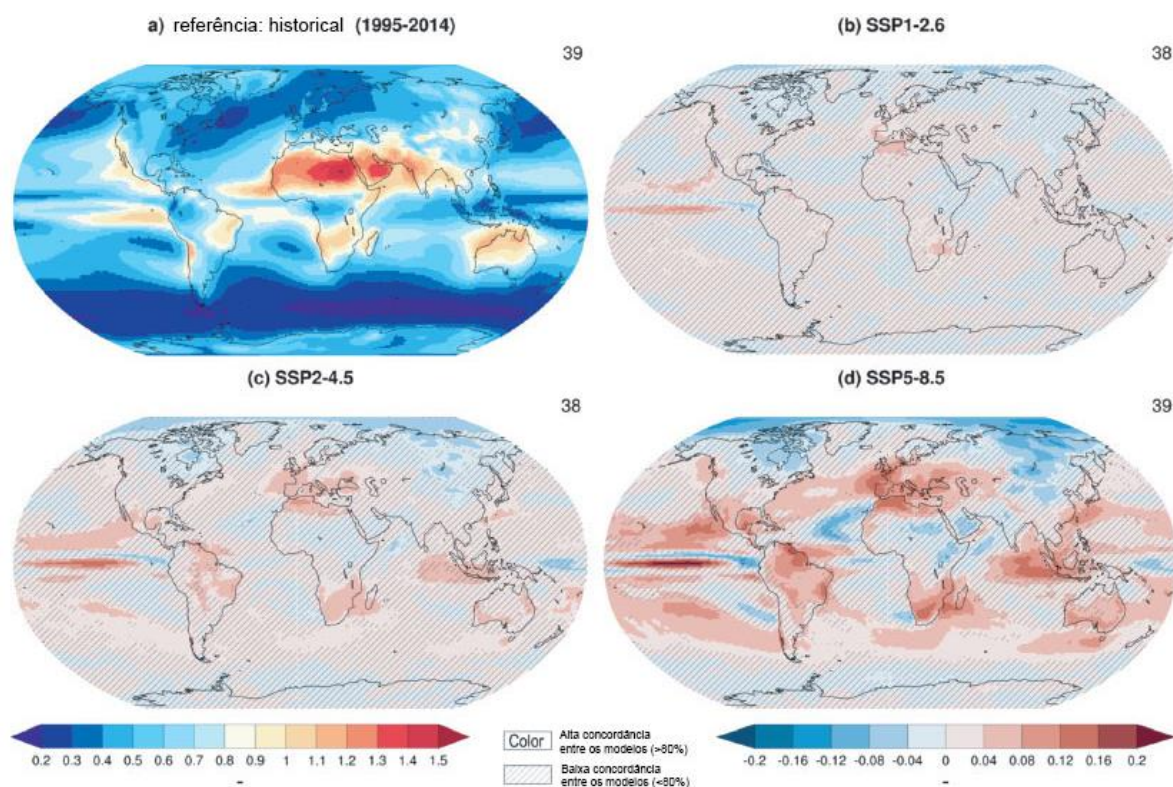


Figura 6: Mudanças projetadas de longo prazo (2081-2100) na sazonalidade da precipitação em média entre os modelos CMIP6 disponíveis (número fornecido no canto superior direito de cada painel) no cenário SSP1-2.6 (b), SSP2-4.5 (c) e SSP5-8.5 (d), respectivamente. A climatologia simulada de 1995–2014 é mostrada no painel (a).

Fonte: Adaptado de AR6

## 2.4 MODELOS HIDROLÓGICOS

Um modelo hidrológico é utilizado para se antecipar aos eventos, por exemplo, avaliando o impacto da urbanização em uma bacia hidrográfica, previsão de enchentes, impacto da alteração do curso de um rio, bem como, ocorrência de eventos extremos estatisticamente possíveis (Tucci, 2005). Yevjevich (1993), ao fazer uma análise das contribuições para a hidrologia no século passado, revelou dois tipos básicos de desenvolvimento. Primeiro, o autor observou o que chamou de “hidrologia utilitária” (também chamada Hidrologia Aplicada ou Hidrologia Técnica), e o surgimento mais recente do que chamou de Hidrologia Teórica (também chamada

Hidrologia Básica, Científica, Analítico-matemática), como sendo os dois polos de todo o espectro hidrológico de atividades e abordagens. O outro tipo de desenvolvimento é a divisão de investigações hidrológicas em Hidrologia Física (determinística) e Hidrologia Estatística (estocástica).

Singh (1995) argumenta que os modelos hidrológicos possuem cinco componentes: geometria do sistema (bacia hidrográfica), entrada, leis governantes, condições de contorno e saída. Esses elementos são combinados de diferentes formas, dependendo do tipo de modelo, permitindo classificá-los como concentrados ou distribuídos, assim como, determinísticos ou estocásticos ou mistos.

Um modelo concentrado é representado por equações que desconsideram a variabilidade espacial de processos, entradas, condições de contorno e características geométricas do sistema (como bacias hidrográficas). Esses modelos combinam equações diferenciais baseadas em leis hidráulicas simplificadas com equações algébricas empíricas. Exemplos de métodos empíricos incluem o SCS-CN (Soil Conservation Service Curve Number, 1954), o SWMM (Storm Water Management Model, 2005) e o HEC-HAS (Hydrologic Engineering Center – Hydraulic Analysis System, 1995). Já os modelos distribuídos consideram explicitamente a variabilidade espacial desses elementos (Singh, 1995). Contudo, a ausência de dados de campo frequentemente limita o desenvolvimento de modelos distribuídos completos. Tucci (2005) destaca que não existem modelos totalmente distribuídos, já que a discretização numérica introduz características de modelos concentrados em subdivisões menores. Exemplos de modelos distribuídos incluem SHE (Système Hydrologique Européen, 1986) e WATFLOOD (Kouwen, 2000; Kouwen et al., 1993).

Em conformidade, modelos determinísticos ignoram a probabilidade, operando com leis definidas. Segundo Dooge (1973), um sistema é determinístico quando, para a mesma entrada, sempre é produzida a mesma saída. Em contraste, um modelo estocástico é aquele que incorpora a probabilidade e considera a chance de ocorrência das variáveis envolvidas no processo (Chow, 1964), isto é, apresenta uma relação estatística entre entrada e saída, sendo dependente de condições iniciais idênticas (Tucci, 2005). Singh (1995) destaca que a maioria dos modelos é determinista, com raros casos de modelos completamente estocásticos. Muitos combinam elementos probabilísticos e determinísticos, podendo ser caracterizados como semi-determinísticos ou semi-estocásticos. Modelos estocásticos têm como

vantagem fornecer aos tomadores de decisão uma estimativa das incertezas nas previsões (Daniel, 2011).

## 2.5 MODELO CHUVA-VAZÃO

Há uma evidente busca por um modelo que represente de maneira satisfatória os fenômenos chuva-vazão, mas que também o faça a partir do menor número de parâmetros. Ao longo da história, houve cerca de 280 modelos chuva-vazão, além de pequenas modificações dos modelos oriundos destes modelos (Peel e McMahon, 2020). A superabundância de modelos chuva-vazão, conforme destacado por Clark et al. (2011), evidencia uma insuficiente compreensão científica da dinâmica ambiental do ciclo hidrológico. Essa lacuna pode ser atribuída às dificuldades inerentes à medição e representação da heterogeneidade presente nos sistemas naturais, que são intrinsecamente complexos e variáveis, de região para região.

Além disso, Saavedra et al. (2022) falam que é preciso identificar as prioridades da modelagem e as limitações da disponibilidade de dados, tempo e orçamento para modelos ajudarem a restringir as escolhas e garantir que o modelo seja o melhor para o propósito pretendido. Os modelos chuva-vazão, por representarem processos hidrológicos, podem ser classificados: quanto aos tipos de dados abordados, sejam eles determinísticos ou estocásticos; quanto à estrutura modelos empíricos, conceituais ou físicos; quanto à variabilidade espacial, modelos concentrados, distribuídos e semi-distribuídos.

Para Melsen et al. (2016), a escolha da estrutura do modelo representa o principal desafio na modelagem chuva-vazão. Os modelos empíricos, de estrutura mais simples, baseiam-se em relações diretas entre entrada e saída, caracterizando uma abordagem de modelagem caixa-preta, que não considera explicitamente os processos internos do sistema. Já os modelos conceituais utilizam equações simplificadas para representar o armazenamento de água na bacia hidrográfica, analisando parcialmente os fluxos hídricos por meio de compartimentos interconectados, o que configura uma modelagem caixa-cinza. Por fim, os modelos físicos, ou caixa-branca, empregam leis e equações físicas baseadas em respostas hidrológicas reais, exigindo uma compreensão detalhada dos processos envolvidos. Cada tipo de estrutura apresenta vantagens e desvantagens, dependendo da finalidade do modelo e do nível de detalhamento desejado (Beven, 2011; Peel e McMahon, 2020).

Segundo Pechlivanidis et al. (2013), a calibração dos parâmetros de qualquer modelo será baseada na qualidade do monitoramento e, portanto, os dados de entrada são importantes. Neste sentido, o aspecto mais desafiador da validação de modelos com dados observados está contido em saber até onde os modelos são confiáveis e o quão bem podem representar o sistema abordado (Andréassian et al., 2004; Fekete et al., 2002). Portanto, os modelos chuva-vazão trazem um conjunto de benefícios para a hidrologia, visto que são adaptáveis à heterogeneidade de cada bacia, demandam poucos dados e são tolerantes a possíveis falhas (Devia et al., 2015).

#### 2.5.1 Método Racional

A primeira descrição formal de um modelo chuva-vazão foi proposta por Mulvaney (1851), um marco na hidrologia que estabeleceu as bases para a modelagem hidrológica. Esse método calcula a vazão máxima ( $Q_{\max}$ ) de pequenas bacias hidrográficas com base na Equação 1.

$$Q_{\max} = C \cdot I \cdot A \quad (1)$$

Em que  $C$  é o coeficiente de escoamento superficial (adimensional), que representa a fração da precipitação que contribui para o escoamento, considerando perdas como infiltração e evapotranspiração;  $I$  é intensidade máxima de precipitação (em mm/h) correspondente ao evento; e  $A$  é a área da bacia hidrográfica (em hectares ou km<sup>2</sup>).

O método racional foi pioneiro por sua simplicidade e aplicabilidade prática, especialmente em projetos de drenagem urbana e no dimensionamento de estruturas hidráulicas. No entanto, suas limitações são evidentes: ele é mais adequado para bacias pequenas e homogêneas, onde o tempo de concentração é relativamente curto, e não considera a variabilidade temporal e espacial da precipitação ou a complexidade dos processos hidrológicos.

#### 2.5.2 Hidrograma Unitário

Outro modelo matemático, que inspirou diversas outras modificações, é o hidrograma unitário de Sherman (1932), que utiliza a chuva efetiva unitária de 1mm, com intensidade constante no tempo e uniformemente distribuída no espaço e sobre a bacia hidrográfica (Figura 7).

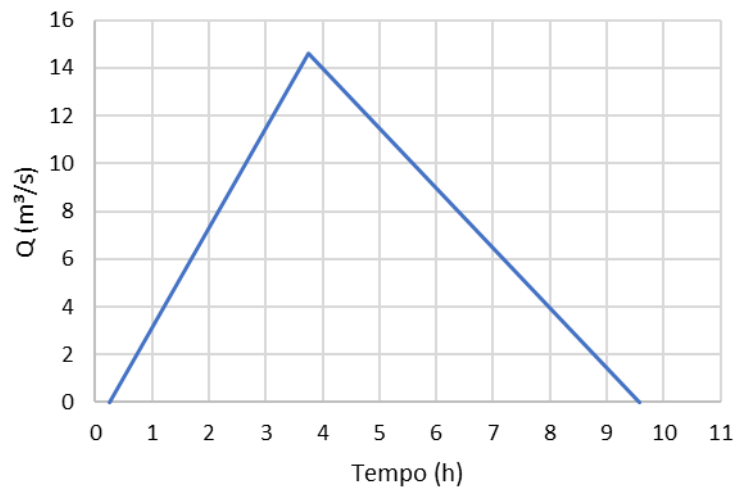


Figura 7: Hidrograma unitário triangular

Considerando a bacia hidrográfica como um sistema linear e invariante no tempo, é possível aplicar os princípios da proporcionalidade e da superposição. O princípio da proporcionalidade estabelece que o hidrograma resultante de uma chuva efetiva com determinada duração é diretamente proporcional à sua intensidade. Portanto, é possível calcular a resposta da bacia hidrográfica a eventos de chuvas diferentes, pois a resposta é uma soma das respostas individuais (superposição). Se o sistema é linear e invariante (bacia hidrográfica), as vazões  $y(t)$  são representadas pela convolução entre a chuva  $x(t)$  e a função de transferência ou a função da resposta impulsional,  $h(u)$ , dada pela Equação 2.

$$y(t) = \int_0^t h(u)x(t-u)du \quad (2)$$

Outros modelos que descrevem a relação chuva-vazão têm sido amplamente discutidos na literatura desde que Sherman (1932) introduziu o conceito do hidrograma unitário. Entre as contribuições, destacam-se os trabalhos de (Rodriguez, 1967), Papazafiriou (1976), Goring (1984), Labat et al. (2000) e Blanco et al. (2005). Nesses modelos, as hipóteses de linearidade e invariância no tempo (Equação 2), são justificadas pelas pequenas dimensões das bacias analisadas. Então, aplica-se a convolução aos dados de entrada  $x(t)$  e à resposta impulsional do sistema  $h(t)$ , resultando nos dados de saída  $y(t)$ . No contexto dos sistemas hidrológicos, a entrada é representada pela precipitação  $P$  (mm) e a saída pela vazão  $Q$  (m³/s), que é expressa pela forma discreta da integral de convolução, conforme a Equação 3.

$$Q_i = \sum_{j=1}^m h_j P_{i-j+1}, \text{ com } i = 1, 2, 3 \dots n + m + 1 \quad (3)$$

onde  $m$  é o comprimento da memória do sistema que representa o efeito de uma chuva continua que se estende por  $m$  intervalos de duração  $T$ .

## 2.6 REDES NEURAIS ARTIFICIAIS

Nesta Seção são discutidos os conceitos básicos sobre neurônio biológico e artificial, o funcionamento das redes neurais, incluindo as fases de treinamento e ativação. Ademais, a descrição de redes do tipo Autorregressiva Não Linear com Entradas Exógenas (NARX) é apresentada.

### 2.6.1 Breve Histórico

As primeiras pesquisas para o desenvolvimento de computadores baseados no comportamento no cérebro humano datam de 1943, quando McCulloch e Pitts publicaram o primeiro estudo descrevendo as redes neurais, unificando os estudos de neurofisiologia e lógica matemática e apresentaram um modelo matemático baseado nos neurônios biológicos (McCulloch & Pitts, 1943).

Em 1949, a publicação do livro *The Organization of Behavior* de Hebb representou um marco importante para o estudo das redes neurais. Nele, Hebb introduziu pela primeira vez uma regra de aprendizagem para a modificação sináptica em neurônios biológicos. Segundo Hebb (1949), a conectividade cerebral é continuamente ajustada à medida que um organismo aprende tarefas funcionais. Ele propôs que a eficiência de uma sinapse entre dois neurônios aumenta com a ativação simultânea desses neurônios, e quanto maior a correlação entre suas atividades, mais forte se torna a conexão entre eles (Haykin, 2009). Essa ideia, conhecida como Lei de Hebb, tornou-se fundamental para a compreensão dos mecanismos de aprendizagem aplicadas às RNAs, permitindo a adaptação e o aprimoramento contínuo desses sistemas (Yadav et al., 2015).

O primeiro modelo computacionalmente prático, conhecido como Perceptron, foi introduzido por Rosenblatt (1958). Ele representa a forma mais simples de uma rede neural artificial, composta por um único neurônio artificial capaz de realizar tarefas básicas de classificação. O Perceptron combina o modelo teórico de McCulloch e Pitts (1943) com as percepções biológicas, resultando na primeira rede neural artificial projetada para classificar padrões linearmente separáveis por meio de aprendizagem supervisionada.

Em 1969, surgiu o livro dos pesquisadores Minsky e Papert criticando o perceptron, demonstrando matematicamente que os perceptrons de uma única camada tinham limitações fundamentais. Isso resultou em um declínio no interesse por redes neurais artificiais (Arbib, 1969). Apenas na década de 80 as redes neurais ressurgiram com o modelo de rede perceptron de múltiplas camadas. Esse novo modelo utiliza um algoritmo chamado backpropagation (ou retropropagação), com aprendizagem supervisionada, que resolveu em grande parte os problemas levantados por Minsky e Papert (1969). (Rumelhart et al., 1986) foram responsáveis por avanços significativos, demonstrando a eficácia do backpropagation para resolver problemas de aprendizagem e popularizando seu uso em redes neurais.

### 2.6.2 Conceitos Básicos

As Redes Neurais Artificiais (RNAs) fazem parte do conjunto de técnicas de aprendizado de máquina (AM), uma subcategoria da inteligência artificial (IA), uma forma de estatística aplicada. As RNA's são sistemas paralelos distribuídos, compostos por neurônios ou unidades de processamento, que computam determinadas funções matemáticas (normalmente não-lineares). Tais neurônios de processamento podem ser distribuídos em uma ou mais camadas e interligados por um grande número de conexões (pesos sinápticos), os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede (Haykin, 2009).

O cérebro humano possui cerca de 100 bilhões de neurônios biológicos, sua célula fundamental. Cada um destes neurônios processa e se comunica com milhares de outros continuamente e em paralelo (Braga et al., 2000). Os neurônios possuem um papel essencial na determinação do funcionamento e comportamento do corpo humano, os quais são divididos em três seções: o corpo da célula; os dendritos, que (terminais de entrada) e; pelos axônios (terminais de saída). As entradas são formadas através das conexões sinápticas que conectam os dendritos aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos como impulsos nervosos e constituem a informação que o neurônio processa para produzir como saída um impulso nervoso no seu axônio (Kovacs, 2002).

O modelo de neurônio artificial proposto por McCulloch e Pitts (1943), interpreta o funcionamento do neurônio biológico como um circuito binário simples que combina

várias entradas e apenas um sinal de saída. Sua descrição matemática resultou em um modelo com  $n$  terminais de entrada representando os dendritos, e apenas uma saída simulando o axônio.

Nesse contexto, o algoritmo de RNAs opera por meio de nós interconectados, onde cada nó funciona como um neurônio artificial capaz de processar e transmitir sinais de entrada. Esses sinais são multiplicados por pesos sinápticos  $w_{kn}$ , que refletem a importância relativa de cada entrada  $x_i$ , e somados a um parâmetro bias  $b_k$ . O resultado dessa soma é processado por uma função de ativação  $f(a)$ , que determina a saída  $y_n$ . Um neurônio típico é representado pela Figura 8.

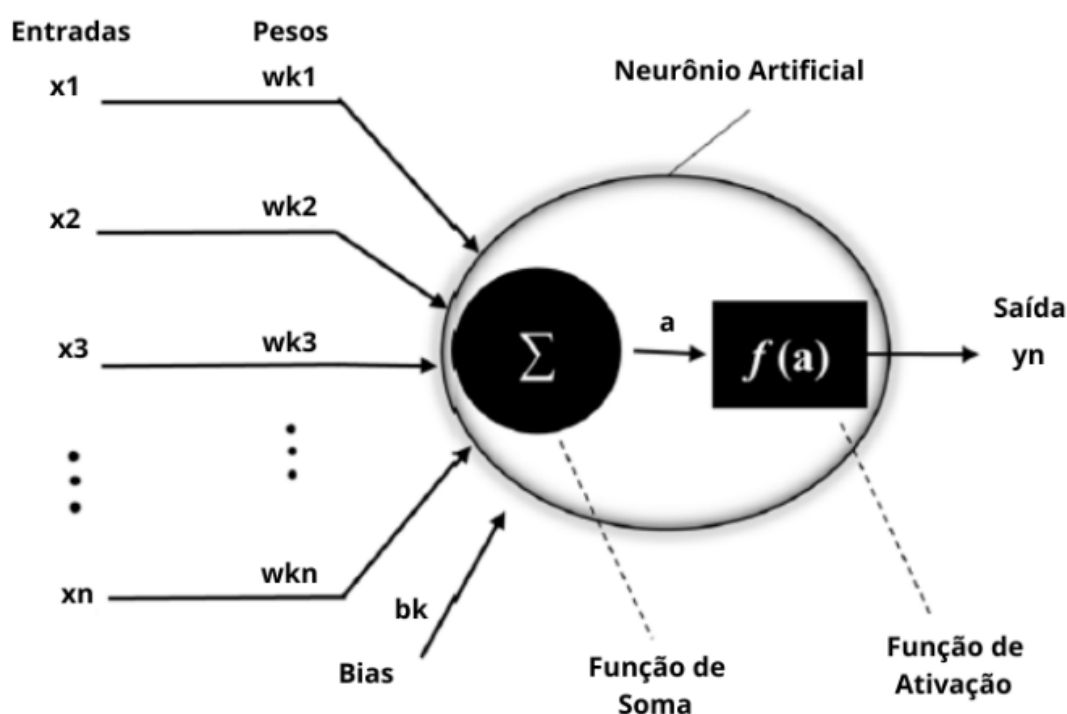


Figura 8: Representação esquemática do modelo matemático de um neurônio artificial

Fonte: Ali e Shahbaz (2020)

As diversas arquiteturas de redes neurais podem ser formadas pela combinação de neurônios artificiais e são definidas pelo tipo de conexão entre as redes. Cada neurônio transfere o seu sinal apenas para os neurônios que se encontram em uma das camadas subsequentes. Haykin (2009) relata três tipos de camadas:

- Camada de entrada: onde os padrões são apresentados à rede.

- Camadas ocultas (ou intermediárias): trabalham como um reconhecedor de características que ficam armazenadas nos pesos sinápticos e são responsáveis pela maior parte do processamento e não tem ligação direta com o usuário externo.
- Camada de saída: onde os sinais de saída da rede são apresentados.

As RNAs também são conhecidas como modelos caixa-preta, que podem aproximar a saída ajustando de forma inteligente seus parâmetros internos. Dessa forma, a relação entre entrada e saída é parametrizada no projeto estrutural do modelo e a RNA pode fazer uma previsão de saída com base em novas entradas não conhecidas (Abdulkadir et al., 2013).

### 2.6.3 Perceptron de Múltiplas Camadas

A arquitetura clássica, conhecida como Perceptron de Múltiplas Camadas (MLP, do inglês Multilayer Perceptron) surgiu como alternativa para modelar relações não-lineares complexas, através do seu treinamento supervisionado usando o algoritmo de retropropagação de erro. Bem como, a partir do uso de funções de ativação não-lineares, como a função sigmoide (Hornik et al., 1989).

Isto é, os sinais de entrada são propagados camada por camada, até que o vetor de saída seja obtido na última camada. O processo de aprendizado termina quando o erro desejado é atingido ou quando se atinge um número máximo de épocas de aprendizado (Haykin, 2009).

Uma das principais limitações do MLP é a necessidade de definir heurísticamente o número de camadas ocultas e de neurônios em cada camada, o que pode resultar em estruturas hiperparametrizadas e computacionalmente custosas (Zhang e Morris, 1998).

### 2.6.4 Redes Neurais Profundas e Convolucionais

As DNNs (Redes Neurais Profundas) são redes neurais com múltiplas camadas ocultas entre a entrada e a saída. Elas são capazes de aprender representações hierárquicas dos dados, onde cada camada extrai características cada vez mais abstratas e complexas (Grünig et al., 2021).

As CNNs (Redes Neurais Convolucionais) são especializadas em processar dados com estrutura de grade, como imagens. Elas utilizam operações de convolução para extrair características locais (como bordas, texturas e padrões) e pooling para

reduzir a dimensionalidade dos dados, preservando as informações mais importantes (Kattenborn et al., 2021). Entretanto, as CNN's e DNN's têm dificuldades com as informações temporais nos dados de entrada, que precisem de informações sequenciais.

#### 2.6.5 Redes Neurais Recorrentes

Para uma rede neural ser considerada dinâmica é necessário possuir memória (Elman, 1990). Existem duas maneiras de fornecer memória a uma rede neural. A primeira forma é utilizar atraso no tempo, tais como as técnicas de *Time Delay Neural Network* (TDNN) e *Finite Impulse Response Multilayer Perceptron* (FIRMLP). A segunda forma, consiste na utilização de redes neurais recorrentes, tais como *Backpropagation Through Time* (ou retropropagação ao longo do tempo) (Braga et al., 2000). Neste contexto, o estudo adota as RNN's como ferramenta principal para explorar padrões dinâmicos e dependências temporais nos dados, o que as torna adequadas para tarefas como previsão.

Redes recorrentes são definidas como aquelas que possuem conexões de realimentação que proporcionam um comportamento dinâmico (Figura 9). Diferentemente da arquitetura clássica, como MLP ou redes neurais profundas (DNN), as Redes Neurais Recorrentes (RNN) são projetadas para processar dados com estrutura temporal ou sequencial (Waqas e Humphries, 2024; Yu et al., 2022), como séries temporais, texto, áudio e vídeo (Yu, Antonio e Villalba-Mora, 2022), incluindo a modelagem hidrológica (Guzman et al., 2017; Mendonça et al., 2021; Menezes e Barreto, 2008; Wang e Chen, 2022).

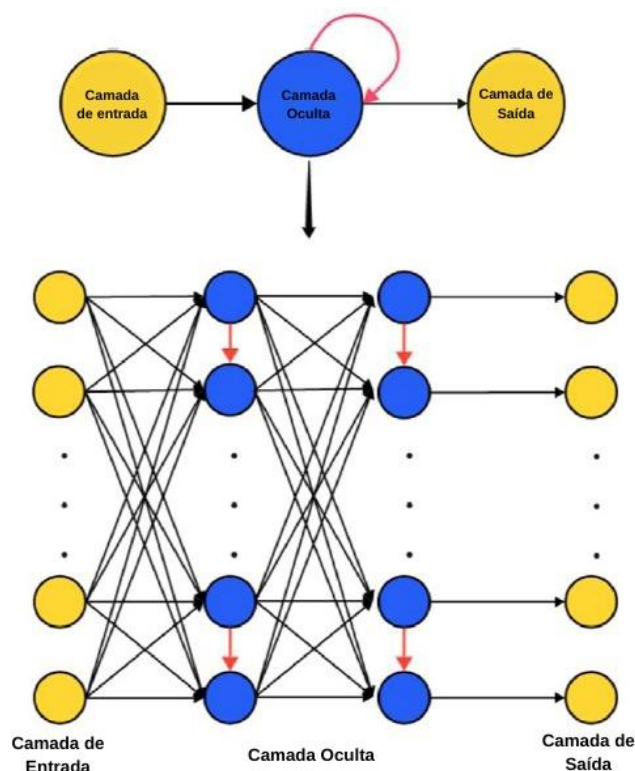


Figura 9: Arquitetura de uma RNN, com múltiplas camadas ocultas (i.e., aprendizado profundo)

Fonte: Waqas e Humphries (2024)

#### 2.6.6 Rede Recorrente NARX

A abordagem Autorregressiva Não Linear com Entradas Exógenas (NARX) é uma arquitetura da rede recorrente, que possuem conexões de realimentação do valor resultante do neurônio de saída diretamente para a camada de entrada. Bem como encontrado em outras RNAs, as NARXs também são divididas em camadas de entrada, oculta e de saída (Wang e Chen, 2022). Assim, a rede recorrente NARX (RNN-NARX) é baseada no modelo linear autorregressivo, que é comumente utilizado na modelagem de séries temporais (Izady et al., 2013). Além disso, a mesma tem melhor habilidade de generalização que outras arquiteturas recorrentes (Lin, Horne e Giles, 1998).

Dois modos de operação na RNN-NARX são importantes e úteis na modelagem. Primeiro, no modo Open Loop, os valores observados (target) são implementados manualmente na camada de entrada de uma feedforward padrão. Segundo, no modo Closed Loop, é possível considerar o valor estimado de saída do modelo (output), realimentando diretamente na camada de entrada (Menezes e Barreto, 2008), como pode ser observado na Figura 10.

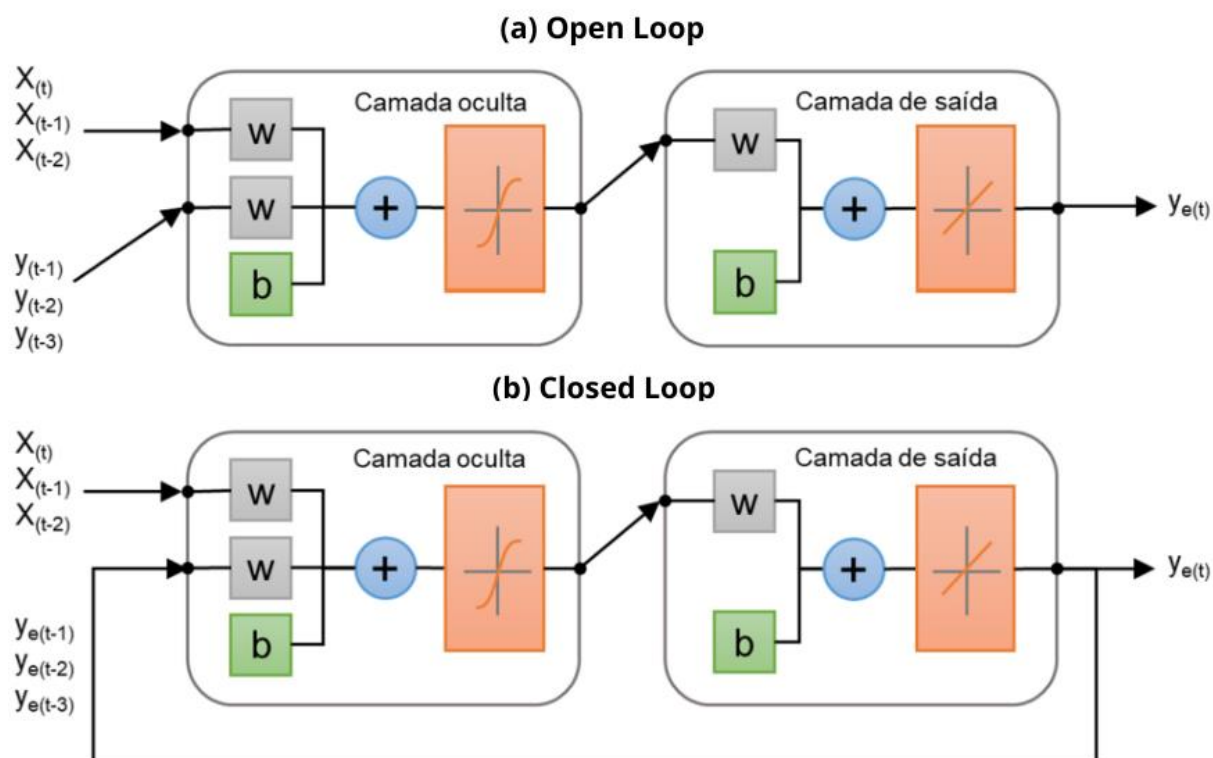


Figura 10: Modo de operação NARX Open Loop (a) e; Closed Loop (b)  
Fonte: Mendonça (2022)

Debastiani, Silva e Neto (2016) simularam as vazões diárias em uma sub-bacia hidrográfica do rio Canoas, Estado de Santa Catarina, Brasil, elaborando uma rede recorrente NARX. A bacia possui 1.980 km<sup>2</sup>, está bem preservada em termos ambientais e é considerada importante zona de recarga do Aquífero Guarani. Foram utilizadas a precipitação e evapotranspiração de quatro estações meteorológicas, duas inseridas na bacia e duas próximas. Após o treinamento em série-paralelo, o modelo foi convertido para paralelo, a fim de simular um ano de vazões diárias. Os autores exaltaram o potencial da arquitetura, alcançando resultados significativos.

Mendonça et al. (2021) aplicaram a NARX em uma sub-bacia do rio Guamá, no Estado do Pará, Brasil, que apresenta área de contribuição de 5.032 km<sup>2</sup>. A área de estudo é marcada pela agropecuária e presença de comunidades tradicionais. Foram utilizadas precipitações diárias de quatro estações pluviométricas em torno da bacia, para simular vazões diárias. Os resultados mostraram um coeficiente de determinação de 0,99 e baixos erros de simulação. Os autores destacaram, conceitualmente, a relação entre o potencial autorregressivo, que é favorecido em bacias planas, e que, conseqüentemente, favorece a infiltração de águas pluviais.

### 2.6.7 Função de Ativação

A função de ativação  $f(a)$ , componente de um neurônio artificial, é responsável por determinar a saída de cada neurônio com base em sua entrada ponderada  $a$ , onde  $a = \sum_i w_k x_i + b_k$  ( $w_k$  são os pesos,  $x_i$  são as entradas e  $b_k$  é o bias). A função  $f(a)$  transforma a entrada ponderada em uma saída que será propagada para os neurônios subsequentes. A escolha da função de ativação tem um impacto direto na capacidade da rede neural de aprender os padrões dos dados de entrada (Abu Yazid et al., 2018). A função de ativação degrau, também conhecida como *hard-limiter* é uma das funções de ativação mais simples e antigas utilizadas em redes neurais (Equação 4). Essa função produz uma saída binária, onde o neurônio "dispara" (saída 1) se a entrada ponderada ultrapassa um determinado limiar, caso contrário, a saída é 0. A função degrau foi amplamente utilizada em modelos pioneiros, como o perceptron de Rosenblatt, mas sua natureza discreta e não diferenciável limita sua aplicação em redes neurais modernas, que dependem de gradientes para o treinamento via *Backpropagation* (Rosenblatt, 1958).

$$f(a) = \begin{cases} 1 & \text{se } a \geq 0 \\ 0 & \text{se } a < 0 \end{cases} \quad (4)$$

Outrossim, a função  $f(a)$  pode ser linear ou não linear, e sua definição determina como o neurônio responde aos estímulos de entrada. Quando  $f(a)$  é uma função linear (também conhecida como *purelin*), a saída do neurônio é diretamente proporcional à sua entrada ponderada (Equação 5). Esta função geralmente está associada à camada de saída das RNAs, pois podem assumir qualquer valor, tanto positivos quanto negativos (Haykin, 2009).

$$f(a) = a \quad (5)$$

Quando  $f(a)$  não é uma função linear, como é o caso da função de ativação log-sigmóide (*logsig*),  $f(a)$  mapeia a entrada  $a$  para um valor no intervalo (0,1), sendo amplamente utilizada em problemas de classificação binária (Ghose et al., 2018), conforme a Equação 6.

$$f(a) = \frac{1}{1 + e^{-a}} \quad (6)$$

A função tangente hiperbólica (*tanh*) é similar à sigmoid, mas mapeia a entrada para o intervalo de -1 a 1 (Equação 7), o que pode acelerar a convergência em alguns casos (Ghose et al., 2018).

$$f(a) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (7)$$

### 2.6.8 Treinamento: Algoritmo de Retropropagação do Erro

O processo de treinamento de RNAs consiste em ajustar os pesos sinápticos das RNAs, de tal modo que as entradas  $x_n$  convirjam para o valor mais próximo à saída desejada  $y_n$ , ou seja, com o menor erro possível. De modo geral, estes algoritmos podem ser classificados em treinamentos não supervisionados, aprendizado por reforço e supervisionados (Haykin, 2009; Yadav et al., 2015).

O algoritmo de retropropagação (em inglês, backpropagation) Levenberg-Marquardt é um algoritmo de aprendizado supervisionado, baseado no processo de aprendizado por correção de erros (Farber, 2011). Neste algoritmo, que opera em função do erro quadrático médio (MSE), os pesos são modificados através da matriz Hessiana aproximada, oriunda da matriz Jacobiana transposta (Sahoo e Jha, 2013), conforme expresso na Equação 8.

$$w_{(k+1)} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (8)$$

Onde  $w_k$  é o peso sináptico,  $J_k^T J_k$ , representando a matriz Hessiana aproximada,  $e_k$  é o erro quadrático associado a cada iteração,  $J_k$  é a matriz Jacobiana,  $I$  é a matriz identidade e  $\mu$  é a constante de aprendizado.

## 2.7 TRANSFORMAÇÕES ESTATÍSTICAS

As transformações estatísticas tentam encontrar uma função  $h$  que mapeia uma variável modelada ( $X_{mod}$ ) de modo que sua nova distribuição seja igual à distribuição da variável observada ( $X_o$ ). Segundo Piani et al. (2010), essa transformação pode, em geral, ser expressa pela Equação 9.

$$X_o = h(X_{mod}) \quad (9)$$

As transformações estatísticas são uma aplicação da transformação integral de probabilidade (Angus, 1994) e se a distribuição da variável de interesse for conhecida, a transformação é definida pela Equação 10.

$$X_o = F_o^{-1}(F_{mod}(X_{mod})) \quad (10)$$

Onde  $F_{mod}$  é a CDF de  $X_{mod}$  e;  $F_o^{-1}$  a inversa da CDF (ou a função quantil) de  $X_o$ . A Figura 11 ilustra transformações estatísticas para saída modelada usando precipitação diária observada. À esquerda tem-se o gráfico quantil-quantil da

precipitação observada e simulada, bem como o melhor ajuste de uma função arbitrária  $h$  que é usada para aproximar a transformação. À direita tem-se o CDF empírico correspondente de valores observados e simulados, bem como os valores simulados transformados. O desafio prático é encontrar uma aproximação adequada para  $h$  e diferentes abordagens são sugeridas nos subtópicos a seguir.

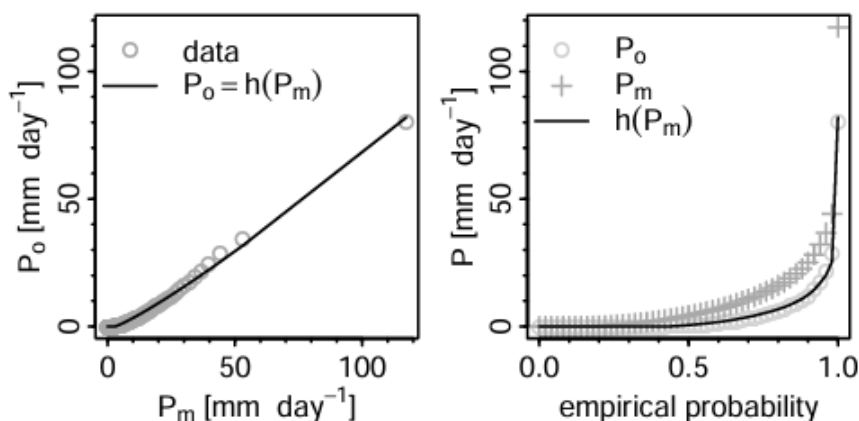


Figura 11: Esquerda: gráfico quantil-quantil da precipitação observada ( $P_o$ ) e projetada ( $P_m$ ), bem como uma transformação ( $P_o = h(P_m)$ ) que é usada para mapear os quantis projetados nos observados. Direita: CDF empírica da precipitação observada, projetada e transformada ( $h(P_m)$ ).

Fonte: Gudmundsson et al. (2012)

### 2.7.1 Transformações derivadas de distribuição

As distribuições estatísticas podem ser usadas para resolver a Equação 10. Esse método estima os quantis da distribuição de probabilidade dos dados, que são valores que dividem os dados em intervalos com probabilidades iguais. Por exemplo, o quantil 0,9 indica que 90% dos dados estão abaixo dele. A distribuição estatística descreve a probabilidade de ocorrência dos valores em um conjunto de dados (ex., distribuição exponencial, Gama, Weibull, etc.). Esta abordagem já foi amplamente aplicada para ajustar variáveis modeladas (Li et al., 2010; Piani et al., 2010; Teutschbein e Seibert, 2012). A maioria desses estudos assume que  $F$  é uma mistura da distribuição de Bernoulli e Gama, onde a distribuição de Bernoulli é usada para modelar a probabilidade de ocorrência e a distribuição Gamma é usada para modelar intensidades de variáveis (Cannon, 2012).

### 2.7.2 Transformações paramétricas

A relação quantil-quantil (vide Figura 11) pode ser modelada diretamente usando transformações paramétricas. Assim, a adequação das seguintes transformações paramétricas podem ser expressam da Equação 11 a Equação 15.

$$\hat{X}_o = b(F_{mod}) \quad (11)$$

$$\hat{X}_o = a + bF_{mod} \quad (12)$$

$$\hat{X}_o = bF_{mod}^c \quad (13)$$

$$\hat{X}_o = b(F_{mod} - x)^c \quad (14)$$

$$\hat{X}_o = (a + bF_{mod}) \left(1 - e^{-\frac{F_{mod}-x}{\tau}}\right) \quad (15)$$

Onde,  $\hat{X}_o$  indica a melhor estimativa de  $X_o$ ;  $a$ ,  $b$ ,  $c$ ,  $x$  e  $t$  são parâmetros livres que estão sujeitos à calibração. A escala simples (Equação 11) é regularmente usada para ajustar a precipitação projetada por modelos do CMIP (Maraun et al., 2010). As transformações da Equação 12 para a Equação 15 foram todas usadas por Piani et al. (2010) para corrigir a precipitação, para dias úmidos ( $X_o > 0$ ) minimizando a soma residual dos quadrados. Os valores modelados correspondentes à parte seca da CDF empírica observada foram definidos como zero em seu estudo.

### 2.7.3 Transformações não-paramétricas

#### 2.7.3.1 Suavização de splines (SSPLIN)

A transformação (Equação 9) também pode ser modelada usando regressão não paramétrica mediante *splines* de suavização cúbica (Hastie et al., 2001). A *spline* de suavização é ajustada apenas à fração da CDF correspondente aos dias observados e valores modelados acima de zero. Isso impõe uma restrição ao método, como é o caso da precipitação diária, que frequentemente apresentam lacuna (dias sem chuva) ou valores zerados na série temporal. O parâmetro de suavização da *spline* é identificado por meio de validação cruzada generalizada. A validação cruzada generalizada é uma técnica robusta para selecionar parâmetros de modelos, evitando o overfitting.

#### 2.7.3.2 Empirical Quantile Mapping (EQM)

Uma abordagem comum para resolver a Equação 10 é o método dos quantis, que se baseia na utilização de quantis da distribuição de probabilidade para alinhá-las à distribuição das observações, proporcionando uma solução flexível para as variáveis hidroclimatológicas. Assim, utiliza-se a CDF empírica de valores observados e modelados em vez de assumir distribuições paramétricas (Reichle e Koster, 2004; Themeßl et al., 2012). Seguindo o procedimento de Boé et al. (2007), as CDF's empíricas são aproximadas usando quantis empíricos. Valores entre os quantis são

aproximados usando interpolação linear. A eficácia desse método varia conforme o contexto. Usman et al. (2022), por exemplo, aplicaram o EQM para corrigir precipitação e temperatura diários em projeções climáticas na Bacia do Rio Chitral, no Paquistão. Ao usar esses dados corrigidos em um modelo hidrológico, os resultados mostraram que o método não trouxe melhorias significativas nas simulações de vazão, tanto para regimes médios quanto extremos. Por outro lado, no estudo de Bum Kim et al. (2021), no qual diferentes métodos de correção foram testados em curvas de duração de vazão, destaca-se a aplicação do EQM para reduzir os erros sistemáticos da simulação e ajustar a variabilidade para valores mais próximos dos observados. Isso sugere que as vantagens no uso do EQM, depende das variáveis e objetivos do estudo.

Com base no descrito nesta seção, a escolha de um desses métodos depende das características dos dados, escala temporal e do contexto de aplicação da transformação estatística (Gudmundsson et al., 2012; Themeßl et al., 2012).

## 2.8 ANÁLISE DE TENDÊNCIA

A compreensão da variabilidade e tendências climáticas permite identificar padrões temporais em séries históricas de dados, como temperatura, precipitação, umidade do solo e vazão de rios. Essa abordagem contribui para a avaliação de mudanças no clima e na disponibilidade hídrica (Marengo et al., 2018). O interesse pela análise de tendências em variáveis climáticas e hidrológicas intensificou-se a partir da segunda metade do século XX, impulsionado por estudos como os do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), que evidenciaram o aquecimento global e seus impactos (IPCC, 2021). Para identificar padrões temporais, métodos estatísticos robustos têm sido amplamente empregados.

Os testes estatísticos podem ser classificados em paramétricos e não paramétricos (Naghetini e Pinto, 2007). Os testes paramétricos se baseiam na hipótese de que os dados amostrais foram obtidos a partir de uma população cuja distribuição seja conhecida ou previamente especificada. Já os testes não-paramétricos não necessitam da especificação do modelo distributivo da população, pois são formulados com base nas características da amostra. A utilização de testes paramétricos e não-paramétricos depende das características dos dados (Xu et al., 2003).

### 2.8.1 Média Móvel e Mediana Móvel

A média e a mediana são medidas de tendência central (Walpole et al., 2016). Porém, a média móvel é um indicador estatístico que calcula a média dos valores dentro de uma janela deslizante ao longo do tempo. Esse método reduz a volatilidade dos dados e facilita a identificação de tendências. Matematicamente, a média móvel simples (MMS) é dada pela Equação 16, considerando uma amostra com os elementos  $x_1+x_2+\dots+x_n$ , sendo  $n$  o tamanho da amostra.

$$MMS_t = \frac{1}{n} \sum_{i=t-n+1}^t x_i \quad (16)$$

Onde  $MMS_t$  é a média móvel no instante  $t$ ;  $x_i$  são os valores individuais da série temporal; e  $n$  é o tamanho da amostra. Existem também variações como a média móvel ponderada, que atribui pesos diferentes para cada dado dentro da janela amostral. Diferentemente da média, a mediana móvel é uma alternativa à média móvel, sendo especialmente útil quando os dados contêm outliers ou valores extremos que podem distorcer a análise. Em vez de calcular a média dos valores dentro da janela de observação, a mediana móvel ordena os valores e seleciona o valor central. Assim, supondo que dos dados da amostra sejam  $x_1+x_2+\dots+x_n$  arranjados em ordem crescente de magnitude, e  $n$  o tamanho da amostra, a mediana da amostra será representada pela Equação 17 (Walpole et al., 2016).

$$\tilde{x} = \begin{cases} \frac{x_{(n+1)}}{2} & \text{se } n \text{ for ímpar} \\ \frac{1}{2}(x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & \text{se } n \text{ for par} \end{cases} \quad (17)$$

Tanto a média móvel quanto a mediana móvel são amplamente utilizadas em diversas áreas, incluindo finanças, economia, ciência de dados e meteorologia (Costa et al., 2023; Silva et al., 2018).

### 2.8.2 Regressão Linear

A regressão linear é obtida estimando-se os valores dos coeficientes de intercepto ( $\beta_0$ ) e inclinação ( $\beta_1$ ) através de alguma técnica de ajustamento (Helsel et al., 2020). Segundo Naghettini e Pinto (2007), o método dos mínimos quadrados é um dos procedimentos mais adequados para este ajuste. Assim, o modelo de regressão linear é dado pela Equação 18, considerando  $i=1, 2, 3, \dots, n$ .

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (18)$$

Onde  $y_i$  é a  $i$ -ésima observação da variável dependente;  $x_i$  é a  $i$ -ésima observação da variável independente;  $\beta_0$  é o coeficiente de intercepto;  $\beta_1$  é o

coeficiente de inclinação;  $\varepsilon_i$  é o erro aleatório ou residual para a  $i$ -ésima observação;  $n$  é o tamanho da amostra. O erro residual depende da variabilidade natural do sistema, possui média igual a zero e variância ( $\sigma^2$ ) constante, portanto,  $\varepsilon_i$  é independente de  $x_i$ .

### 2.8.3 Spearman Rho

O teste Spearman Rho (SR) é um teste não-paramétrico, semelhante ao Mann-Kendall, com potência uniforme para tendências lineares e não lineares. Esse método é comumente utilizado para verificar tendências em séries temporais (Gauthier, 2001). Neste teste, a hipótese nula, de ausência de tendência ( $H_0$ ), ocorre quando todos os dados da série temporal são independentes e identicamente distribuídos, enquanto a hipótese alternativa, com tendência ( $H_1$ ), existe quando há um aumento ou a diminuição tendências (Yue et al., 2002). A estatística  $D$  e o teste  $Z_{SR}$  são expressos pelas Equações 19 e 20.

$$D = 1 - \frac{6 \sum_{i=1}^n (R_i - i)^2}{n(n^2 - 1)} \quad (19)$$

$$Z_{SR} = D \sqrt{\frac{n-2}{1-D^2}} \quad (20)$$

Onde  $R_i$  é o ranking da precipitação medida no intervalo  $i$  e  $n$  é o tamanho da amostra. Os valores positivos de  $Z_{SR}$  indicam tendências crescentes, enquanto  $Z_{SR}$  negativo indica tendências negativas nas séries temporais. Quando  $|Z_{SR}| > t_{(n-2, 1-\alpha/2)}$ , a hipótese nula é rejeitada e uma tendência significativa existe na série temporal. O parâmetro  $t_{(n-2, 1-\alpha/2)}$  é o valor crítico de  $t$  a partir da tabela t-student, para o nível significativo de 5%.

### 2.8.4 Mann-Kendall

O teste de tendência de Man-Kendall (Mann, 1945; Kendall, 1975) é um dos mais utilizados na avaliação de tendências de séries históricas naturais que se distanciam da distribuição normal, como vazões, temperatura e precipitação (Hamed, 2009). A hipótese nula ( $H_0$ ) assume que a série é constante, sem variações significativas ao longo do tempo, mantendo a distribuição de probabilidade inalterada. Já a hipótese alternativa ( $H_1$ ) sugere a presença de uma tendência monotônica (crescente ou decrescente), indicando mudanças significativas na série temporal (Xu et al., 2003).

Na aplicação do teste, para uma dada série temporal  $X_t$ , composta por  $n$  termos, avalia-se a presença de tendências comparando a ordem relativa dos valores ao longo do tempo. Em vez de analisar os valores absolutos, o teste se baseia na contagem de concordâncias e discordâncias entre pares de observações. Isso significa que, para cada par de pontos na série temporal, verifica-se aumento ou diminuição relativa entre eles. A partir dessa análise, calcula-se o coeficiente de Kendall Tau (S), que quantifica a força e a direção da tendência. Além disso, o teste fornece um p-valor, que indica a significância estatística da tendência observada.

O valor de Kendall Tau, também conhecido como coeficiente de concordância de Kendall, é uma medida estatística de correlação usada para avaliar a associação entre duas variáveis classificadas. Ele quantifica a concordância ou discordância entre as classificações das duas variáveis, independentemente dos valores exatos das classificações. O coeficiente de Kendall Tau varia de -1 a +1, sendo:

- a) Se Tau for próximo de +1, indica uma forte concordância entre as classificações das duas variáveis;
- b) Se Tau for próximo de -1, indica uma forte discordância entre as classificações das duas variáveis;
- c) Se Tau for próximo de 0, indica uma ausência de associação linear entre as duas variáveis classificadas.

O p-valor de Kendall é uma medida estatística usada em conjunto com o coeficiente de concordância de Kendall (Tau) para determinar se a relação observada entre duas variáveis classificadas é estatisticamente significativa. O p-valor indica a probabilidade de observar uma associação tão forte (ou mais forte) entre as variáveis, assumindo que não haja associação real na população. Se o p-valor for menor que um determinado nível de significância (geralmente 0,05), então há evidências estatísticas para rejeitar a hipótese nula de que não há associação entre as variáveis. Ou seja, a associação observada entre as variáveis é improvável de ocorrer apenas por acaso. Por outro lado, se o p-valor for maior que o nível de significância escolhido, então não há evidências suficientes para rejeitar a hipótese nula e se conclui que não há uma associação estatisticamente significativa entre as variáveis. Em resumo, o p-valor de Kendall ajuda a determinar se a relação entre as variáveis classificadas é estatisticamente significativa ou se ocorreu por acaso.

Além disso, embora o teste de Mann-Kendall permita detectar tendências estatisticamente significativas, ele não estima a magnitude dessas tendências. Por isso, sua aplicação é frequentemente complementada pelo Estimador de Declive de Sen. Esse estimador quantifica a magnitude da tendência em uma série temporal, determinando a inclinação verdadeira caso uma tendência linear esteja presente (Sen, 1968). O teste Mann-Kendall é preferido ao teste de Spearman para analisar taxas de vazão por ser robusto com dados não paramétricos e por detectar tendências monotônicas sem exigir uma distribuição específica. Enquanto o Spearman foca na correlação de classificação, o Mann-Kendall lida melhor com correlação serial e variações sutis nas taxas de vazão, tornando-o mais adequado para esse tipo de análise (Ashraf et al., 2021; Baran-Gurgul, 2017; Hamed, 2016).

### **3 MATERIAL E MÉTODOS**

#### **3.1 ÁREA DE ESTUDO**

##### **3.1.1 Bacia hidrográfica do rio Capim-Guamá**

A bacia hidrográfica do Capim-Guamá, formada pela confluência dos rios Capim e Guamá, está localizada no nordeste do estado do Pará, abrangendo uma área de drenagem de 80.317,63 km<sup>2</sup>. A bacia fica localizada no Nordeste Paraense, que é a mais antiga fronteira de colonização do estado do Pará. Hoje, a maior parte de sua vegetação original já foi devastada ou fortemente alterada. A antropização foi acelerada a partir do desmatamento para a construção da rodovia Belém-Brasília, a qual foi preconizada no Programa de Integração Nacional (Cordeiro et al., 2017). Geograficamente, a bacia situa-se entre as coordenadas 1°5'33" N e 5°45'36" S de latitude e 49°39'11" O e 46°46'6" L de longitude. É uma das principais bacias hidrográficas do estado, destacando-se por abranger a cidade de Belém, capital do Pará e sede da COP30, Conferência das Nações Unidas sobre Mudanças Climáticas de 2025.

##### **3.1.2 Sub-bacia hidrográfica do rio Guamá**

A sub-bacia hidrográfica do rio Guamá (Figura 12), foco deste estudo, corresponde à área de drenagem delimitada pela seção transversal da estação fluviométrica Bom jardim, representada por Q1. Na Figura 12, também, estão localizadas as estações pluviométricas, denominadas P1, P2, P3 e P4. A sub-bacia está localizada entre as latitudes 1°25'44" N e 2°35'43" S e as longitudes 47°28'57" O

e 46°46'6", abrangendo uma área total de 5.001,29 km<sup>2</sup>. A sub-bacia abrange 4 municípios, sendo estes: Capitão Poço, Garrafão do Norte, Ourém e Santa Luzia do Pará.

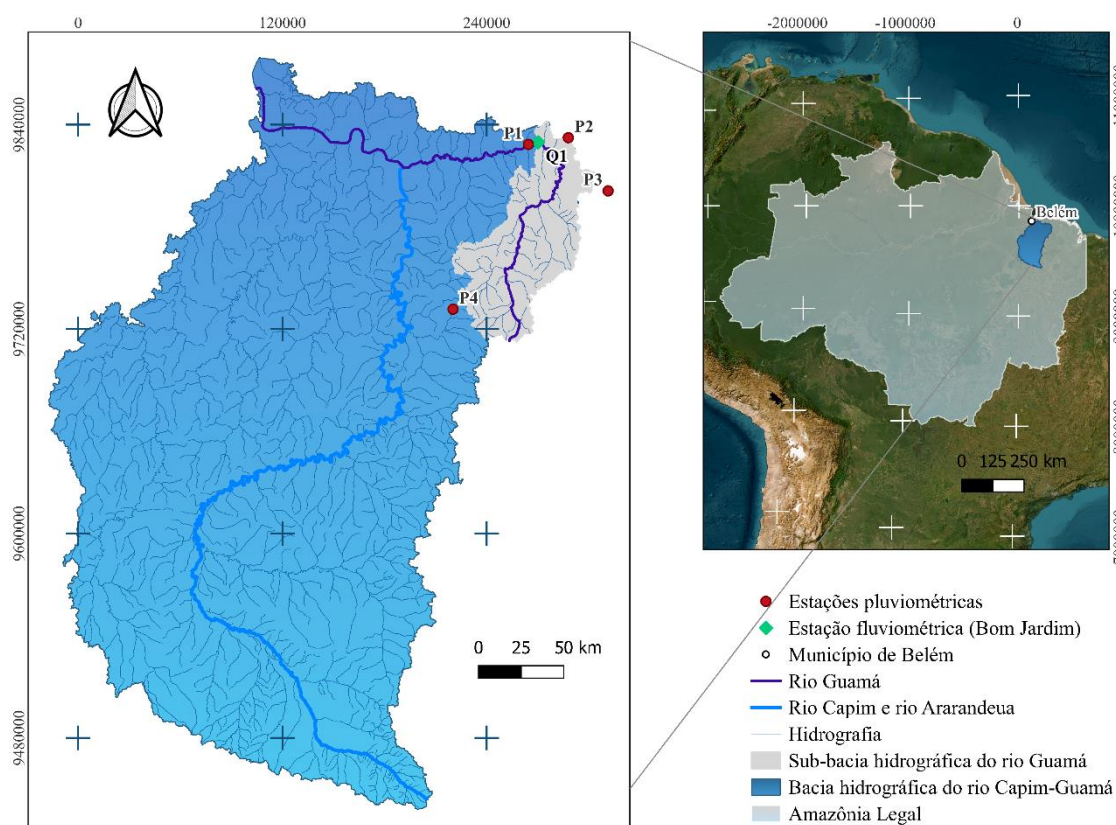


Figura 12: Localização da sub-bacia hidrográfica do rio Guamá

O clima da área de estudo é o Am, conforme a classificação climática de Köppen-Geiger, característico de um clima tropical, com temperaturas acima de 18°C, altos índices de precipitação e presença de uma estiagem de pequena duração (Alvares et al., 2013). A classe de uso do solo predominante na bacia hidrográfica é a Pastagem, ocupando 62,13% da área total, evidenciando sua importância no contexto regional. Além disso, existe a Formação Florestal, com 34,54%, e a Floresta Alagável, com 1,54%, caracterizando a vegetação natural da região. Em menor escala, estão as áreas destinadas a plantações de dendê, soja e outras lavouras temporárias, que somam 0,72%, e a área urbanizada, correspondendo a 0,27% da área da bacia (Mapbiomas Brasil, 2024). A Figura 13 apresenta tais classes da cobertura e uso da terra para a área de estudo.

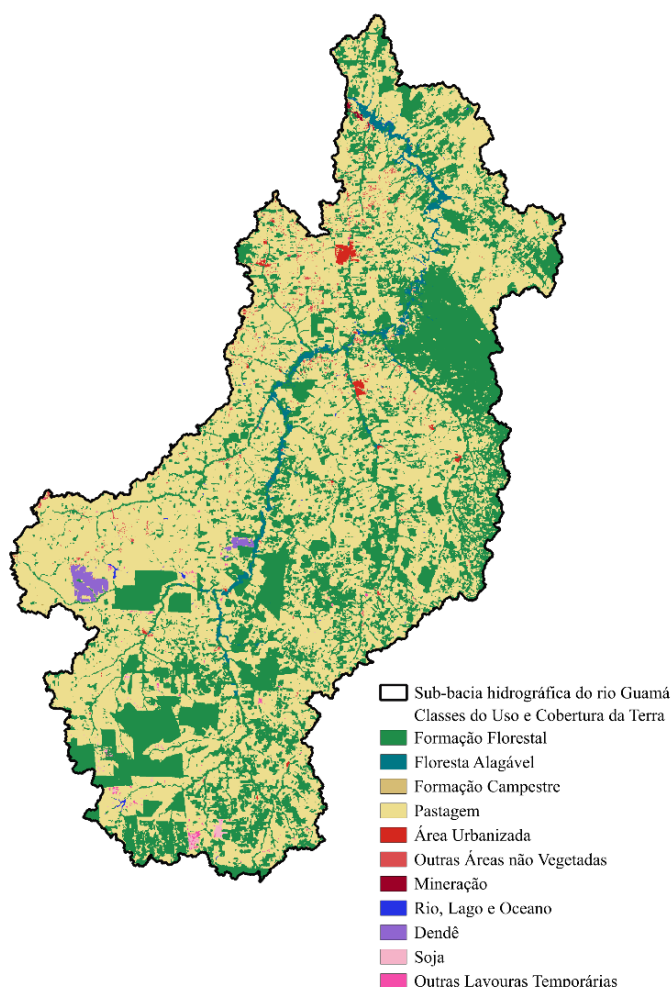


Figura 13: Mapa do Uso e Cobertura da terra da sub-bacia hidrográfica do rio Guamá

### 3.2 EXTRAÇÃO DE DADOS

No presente estudo, a análise dos dados foi conduzida considerando dois períodos de análise distintos: um período de referência e um período futuro. O período de referência abrange os anos de 2009 a 2021, sendo utilizado como base para estabelecer condições e tendências históricas. E o período futuro estende-se de 2022 a 2100. Na Tabela 2 são apresentados dados sobre identificação, coordenadas geográficas, estações hidrometeorológicas e siglas utilizadas ao longo do texto. Os dados de chuva e vazão observados e registrados pelas estações estão disponíveis na plataforma HYDROWEB (<https://www.snirh.gov.br/hidroweb/serieshistoricas>) da ANA.

Tabela 2: Identificação, coordenadas geográficas e estações hidrometeorológicas utilizadas no estudo

Código	Tipo	Nome da estação	Longitude	Latitude	Sigla
147016	Pluviométrica	Ourém	47°07'02" O	01°33'06" S	P1
147011	Pluviométrica	Santa Luzia	46°54'22" O	01°47'56" S	P2
146012	Pluviométrica	Japim	46°41'48" O	01°47'56" S	P3
247004	Pluviométrica	Fazenda São Raimundo	47°30'58" O	02°25'34" S	P4
31520000	Fluviométrica	Bom Jardim	47°03'56" O	01°32'26" S	Q1

Fonte: ANA (2024)

Projeções climáticas do GCM GFDL-ESM4, parte do conjunto NASA Earth Exchange Global Daily Downscaled Projections (NEX-GDDP) do CMIP6, com resolução espacial de 0,25° x 0,25° foram utilizadas para alimentar a modelagem com chuvas futuras. As precipitações projetadas foram utilizadas para os dois períodos de análise (referência e futuro). O período que abrange projeções climáticas históricas do CMIP6 corresponde aos anos de 1850 a 2014. Entretanto, foram baixadas as projeções climáticas a partir de 2009, em correspondência com a disponibilidade de dados observados da sub-bacia. O conjunto de dados de referência é necessário para se observar o “presente” ou “passado recente”.

As precipitações projetadas, a partir de 2022 até 2100, foram obtidas com base em dois cenários de desenvolvimento socioeconômico compartilhados: SSP2-4.5, que representa um cenário intermediário com políticas moderadas de mitigação e transição tecnológica; e o SSP5-8.5, que reflete um cenário de crescimento econômico intenso impulsionado por combustíveis fósseis e altas emissões de gases de efeito estufa (Leimbach et al., 2017; O'Neill et al., 2016). O GCM selecionado para obtenção dos dados de chuva futura foi o GFDL-ESM4. De acordo com o ranqueamento realizado por Mendonça et al. (2024), os GCMs que melhor simularam as variações sazonais de precipitação no bioma amazônico foram, em ordem decrescente de desempenho: KIOST-ESM, FGOALS-g3, CESM2-WACCM, BCC-CSM2-MR, NESM3 e GFDL-ESM4, este último ocupando a sétima posição. No entanto, ao realizar uma análise de correlação em escala de pixel com base nos dados históricos, o GFDL-ESM4 destacou-se como o modelo mais adequado para a região de estudo, justificando sua seleção.

O GFDL-ESM4 vem sendo desenvolvido pelo Geophysical Fluid Dynamics Laboratory (GFDL), criados nos Estados Unidos com o apoio da National Oceanic and

Atmospheric Administration (NOAA). Assim, as precipitações projetadas de referência e futura foram associadas diretamente às coordenadas geográficas das estações pluviométricas P1, P2, P3 e P4.

### 3.3 MÉTRICAS DE DESEMPENHO

Na Tabela 3 são apresentadas as métricas de desempenho utilizadas no estudo. As métricas incluem o Erro Médio Quadrático (MSE), o Coeficiente de Determinação ( $R^2$ ), o Valor de Ajuste (FIT) e o Índice de Eficiência Kling-Gupta (KGE) e suas componentes.

Tabela 3: Métricas de desempenho

Métricas	Fórmulas	Valor ótimo	Referência
MSE	$\frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2$	0	Chai e Draxler (2014)
$R^2$	$1 - \frac{\sum_{i=1}^n (S_i - O_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2}$	1	Steel e Torrie (1981)
FIT	$1 - \frac{\sqrt{\sum_{i=1}^n (O_i - E_i)^2}}{O_{\max} - O_{\min}}$	1	Nouri e Homaei (2018)
KGE	$1 - \sqrt{(1-r)^2 + (1-\gamma)^2 + (1-\beta)^2}$		
KGE <sub>r</sub>	$1 - \sqrt{(1-r)^2}$	1	Gupta et al. (2009)
KGE <sub><math>\gamma</math></sub>	$1 - \sqrt{(1-\gamma)^2}$		
KGE <sub><math>\beta</math></sub>	$1 - \sqrt{(1-\beta)^2}$		

Na Tabela 3,  $O_i$  e  $E_i$  são valores observados e estimados, respectivamente;  $O_{\max}$  e  $O_{\min}$  são as observações máximas e mínimas, respectivamente;  $\bar{O}$  é a média dos valores observados;  $n$  é tamanho da amostra; o parâmetro  $r$  representa a

correlação de Pearson;  $\gamma$  é a razão entre o coeficiente de variação dos valores estimados ( $CVs = \sigma E / \mu E$ ) e o coeficiente de variação dos valores observados ( $CVo = \sigma O / \mu O$ ) e;  $\beta$  é a razão entre a média dos valores estimados ( $E_i$ ) e a média dos valores observados ( $O_i$ ). Sobre a melhor faixa de desempenho do KGE, para determinar se um modelo é “bom” ou “ruim”, foram adotados níveis de desempenho determinados por Mai et al. (2022) (Tabela 4). A classificação da precisão baseada no FIT pode ser resumida da seguinte forma: valores FIT de 0,90 ou superiores indicam excelente precisão, valores variando de 0,70 a 0,90 significam precisão confiável e valores inferiores a 0,60 refletem baixa precisão (Nouri e Veysi, 2024).

Tabela 4: Níveis de desempenho estratificados para qualificar um modelo				
Parâmetro	Ruim	Médio	Bom	Excelente
KGE	$[-\infty \text{ a } 0,48[$	$[0,48 \text{ a } 0,65[$	$[0,65 \text{ a } 0,83[$	$[0,83 \text{ a } 1[$
KGE <sub>r</sub>	$[-\infty \text{ a } 0,70[$	$[0,70 \text{ a } 0,80[$	$[0,80 \text{ a } 0,90[$	$[0,90 \text{ a } 1[$
KGE <sub><math>\gamma</math></sub>	$[-\infty \text{ a } 0,70[$	$[0,70 \text{ a } 0,80[$	$[0,80 \text{ a } 0,90[$	$[0,90 \text{ a } 1[$
KGE <sub><math>\beta</math></sub>	$[-\infty \text{ a } 0,70[$	$[0,70 \text{ a } 0,80[$	$[0,80 \text{ a } 0,90[$	$[0,90 \text{ a } 1[$

Fonte: Mai et al. (2022)

### 3.4 CORRELAÇÃO CRUZADA E AUTOCORRELAÇÃO PARCIAL

Correlação cruzada e autocorrelação parcial são técnicas utilizadas para se obter um modelo parcimonioso, evitando-se aumentar o número de defasagens na entrada da rede neural sem ganho significativo de desempenho, definindo-se de forma mais coerente os vetores de entrada no modelo RNN-NARX. A correlação cruzada (Bayer et al., 2012) é utilizada para avaliar a relação linear entre precipitação (P1, P2, P3, P4) e vazão (Q1), considerando defasagens temporais nas séries observadas (Equação 21 e Equação 22).

$$\text{cov}_{(y, x_{(t-k)})} = \frac{1}{n} \left[ \sum_{t=k+1}^n (y - \bar{y})(x_{t-k} - \bar{x}) \right] \quad (21)$$

$$r_{x(t-k)y} = \frac{\text{cov}_{(y, x_{(t-k)})}}{\sqrt{(y - \bar{y})}} \quad (22)$$

Onde cov é a covariância amostral, y e x são as variáveis abordadas, k são os valores defasados do instante t,  $\bar{y}$  e  $\bar{x}$  são médias amostrais, e n é o número de observações. A autocorrelação parcial foi usada para analisar a influência de valores passados da vazão sobre os atuais, isolando efeitos de defasagens distintas, com um intervalo de confiança de 99% (Mendonça et al., 2021). Esse índice elimina

interferências entre defasagens e representa a dependência temporal real (Equação 23 e Equação 24).

$$\rho_k = \left[ \sum_{t=k+1}^n (y_t - \bar{y})(y_{t-k} - \bar{y}) \right] \left[ \sum_{t=1}^n (y_t - \bar{y})^2 \right]^{-1} \quad (23)$$

$$\phi_{kk} = \left[ \rho_k - \sum_{j=1}^{k-1} (\phi_{k-1,j} - \rho_{k-j}) \right] \left[ 1 - \sum_{j=1}^{k-1} (\phi_{k-1,j} - \rho_{k-j}) \right]^{-1} \quad (24)$$

Onde  $\rho_k$  é o coeficiente de autocorrelação,  $y$  é a variável autocorrelacionada nos instantes  $t$  e  $t-k$ ,  $\bar{y}$  é a média de  $y$ ,  $\phi_{kk}$  é o coeficiente de autocorrelação parcial e  $\phi_{k-1j}$  são os coeficientes de autocorrelação parcial filtrados das defasagens anteriores.

### 3.5 MODELO RNN-NARX

Para a modelagem das séries temporais de vazão neste estudo, sob os cenários climáticos SSP2-4.5 e SSP5-8.5, foi utilizado uma rede neural recorrente, com arquitetura Autorregressiva Não Linear com Entradas Exógenas (RNN-NARX), já exploradas por outros autores (Fabio et al., 2022; Guzman et al., 2017). As redes NARX's possuem conexões recorrentes que permitem que a rede tenha uma memória interna (feedback), necessária para capturar dependências temporais e sequenciais nos dados (Sit et al., 2020), conforme expresso pela Equação 26.

$$y_k = f \left( \sum_{n=1}^z w_{kn} x_n + b_k \right) \quad (26)$$

Onde cada  $x_n$  é ponderado por um peso sináptico  $w_{kn}$ , que é somado ao parâmetro bias  $b_k$ , que modula o sinal de saída através de uma função de ativação  $f$ , ou seja, as informações fluem através de sucessivas conexões ponderadas, até gerar um sinal de resposta ( $y_k$ ). A seguir são descritas as etapas de treinamento e validação cruzada. As seções 3.5.1, 3.5.2 e 3.5.3 apresentam a divisão de dados e as etapas de desenvolvimento do modelo, o qual foi desenvolvido em linguagem de programação computacional.

#### 3.5.1 Divisão do conjunto de dados

No processo de parametrização, isto é, durante o treinamento os vetores de entrada são um conjunto de dados observados, correspondentes a vazão e precipitação extraídas das estações, Figura 14 e Figura 15, respectivamente. Os dados foram divididos em dois subconjuntos: destacando-se treinamento (2009-2019)

e validação cruzada (2020-2021), que utiliza um subconjunto de dados independente do utilizado durante o treinamento.

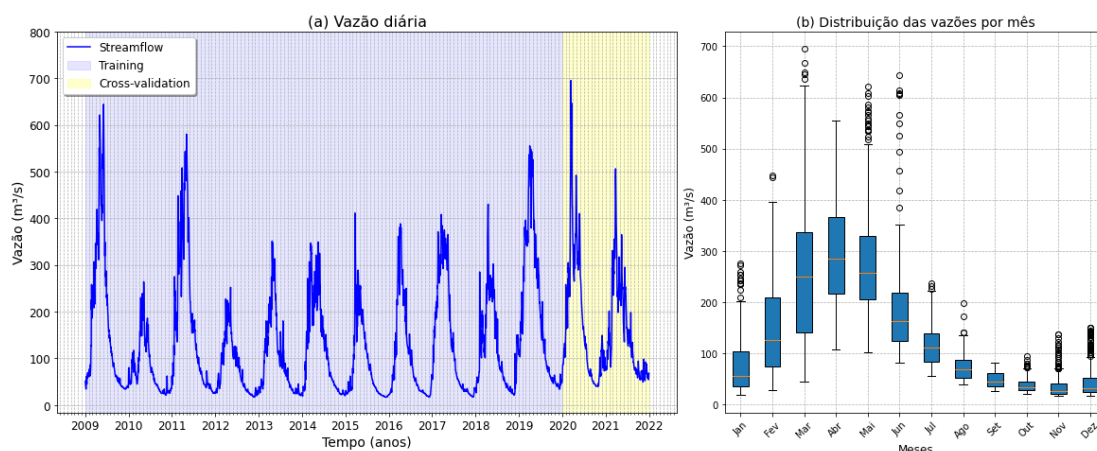


Figura 14: Divisão das vazões diárias observadas em períodos destinados ao treinamento e validação cruzada do modelo RNN-NARX (a) e mensais (b) na estação fluviométrica Bom Jardim.

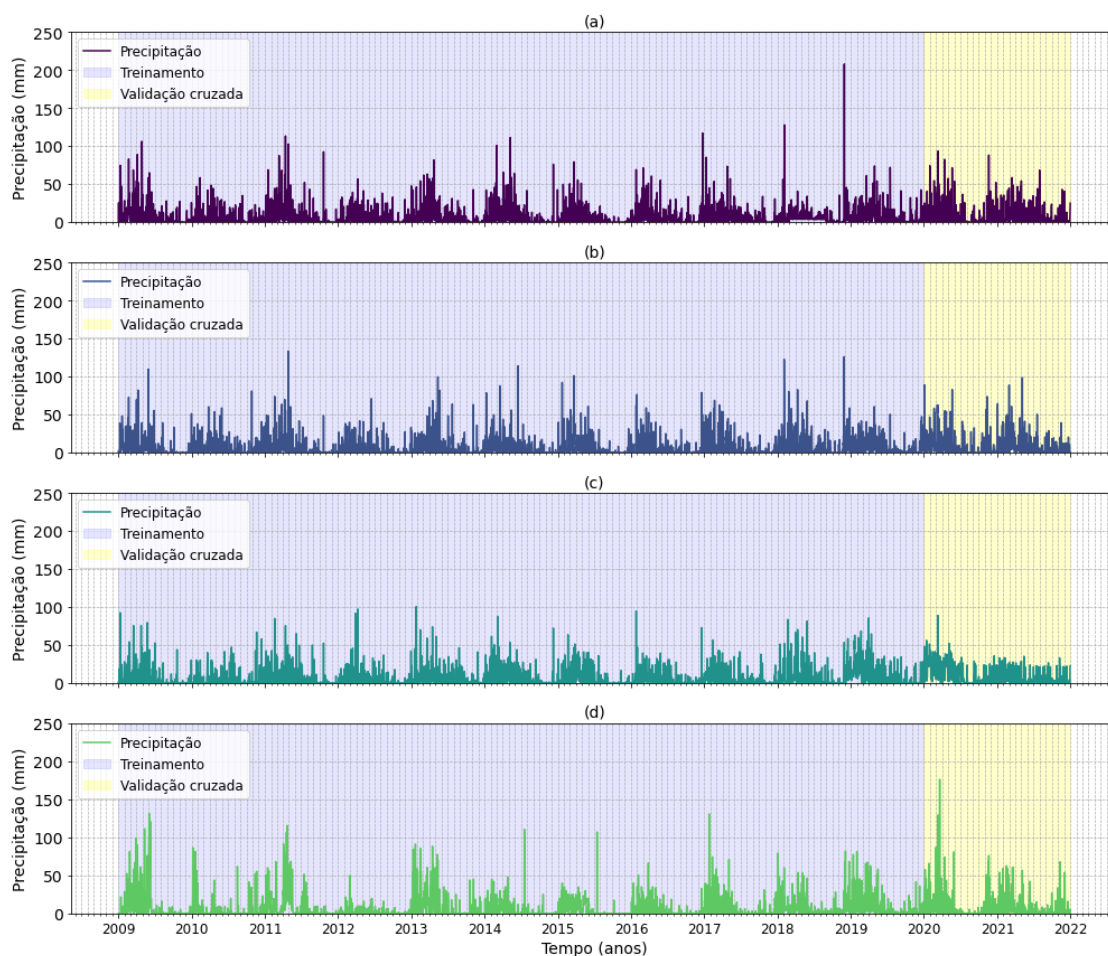


Figura 15: Divisão das precipitações observadas nas estações pluviométricas (P1 (a), P2 (b), P3 (c), e P4 (d)) em períodos destinados ao treinamento e validação cruzada do modelo RNN-NARX.

Ao utilizar redes de algoritmos de retropropagação, dependendo da função de ativação dos neurônios, é necessário realizar a normalização dos dados de entrada. Sola e Sevilla (1997) afirmaram que a normalização dos dados de entrada é crucial para obter bons resultados, bem como agilizar substancialmente os cálculos. Dessa forma, os dados foram normalizados no intervalo de -1 a 1, conforme a Equação 25, para se adequar à faixa de funcionamento da função de ativação. Este intervalo corresponde à faixa de funcionamento da função de ativação tangente hiperbólica.

$$x_n = i_{min} + \frac{x - x_{min}}{x_{max} - x_{min}} (i_{max} - i_{min}) \quad (25)$$

Em que  $x$  é a variável, que se deseja normalizar,  $x_n$  é a variável normalizada,  $x_{min}$  e  $x_{max}$  são os valores mínimos e máximos encontrados nos dados, e  $i_{min}$  e  $i_{max}$  são, respectivamente, os limites inferior e superior do intervalo, que se deseja normalizar. Ao final das simulações, as vazões diárias foram desnormalizadas, retornando aos seus valores originais.

### 3.5.2 Treinamento

No treinamento, o modelo foi parametrizado no modo open loop. O conjunto de dados observados foi utilizado como entrada, permitindo ajuste de pesos e biases a fim de aprender a relação não linear entre a precipitação (entrada) e a vazão (saída). Essa fase tem como objetivo otimizar os parâmetros internos da rede para minimizar o erro de previsão. O modelo foi configurado da seguinte forma:

- Camada de entrada: os vetores de entrada correspondem às precipitações e vazões, nos quais foram testadas várias combinações de valores defasados;
- Camada Oculta: utilizou-se uma única camada oculta, suficiente para aproximar funções não lineares (Menezes e Barreto, 2008). O número de neurônios ocultos (entre 2 e 20) foi definido pelo método das aproximações sucessivas, tendo como função objetivo o MSE (Tabela 3). A quantidade de neurônios na camada oculta é crucial no processo de treinamento. Uma quantidade pequena de neurônios pode ser insuficiente para aprender os padrões existentes (underfitting). Por outro lado, uma maior quantidade de neurônios pode conduzir à perda de capacidade de generalização (overfitting);
- A função de ativação aplicada na camada oculta da RNN-NARX foi a tangente hiperbólica (*tanh*). Visto que os estudos de Rezaeian Zadeh et al. (2010) e Yonaba et al. (2010) mostraram que a função tangente hiperbólica teve um

desempenho melhor do que a log-sigmoide na previsão de vazões diárias. Foi utilizada apenas uma camada oculta, pois é suficiente para aproximar qualquer função não linear (Hornik et al., 1989); e

- O algoritmo de otimização utilizado foi o Levenberg-Marquardt (*trainlm*), realizado ao longo de até 1000 épocas para minimizar o MSE. Este algoritmo é uma adaptação do método Gauss-Newton, abordando um treinamento de segunda ordem com a aproximação de uma matriz Hessiana (Sahoo e Jha, 2013). A partir desse algoritmo de treinamento, expresso pela Equação 8 (Seção 2.6.8), o ajuste dos parâmetros dos pesos sinápticos ( $w_k$ ) e bias ( $b_k$ ) foi elaborado.

Cada combinação possível é treinada várias vezes, e a configuração com o menor erro é a escolhida para dar continuidade a validação cruzada.

### 3.5.3 Validação cruzada por parada antecipada

A validação cruzada é uma extensão do treinamento, pelo qual se acompanhou a evolução do aprendizado sobre um conjunto de dados distinto. Nesta etapa, o método de parada antecipada foi utilizado para evitar *overtraining*. Os critérios de finalização do treinamento são mostrados na Tabela 5. A parada antecipada consiste na avaliação iterativa de um subconjunto de dados, de modo que quando alcançado algum critério específico, tal como o menor erro pré-definido, a etapa seja interrompida (Mendonça et al., 2023).

Tabela 5: Condições de parada antecipada por validação cruzada

Parâmetro	Valor
Máximo número de iterações	1000
Desempenho desejado (erro quadrático médio máximo)	0,005
Nº máx. de aumento de desempenho na validação	200
Tempo máximo de treinamento (segundos)	3000

Inicialmente, o modelo foi configurado em modo Open Loop durante o período de referência. Posteriormente, ainda nesse mesmo período, foi convertido para o modo Closed Loop para avaliar sua capacidade de realizar previsões autônomas e verificar seu desempenho em estimativas de longo prazo. Os vetores de entrada

utilizados foram as precipitações projetadas pelo GCM GFDL-ESM4, que abrangem dados do período *historical* e cenários do período de 2009 a 2021, uma vez que os cenários climáticos do CMIP6 começam apenas em 2015. Após a avaliação do desempenho do modelo e a obtenção das equações de correção (Seção 3.6), as vazões de longo prazo (2022 a 2100) foram simuladas, considerando os dois cenários climáticos do CMIP6: SSP2-4.5 e SSP5-8.5.

### 3.6 CORREÇÃO DE VIÉS DAS VAZÕES SIMULADAS

As vazões futuras foram corrigidas pelo método Empirical Quantile Mapping (EQM), um dos métodos mais utilizados e efetivos para a correção de viés de variáveis que foram simuladas, tendo como entradas variáveis forçantes oriundas de GCMs (Holthuijzen et al., 2022). Este método se fundamenta nas transformações estatísticas e probabilísticas (Angus, 1994), ajustando as distribuições simuladas às observadas, minimizando distorções (Equação 27).

$$Q_{corr,d} = CDF_{obs}^{-1}(CDF_{sim}^{-1}(Q_{sim,d})) \quad (27)$$

Onde  $CDF_{sim}^{-1}$  é a função a função de distribuição acumulada aplicada à variável simulada em valores diários ( $Q_{sim,d}$ ), transformando esses valores para o espaço probabilístico padrão (intervalo [0,1]). Já a  $CDF_{obs}^{-1}$  é a função que transforma o espaço probabilístico de volta para o domínio das vazões diárias corrigidas ( $Q_{corr,d}$ ). Dessa forma, as vazões simuladas pelo modelo RNN-NARX para o período de referência (2009 a 2021) foram utilizadas como controle, enquanto as vazões simuladas para o período futuro (2022 a 2100) foram submetidas ao processo de correção.

### 3.7 TESTE MANN-KENDALL

O teste MK é um método de teste estatístico não paramétrico comumente utilizado para analisar a tendência de uma série temporal. O método não exige que os dados obedeçam a uma distribuição específica e a faixa de teste é ampla. É adequado para testes de tendências de dados hidrometeorológicos aleatórios e não normalmente distribuídos (Yue et al., 2002). O teste examina a significância da estatística MK padronizada, i.e.,  $Z_{\alpha/2}$  (Equação 31). O valor estatístico S para séries temporais é definido pela Equação 28.

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (28)$$

Onde  $sgn$  é função de sinal;  $n$  é o tamanho da amostra,  $x_i$  e  $x_j$  são variáveis aleatórias com  $x_j$  seguindo  $x_i$  no tempo. O valor positivo da estatística  $S$  indica uma tendência ascendente da série temporal; caso contrário, um valor negativo significa uma tendência descendente. Quando  $n$  é maior que 8, pode-se considerar que  $S$  obedece à suposição de distribuição normal padrão, e sua expectativa  $E(S)$  e variância  $Var(S)$  podem ser expressas pela Equação 29 e Equação 30, respectivamente.

$$E(S) = 0 \quad (29)$$

$$Var(S) = \frac{1}{18} [n(n-1)(2n+5)] \quad (30)$$

$$Z_{\alpha/2} = \begin{cases} (S-1) / \sqrt{Var(S)} & S > 0 \\ 0 & S = 0 \\ (S+1) / \sqrt{Var(S)} & S < 0 \end{cases} \quad (31)$$

Para uma sequência aleatória, o valor crítico do teste  $Z_{\alpha/2}$  no determinado nível de significância pode ser encontrado na tabela de distribuição normal, sendo  $\alpha$  o limite para significância estatística. Um valor de  $1,96 < |Z_{\alpha/2}| \leq 2,58$  indica que a amostra tem uma tendência de mudança significativa no nível de significância  $\alpha = 0,05$ ; quando  $|Z_{\alpha/2}| > 2,58$ , indica que a série de dados tem uma tendência de mudança significativa no nível de significância de  $\alpha = 0,01$ . Em que o p-valor de 0,05 ou inferior é considerado como indicativo de uma mudança estatisticamente significativa, enquanto p-valor de 0,01 ou inferior indica uma mudança muito significativa (Kendall, 1975).

O MK foi utilizado em conjunto com o estimador *Sen's Slope* e o coeficiente de variação (CV) para avaliar a tendência das vazões futuras médias de longo período da sub-bacia hidrográfica do rio Guamá. A vazão média de longo período permite caracterizar a maior vazão possível de ser regularizada em uma bacia permitindo a avaliação dos limites superiores (abstraindo as perdas) da disponibilidade de água de um manancial. A vazão média de longo período é definida como a média das vazões médias anuais para toda a série de dados, sendo específica quando dividida pela área da bacia hidrográfica de interesse (Alexandre e Martins, 2005).

### 3.8 ESTIMADOR SEN'S SLOPE

Além de identificar se existe uma tendência, a magnitude de uma tendência também deve ser estimada. O estimador Sen's Slope é um método não paramétrico

amplamente utilizado para identificar e quantificar tendências em séries temporais (Sen, 1968). Esse método é considerado robusto por não ser sensível a *outliers* e por não exigir normalidade ou linearidade. Sendo frequentemente empregado em análises ambientais, hidrológicas e climáticas (Yue et al., 2002). O estimador *Sen's Slope* ( $\beta$ ) é a mediana sobre todas as combinações possíveis de pares para todo o conjunto de dados ( $S_{ij}$ ). Um valor positivo de  $\beta$  indica uma 'tendência ascendente', enquanto um valor negativo de  $\beta$  indica uma 'tendência descendente' (Hirsch et al., 1991; Xu et al., 2007). A inclinação, i.e., a taxa linear de mudança, é calculada via Equação 32.

$$S_{ij} = \frac{x_j - x_i}{j - i} \quad (32)$$

Onde  $S_{ij}$  é a inclinação,  $x$  denota a variável e  $i, j$  são índices. O valor final do Sen's Slope ( $\beta$ ) corresponde à mediana de todas as inclinações ( $S_{ij}$ ), conforme dado pela Equação 33.

$$\beta = \text{mediana}(S_{ij}) \quad (33)$$

### 3.9 COEFICIENTE DE VARIÂNCIA

O coeficiente de variação (CV) será aplicado a uma série temporal de vazões diárias como uma medida de variabilidade relativa. Ele é calculado como a razão entre o desvio padrão ( $\sigma$ ) e a média ( $\bar{x}$ ) das vazões diárias, conforme a Equação 34.

$$CV = \frac{\sigma}{\bar{x}} 100 \quad (34)$$

Neste estudo, foram realizadas análises de tendências de vazões diárias, para identificar possíveis mudanças significativas no regime hidrológico, como aumentos ou reduções nas vazões, que podem estar associadas ou não à influência das mudanças climáticas. A Figura 16 mostra o fluxograma da metodologia desenvolvida.

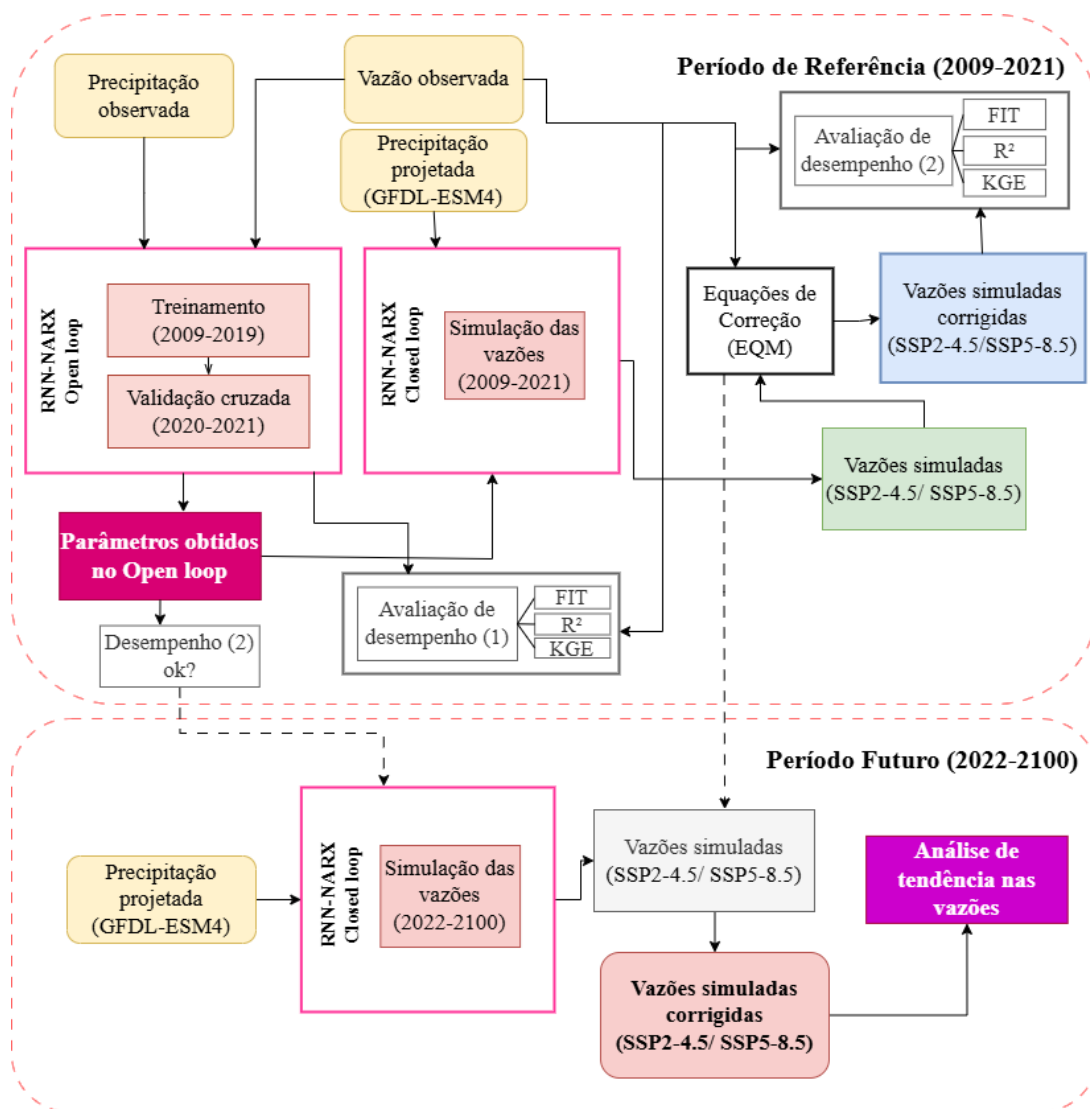


Figura 16: Fluxograma da metodologia apresentada para estimar as vazões com um modelo RNN-NARX sob a influência das mudanças climáticas.

## 4 RESULTADOS E DISCUSSÃO

### 4.1 CORRELAÇÃO CRUZADA E AUTOCORRELAÇÃO PARCIAL

A Figura 17 mostra os coeficientes de correlação cruzada entre a vazão observada (Q1) e as precipitações (P1, P2, P3 e P4). Ademais, a Figura 17 mostra o coeficiente de autocorrelação parcial para a vazão observada com defasagens de até 10 dias e intervalo de confiança de 99% indicado pelas linhas tracejadas em azul.

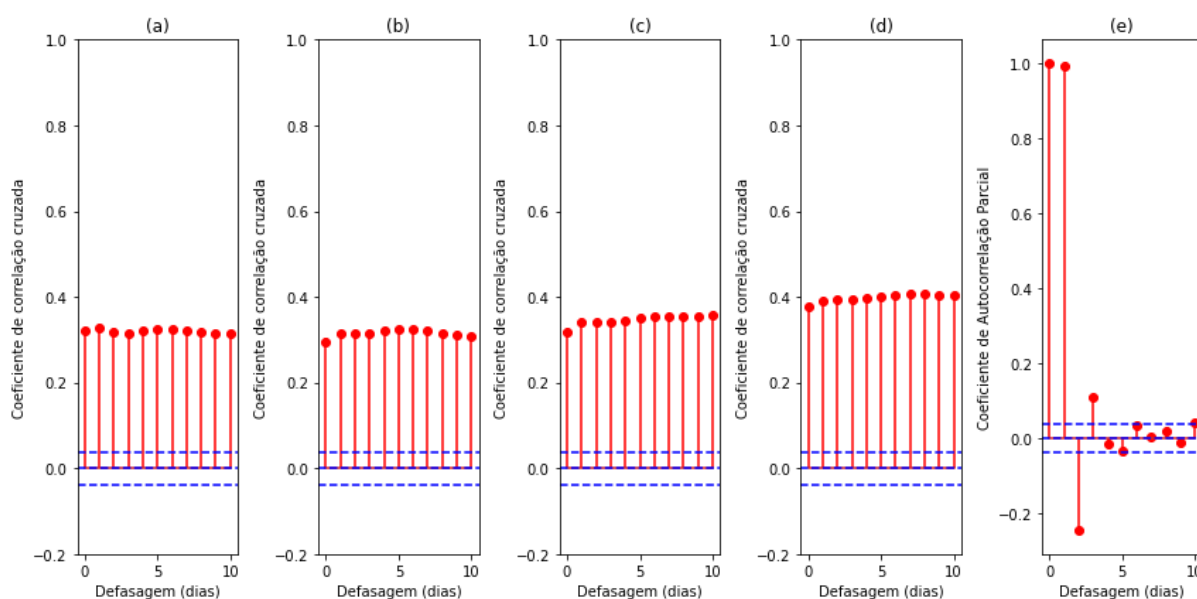


Figura 17: Coeficientes de correlação cruzada entre a vazão (Q1) e as precipitações (P1-a, P2-b, P3-c e P4-d) e coeficientes de autocorrelação parcial da vazão (e), com intervalo de confiança de 99% para o período de referência (2009-2021)

Nas Figuras 17-a, 17-b, 17-c e 17-d, são apresentados os coeficientes de correlação cruzada entre a vazão (Q1) e as precipitações (P1, P2, P3 e P4). Os coeficientes positivos observados nas defasagens de até 10 dias representam a resposta não imediata da vazão em relação às precipitações. Nota-se um padrão crescente nos valores à medida que os dias passam, o que sugere uma influência temporal e espacial das precipitações sobre a vazão. Esse efeito é mais pronunciado na estação mais distante ao exutório (P4), pois a precipitação, medida nessa estação, demora mais tempo (dias) para influenciar as vazões, refletindo em uma resposta hidrológica mais lenta. Isso é devido à não linearidade do fenômeno chuva-vazão.

Já na Figura 17-e, a autocorrelação parcial das vazões mostra uma dependência temporal positiva no primeiro dia de defasagem (próximo a 1) e negativa no segundo dia (próximo a -0,2). Esse comportamento reflete a persistência das

condições hidrológicas e a inércia do sistema, onde os valores iniciais de vazão influenciam diretamente nos valores dos dias subsequentes. Mendonça et al. (2021), ao analisar uma série temporal de dados até 2019, identificaram valores de autocorrelação parcial semelhantes na mesma sub-bacia. Entretanto, observa-se divergências em relação aos valores de correlação cruzada encontrados no estudo dos autores. Isso pode ser explicado pela inclusão de dados dos anos de 2020 e 2021, neste estudo, que refletiram na resposta hidrológica.

## 4.2 PERÍODO DE REFERÊNCIA

### 4.2.1 Open Loop – treinamento e validação cruzada

No processo de parametrização do modelo, as análises de defasagem temporal das variáveis (Figura 17) possibilitaram a definição dos vetores de entrada do modelo e seus atrasos, incluindo a retroalimentação das vazões (Tabela 6).

Tabela 6: Vetores de entrada e os atrasos temporais da RNN-NARX treinada

Vetores de Entrada	Atrasos de Entrada	Retroalimentação	Saída
P1(t), P2(t), P3(t), P4(t)	(t-1), (t-2), (t-3), (t-4), (t-5), (t-6)	Q(t-1), Q(t-2), Q(t-3)	Q(t)

Na Tabela 6 observa-se a configuração dos vetores de entrada e retroalimentação definidos para a RNN-NARX, que apresentou as melhores métricas de desempenho entre as vazões simuladas (saída do modelo) e as vazões observadas (Tabela 7). Os vetores de entrada incluem as séries de precipitação projetadas P1, P2, P3 e P4 com atrasos de 1 a 6 passos de tempo (t-1, t-2, t-3, t-4, t-5, t-6). Adicionalmente, a retroalimentação da rede foi estruturada utilizando valores passados da série de vazão Q, com atrasos de 1 a 3 passos de tempo (Q(t-1), Q(t-2), Q(t-3)).

A seguir, a Figura 18 ilustra a comparação entre a vazão simulada pelo modelo e a vazão observada, para o período de referência (2009 a 2021), a partir da obtenção dos parâmetros do modelo.

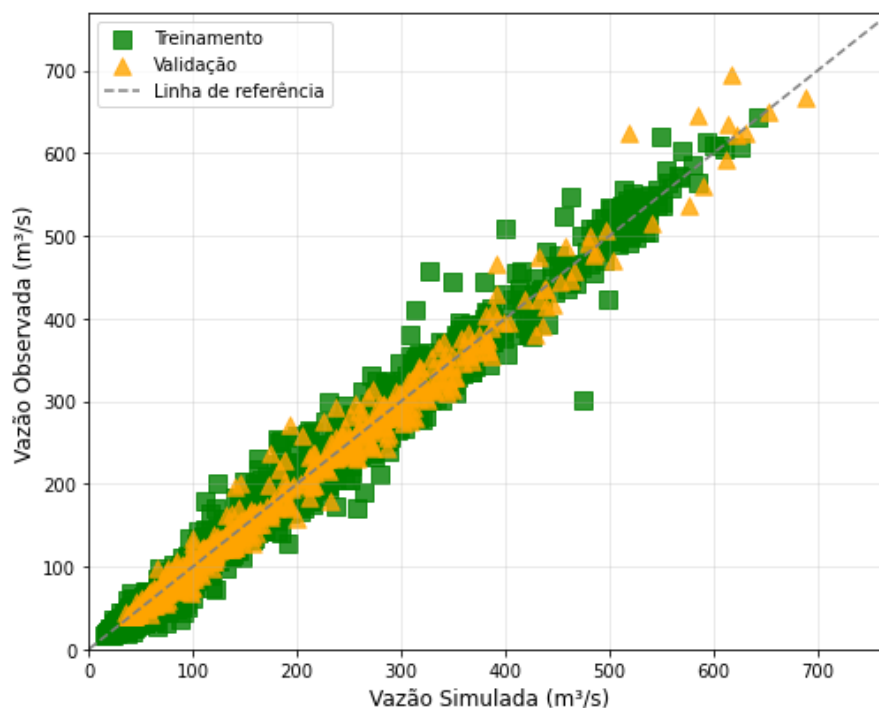


Figura 18: Dispersão entre os dados observados e simulados nas etapas de treinamento e validação para o período de referência (2009-2021), resultado da parametrização

A Figura 18, demonstra a dispersão entre os dados observados e simulados durante as etapas de treinamento e validação para o período de 2009 a 2021. Analisando-se a proximidade dos pontos em relação à linha de referência indica que o modelo conseguiu reproduzir com boa precisão os dados observados, sugerindo uma parametrização adequada. Essa análise é necessária para validar a confiabilidade do modelo e garantir que a parametrização do modelo tenha sido eficaz.

A seguir, a Tabela 7 mostra a avaliação de desempenho das vazões simuladas pela RNN-NARX, que foram obtidas a partir da configuração apresentada anteriormente (Tabela 6).

Tabela 7: Métricas de desempenho da RNN-NARX no treinamento e validação cruzada

Etapa	FIT	R <sup>2</sup>	KGE	KGE <sub>r</sub>	KGE <sub>y</sub>	KGE <sub>β</sub>
Treinamento	0,98	0,99	0,99	0,99	0,99	1,0
Validação cruzada	1,0	0,99	0,99	0,99	1,0	1,0

As métricas apresentaram valores elevados ( $FIT=0,98$ ;  $R^2=0,99$ ; KGE e componentes=0,99 a 1,0), indicando um excelente nível de desempenho entre os dados simulados e observados no treinamento. Por conseguinte, os resultados na etapa de validação cruzada permaneceram excelentes ( $FIT=1,0$ ;  $R^2=0,99$ ; KGE e componentes=0,99 e 1,0), demonstrando alta generalização do modelo. Isso confirma a eficiência do modelo RNN-NARX na predição de vazões na sub-bacia, assim como, em Mendonça et al. (2021), que encontraram valores de  $R^2$  de 0,987 e 0,99 nas etapas de treinamento e validação cruzada, respectivamente.

#### 4.2.2 Closed Loop – simulação de vazão

Após a parametrização da rede, as vazões foram simuladas (agora no Closed Loop) para avaliar a capacidade de generalização do modelo, ainda no período de referência. A Tabela 8 mostra os resultados quantitativos da avaliação de desempenho dessas simulações, que incluem as métricas FIT,  $R^2$  e KGE. A avaliação buscou evidenciar o nível de precisão e confiabilidade do modelo RNN-NARX em ambos os cenários climáticos no período de referência. Os resultados da análise indicam um desempenho satisfatório do modelo em ambos os cenários, com as métricas FIT e KGE refletindo uma boa aderência às vazões observadas.

Tabela 8: Métricas de desempenho das vazões na validação da RNN-NARX sob os cenários SSP2-4.5 e SSP5-8.5 para o período de referência

Cenário	FIT	$R^2$	KGE	KGE <sub>r</sub>	KGE <sub>y</sub>	KGE <sub><math>\beta</math></sub>
SSP2-4.5	0,88	0,58	0,73	0,76	0,87	1,00
SSP5-8.5	0,88	0,56	0,73	0,75	0,92	0,99

O valor de ajuste (FIT) foi de 0,9 nos cenários SSP2-4.5 e SSP5-8.5, indicando que o modelo apresentou precisão confiável (Nouri e Veysi, 2024). O índice KGE revelou um desempenho semelhante entre os cenários, com valores de 0,73 para SSP2-4.5 e SSP5-8.5, indicando que o modelo foi capaz de estimar as vazões com boa precisão, conforme os critérios de desempenho definidos por Mai et al. (2022). O componente de correlação ( $r$ ) foi sutilmente mais forte no cenário SSP2-4.5 (0,76) em comparação com o SSP5-8.5 (0,75), sugerindo um nível de desempenho médio. O componente  $y$ , que reflete a variabilidade das estimativas, apresentou valores de 0,87

para o cenário SSP2-4.5 e 0,92 para o SSP5-8.5, classificando ambas as estimativas como boas. Por fim, os valores do componente  $\beta$  foram de 1 para o cenário SSP2-4.5 e 0,99 para o SSP5-8.5, indicando uma excelente performance no viés. Esses resultados mostram que o modelo consegue capturar parte significativa da variabilidade nas vazões observadas. Porém, pode-se constatar que o desempenho foi afetado por um erro sistemático nas precipitações projetadas pelo GCM, caracterizada pelo atraso no pico das chuvas máximas. O atraso de pico nas projeções CMIP6 dos GCMs é influenciado, principalmente, pelos vieses dos GCMs. O estudo de Tebaldi et al. (2021) demonstrou que as trajetórias individuais dos GCMs, sob os diferentes cenários, causam um atraso em comparação com as projeções médias de um multimodelo.

A Figura 19 mostra o gráfico de dispersão, comparando as vazões simuladas para os cenários climáticos SSP2-4.5 e SSP5-8.5 e as vazões observadas do período de referência (2009 a 2021).

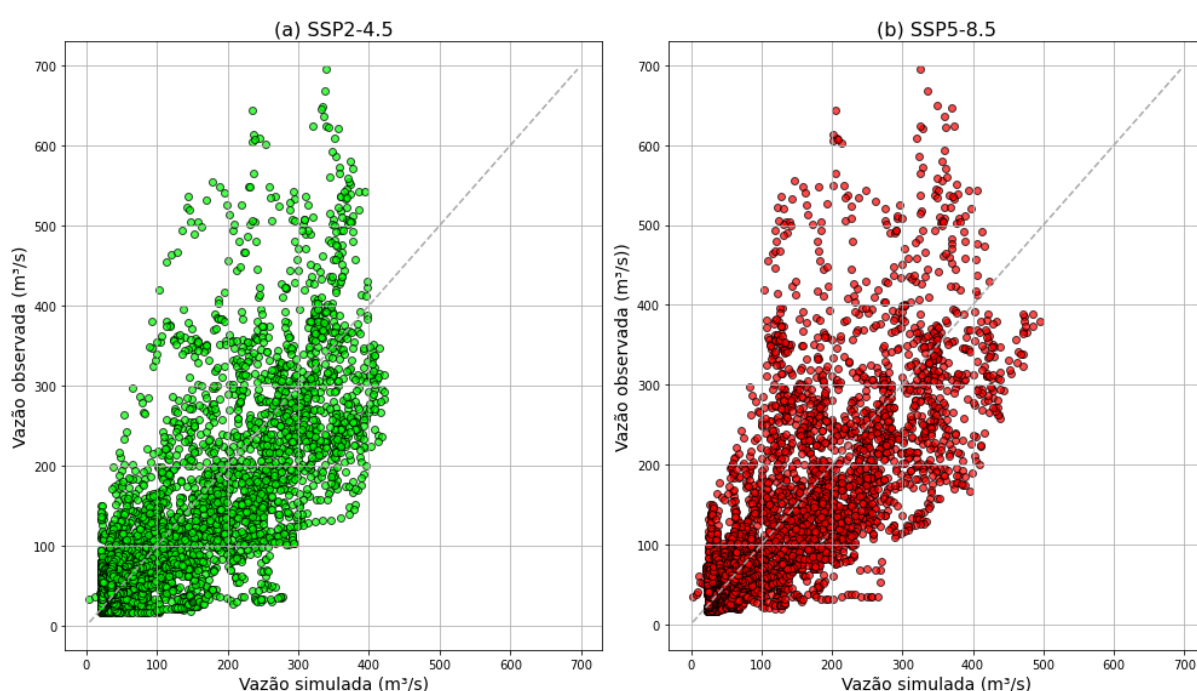


Figura 19: Dispersão das vazões diárias observadas e estimadas durante a validação da RNN-NARX para os cenários SSP2-4.5 (a) e SSP5-8.5 (b) no período de referência (2009-2021)

É possível observar a subestimação das vazões máximas pelo modelo RNN-NARX, em ambos os cenários (Figura 19). Esse comportamento sugere que o modelo apresenta limitações para simular vazões máximas. Logo, técnicas de correção de

viés são necessárias na mitigação de erros sistemáticos em vazões simuladas, provenientes de dados climáticos projetados (Lin et al. 2019).

#### 4.2.3 Correção de Viés

Para a correção de viés, o método EQM, foi aplicado ao período de referência com dados observados e simulados pela RNN-NARX, que tiveram como entradas as precipitações simuladas pelo GCM- GFDL-ESM4, seguindo os cenários SSP2-4.5 e SSP5-8.5. A Figura 20 apresenta as equações obtidas para correção das vazões futuras via método EQM no período de referência (2009 a 2021).

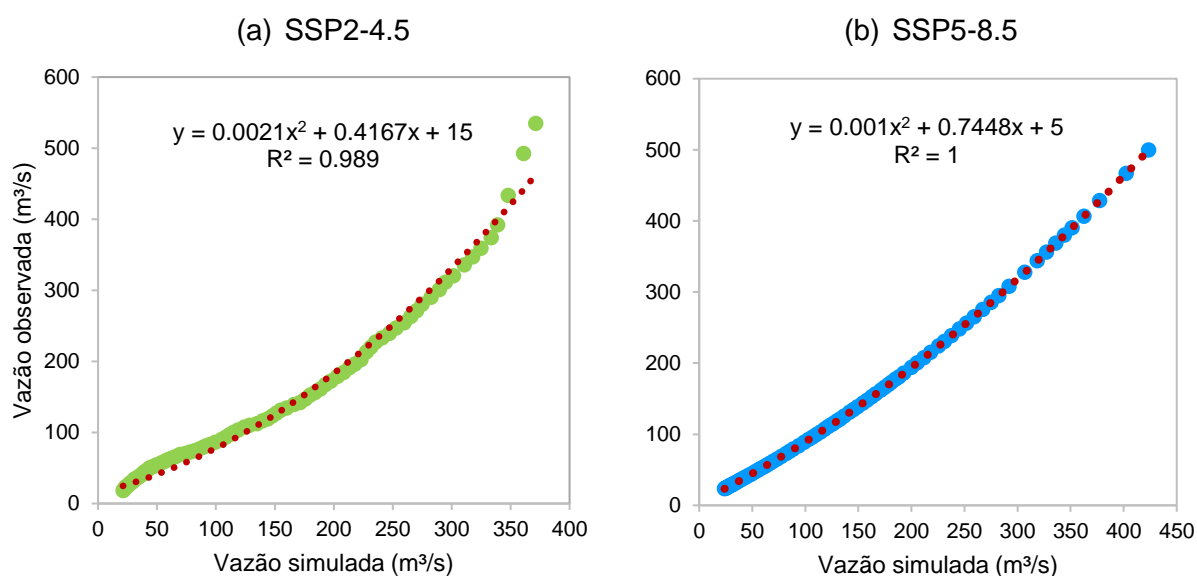


Figura 20: Equações para a correção das vazões simuladas pelo método EQM para o cenário SSP2-4.5 (a) e SSP5-8.5 (b), no período de referência (2009-2021)

Na Figura 21 são mostradas as curvas de distribuição cumulativa das vazões observadas, estimadas e corrigidas, para ambos os cenários climáticos (SSP2-4.5 e SSP5-8.5).

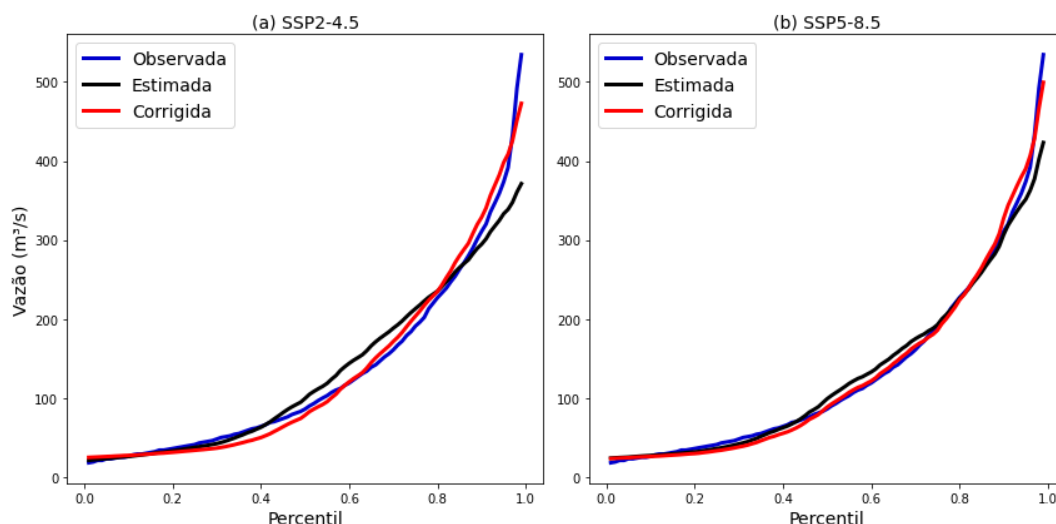


Figura 21: Curvas de vazões observadas, estimadas e corrigidas para os cenários SSP2-4.5 (a) e SSP5-8.5 (b), para o período de referência (2009-2021)

Observa-se na Figura 21 que as vazões simuladas (linha preta) subestimam os valores máximos, uma limitação já identificada previamente. No entanto, as vazões corrigidas (linha vermelha) demonstram uma maior aproximação das vazões observadas (linha azul), especialmente nas extremidades, em ambos os cenários analisados. Essa melhoria é destacada pelo desempenho superior da métrica de variabilidade  $KGE_y$ . A Tabela 9 apresenta as métricas de desempenho (FIT,  $R^2$ , KGE e suas componentes) antes e depois da correção de viés nas vazões simuladas pela RNN-NARX, sob os cenários SSP2-4.5 e SSP5-8.5, para o período de referência.

Tabela 9: Valores das métricas de desempenho antes e depois da correção de viés nas vazões simuladas pela RNN-NARX, sob os cenários SSP2-4.5 e SSP5-8.5, para o período de referência (2009-2021)

SSP2-4.5		
Métricas	Antes	Depois
FIT	0,88	0,87
$R^2$	0,58	0,56
KGE	0,73	0,75
$KGE_r$	0,76	0,75
$KGE_y$	0,87	0,98
$KGE_\beta$	1,0	1,0
SSP5-8.5		

	Antes	Depois
FIT	0,88	0,87
R <sup>2</sup>	0,56	0,54
KGE	0,73	0,74
KGE <sub>r</sub>	0,75	0,74
KGE <sub>y</sub>	0,92	0,98
KGE <sub>β</sub>	0,99	1,0

Conforme o exposto na Tabela 9, os valores de FIT permaneceram consistentes em torno de 0,9, indicando simulações com precisão confiável, bem como o R<sup>2</sup> (~0,6-0,5). O índice KGE<sub>r</sub> apresentou valores de 0,75 e 0,74 nos cenários SSP2-4.5 e SSP5-8.5, respectivamente, com uma redução de 0,01 em ambos os cenários após a correção. No entanto, a principal melhoria ocorreu na componente de variabilidade (KGE<sub>y</sub>), que aumentou de 0,87 para 0,98 no cenário SSP2-4.5 e de 0,92 para 0,98 no SSP5-8.5. Isso indicou uma melhoria de "bom" para "excelente" na variabilidade da série simulada. Além disso, o KGE<sub>β</sub> manteve um desempenho excelente, com valor igual a 1 em ambos os cenários. O que refletiu em uma melhora no índice geral KGE, que atingiu 0,75 e 0,74 para SSP2-4.5 e SSP5-8.5, respectivamente. Esse aprimoramento refletiu no índice geral KGE, que atingiu 0,75 no SSP2-4.5 e 0,74 no SSP5-8.5. Após a correção, o desempenho geral das simulações foi classificado como "confiável", "bom" e "excelente". Ressaltando-se a importância de corrigir vazões simuladas por modelos que utilizam projeções climáticas provenientes de GCMs.

#### 4.3 PERÍODO FUTURO

##### 4.3.1 Closed Loop -Simulação das vazões sob influência das mudanças climáticas

As equações de correção de viés (na Figura 20) foram aplicadas às vazões simuladas entre 2022 a 2100, considerando os cenários climáticos SSP2-4.5 e SSP5-8.5, respectivamente. Assim, as Figuras 22 e 23 apresentam os hidrogramas para o período de referência (2009 a 2021), e futuro (2022 a 2100). Esses gráficos ilustram o comportamento das vazões simuladas pela RNN-NARX, a partir das precipitações simuladas pelo GFDL-ESM4.

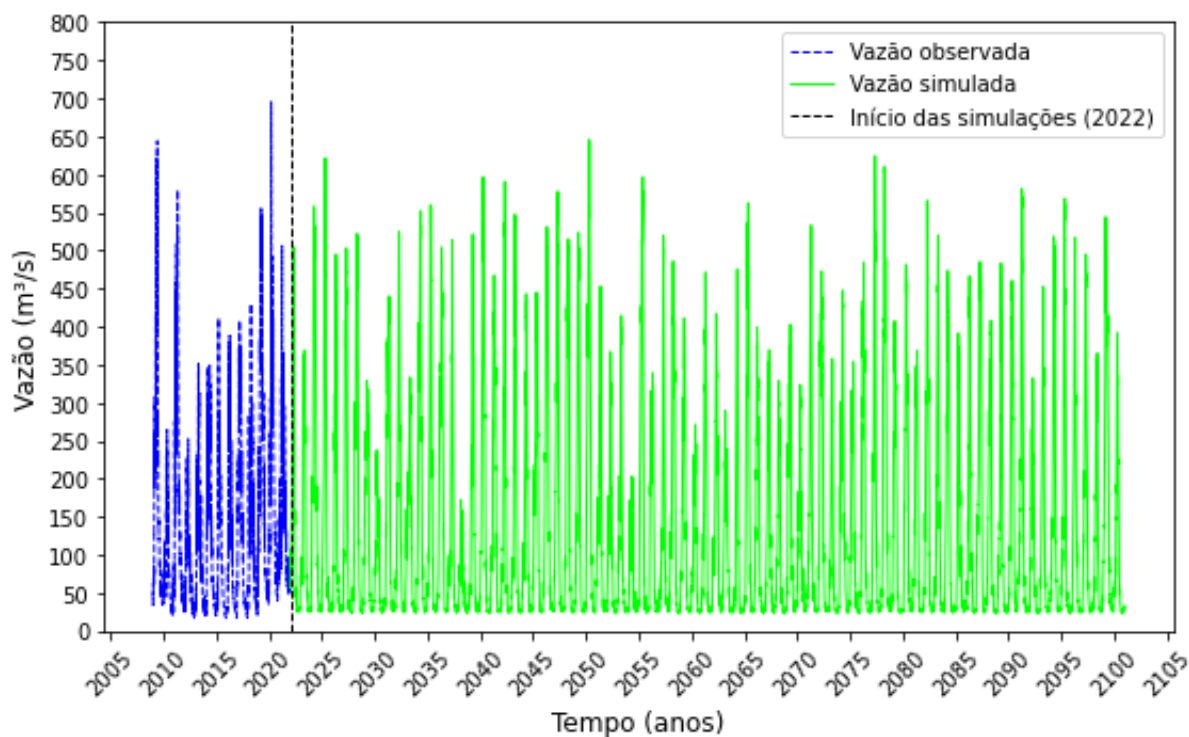


Figura 22: Vazão simulada para o cenário SSP2-4.5 para o período futuro (2022-2100)

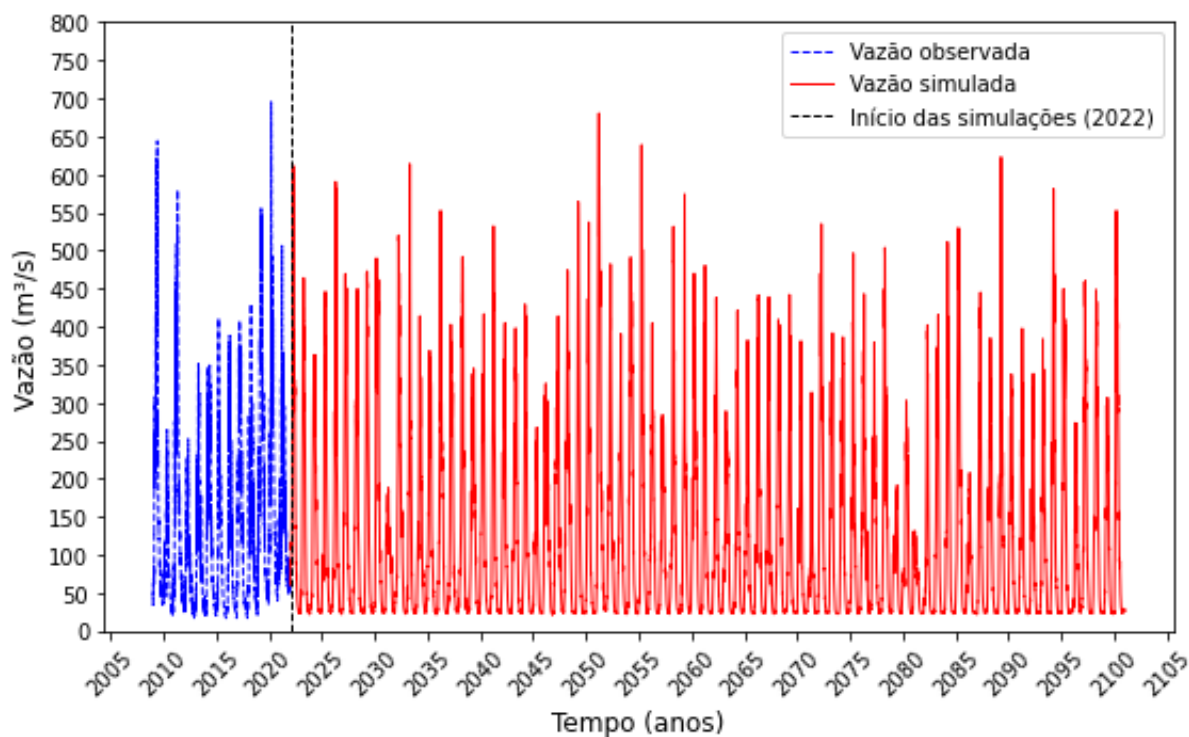


Figura 23: Vazão simulada para o cenário SSP5-8.5 para o período futuro (2022-2100)

Observam-se as variações nas vazões mínimas e máximas, tanto no cenário de médias emissões (SSP2-4.5), quanto no cenário de altas emissões (SSP5-8.5),

apresentadas na Figura 22 e Figura 23, respectivamente. As variações nas vazões máximas são mais perceptíveis, pois essas vazões são mais dependentes de fenômenos meteorológicos, tais como a Zona de Convergência Intertropical (ZCIT) e a Zona de Convergência do Atlântico Sul (ZCAS) que atuam na Amazônia durante a estação chuvosa (Amanajás e Braga, 2012; Moura e Vitorino 2012). Por outro lado, as vazões mínimas, com variações menos perceptíveis, ocorrem durante a estiagem e estão diretamente relacionadas ao volume de água subterrânea armazenado nas cheias. Isso se deve às características da sub-bacia do rio Guamá, que favorecem a infiltração por conta dos solos profundos e da baixa declividade (Mendonça et al., 2021). De qualquer forma, é importante considerar que a variação das vazões, pelo menos nas próximas duas décadas, pode estar diretamente associada aos impactos das mudanças climáticas. Isso porque estima-se que, até 2040, a temperatura global atingirá um aumento de até 2°C em relação aos níveis pré-industriais, conforme destacado por Park et al. (2022). Essa elevação térmica pode influenciar significativamente os padrões hidrológicos, alterando a disponibilidade e a distribuição dos recursos hídricos. A seguir, as vazões simuladas são apresentadas na Figura 24, distribuídas por mês, para ambos os cenários.

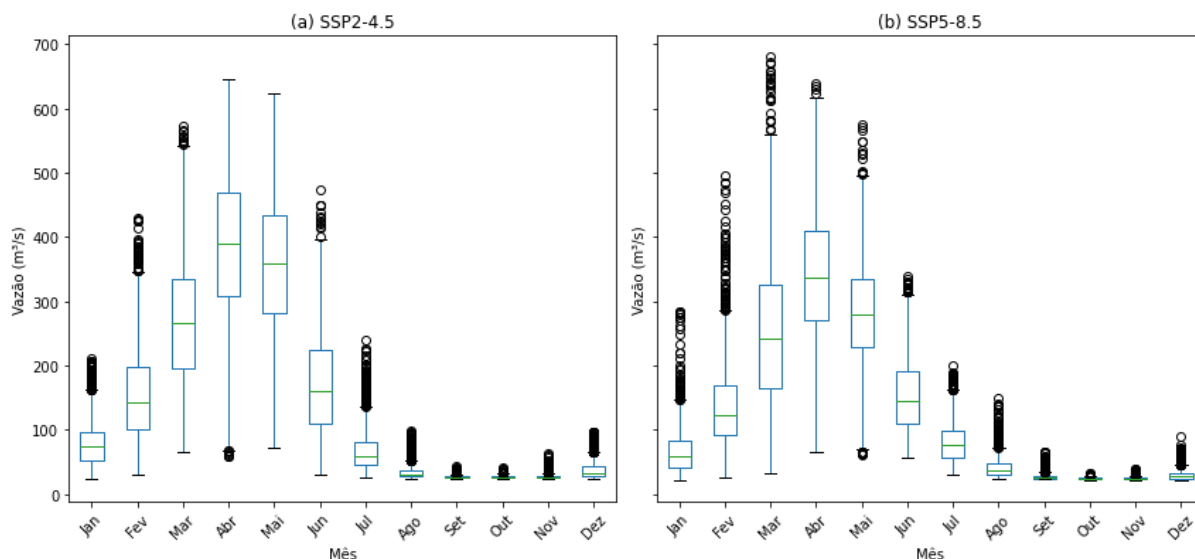


Figura 24: Distribuição das vazões simuladas por mês para o cenário SSP2-4.5 (a) e SSP5-8.5 (b), no período futuro (2022 a 2100)

A Figura 24 apresenta a distribuição das vazões simuladas por mês para os cenários SSP2-4.5 e SSP5-8.5 no período de 2022 a 2100. Comparando-se os cenários, observa-se que ambos os cenários exibem um padrão sazonal semelhante, com maiores vazões concentradas entre os meses de janeiro e junho e menores

vazões entre julho e dezembro. No entanto, o SSP5-8.5 (Figura 24-b), que representa um cenário de emissões mais intensas, apresenta uma maior variabilidade nas vazões, evidenciada pela maior dispersão dos valores e presença de mais outliers. Esses resultados sugerem que mudanças climáticas mais severas podem resultar em eventos hidrológicos extremos mais frequentes e intensos.

#### 4.4 ANÁLISE DE TENDÊNCIA NAS VAZÕES SIMULADAS

A Figura 25 mostra a análise de tendência através do método MK, que foi aplicado às vazões médias anuais observadas (2009 a 2021) e vazões simuladas a partir de 2022, sob os cenários SSP2-4.5 e SSP5-8.5.

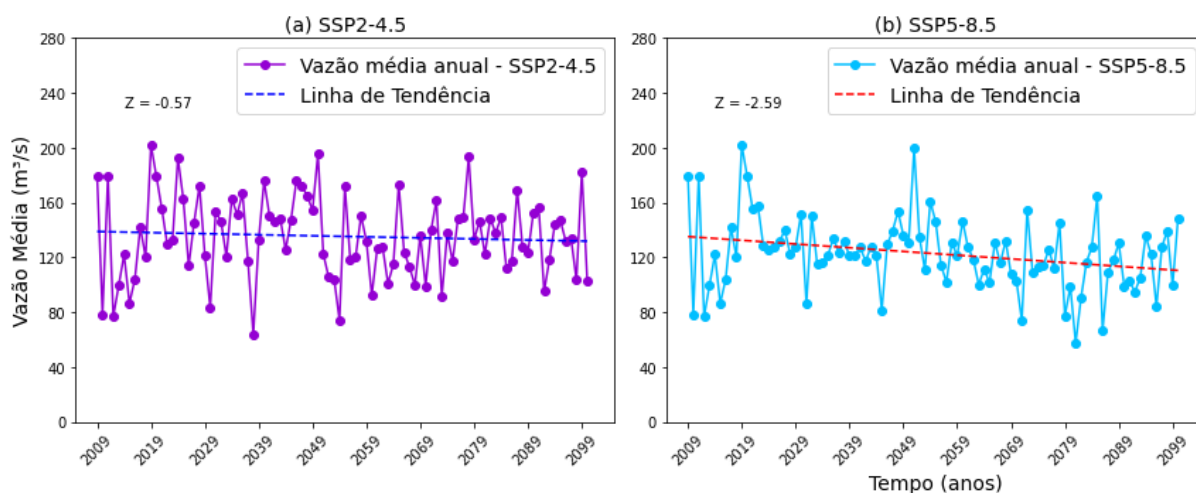


Figura 25: Tendência das vazões médias anuais para os cenários SSP2-4.5 (a) e SSP5-8.5 (b)

A partir da Figura 25, obtêm-se as tendências das vazões médias, para o futuro, nos cenários climáticos SSP2-4.5 (médias emissões) e SSP5-8.5 (altas emissões). No cenário SSP2-4.5, não foi identificada uma tendência significativa nas vazões, apesar de decrescente, conforme os resultados do teste MK ( $Z = -0,57$ ;  $p\text{-valor}=0,569$ ) e estimador de Sen de  $-0,077 \text{ m}^3/\text{s}$ . Esses resultados indicam estabilidade no regime hidrológico. Outrossim, o coeficiente de variação (CV) de 22,11% sugere uma variabilidade moderada, mas sem mudanças relevantes ao longo do tempo. Em contraste, no cenário SSP5-8.5, foi detectada uma tendência decrescente significativa, com base nos resultados do teste MK ( $Z=-2,59$ ;  $p\text{-valor}=0,00968$ ) e estimador de Sen de  $-0,271 \text{ m}^3/\text{s}$ , apontando para uma redução gradual nas vazões. O CV de 21,76% mostra uma variabilidade semelhante ao cenário de médias emissões, porém em um contexto de declínio na disponibilidade hídrica da sub-bacia

hidrográfica do rio Guamá. Esses resultados destacam que, enquanto o cenário de emissões médias mantém a estabilidade das vazões, o cenário de altas emissões pode levar a impactos hidrológicos adversos, com redução na disponibilidade de água na sub-bacia, reforçando a importância de políticas de mitigação das mudanças climáticas para preservar os recursos hídricos.

## 5 CONCLUSÃO

O presente estudo demonstrou o bom desempenho de um modelo hidrológico via aprendizado de máquina com RNA, em particular a RNN-NARX, ao estimar vazão em cenários de mudanças climáticas, em uma bacia hidrográfica da Amazônia. As vazões simuladas apresentaram os padrões sazonais dos dados observados, todavia ocorre subestimação nas magnitudes dos eventos máximos, associado à subestimação presente nas projeções das precipitações, que são os vetores de entrada do modelo. A subestimação é resultante de vieses provenientes dos GCMs. Esses vieses foram corrigidos através do método EQM, resultando em melhores métricas de desempenho determinadas entre vazões observadas e simuladas, tendo como entradas as precipitações projetadas nos cenários SSP2-4.5 e SSP5-8.5 para o período de referência (2009-2021). Nesse caso o desempenho da modelagem foi classificado como “confiável”, “bom” e “excelente” com valores de FIT de ~0,9 e KGE de 0,74-0,75 em ambos os cenários (SSP2-4.5 e SSP5-8.5). A correção de viés, também, foi aplicada à simulação das vazões de longo prazo, i.e., de 2022 a 2100, considerando os dois cenários supramencionados, permitindo a análise de tendência das vazões resultantes. Assim, no cenário SSP2-4.5 (emissões médias), não foi identificada uma tendência significativa nas vazões, com um estimador de Sen de -0,07704, os resultados do teste MK ( $Z = -0,57$ ;  $p\text{-valor}=0.569$ ), indicando estabilidade no regime hidrológico. O coeficiente de variação (CV) de 22,11% sugere uma variabilidade moderada, mas sem mudanças relevantes ao longo do tempo. Em contraste, no cenário SSP5-8.5 (emissões altas), foi detectada uma tendência decrescente significativa, com um estimador de Sen de -0,27110, os resultados do teste MK ( $Z=-2,59$ ;  $p\text{-valor}=0.00968$ ), apontando para uma redução gradual nas vazões médias anuais. O CV de 21,76% mostra uma variabilidade semelhante ao cenário SSP2-4.5, porém em um contexto de declínio na disponibilidade hídrica da sub-bacia hidrográfica do Rio Guamá. A simulação e análise de vazões futuras sob a influência das mudanças climáticas devem ser popularizadas, visando fomentar políticas públicas e estratégias de adaptação frente ao aquecimento global.

## REFERÊNCIAS

Abdulkadir, T., Salami, A., Anwar, A., Kareem, A. (2013). Modelling of Hydropower Reservoir Variables for Energy Generation: Neural Network Approach. Ethiopian Journal of Environmental Studies and Management, 6(3). <https://doi.org/10.4314/ejesm.v6i3.12>

Abu Yazid, M. H., Haikal Satria, M., Talib, S., Azman, N. (2018). Artificial Neural Network Parameter Tuning Framework For Heart Disease Classification. 2018 5th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI), 674–679. <https://doi.org/10.1109/EECSI.2018.8752821>

Alexandre, A., Martins, E. (2005). Regionalização de Vazões Médias de Longo Período Para o Estado do Ceará. Revista Brasileira de Recursos Hídricos, 10(3), 93–102. <https://doi.org/10.21168/rbrh.v10n3.p93-102>

ANA. Agência Nacional de Águas e Saneamento Básico. (2015). Conjuntura dos Recursos Hídricos no Brasil: regiões hidrográficas brasileiras. <https://www.snirh.gov.br/portal/snirh/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/regioeshidrograficas2014.pdf>

ANA. Agência Nacional de Águas e Saneamento Básico. (2024). Conjuntura dos recursos hídricos no Brasil 2023: informe anual. <https://www.snirh.gov.br/portal/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/conjunturainforme2023.pdf>

ANA. Agência Nacional de Águas e Saneamento Básico. Nota Técnica nº 16/2016/SPR (2016). : Definição da base de referência de Disponibilidade Hídrica Superficial Disponível em: [https://metadados.snirh.gov.br/geonetwork/srv/api/records/0c75f8eb-f5c7-4643-9f91-5bf86a09fb63/attachments/NOTA\\_TECNICA\\_Disphidric.pdf](https://metadados.snirh.gov.br/geonetwork/srv/api/records/0c75f8eb-f5c7-4643-9f91-5bf86a09fb63/attachments/NOTA_TECNICA_Disphidric.pdf).

Andréassian, V., Perrin, C., Michel, C. (2004). Impact of imperfect potential evapotranspiration knowledge on the efficiency and parameters of watershed models. *Journal of Hydrology*, 286(1–4), 19–35. <https://doi.org/10.1016/j.jhydrol.2003.09.030>

Angus, J. E. (1994). The Probability Integral Transform and Related Results. *SIAM Review*, 36(4), 652–654. <https://doi.org/10.1137/1036146>

Arbib, M. (1969). Review of “Perceptrons: An Introduction to Computational Geometry” (Minsky, M., and Papert, S.; 1969). *IEEE Transactions on Information Theory*, 15(6), 738–739. <https://doi.org/10.1109/TIT.1969.1054388>

Arrhenius, S. (1896). On the Influence of Carbonic Acid in the Air upon the Temperature of the Earth. *Philosophical Magazine and Journal of Science*.

Ashraf, M. S., Ahmad, I., Khan, N. M., Zhang, F., Bilal, A., Guo, J. (2021). Streamflow Variations in Monthly, Seasonal, Annual and Extreme Values Using Mann-Kendall, Spearman’s Rho and Innovative Trend Analysis. *Water Resources Management*, 35(1), 243–261. <https://doi.org/10.1007/s11269-020-02723-0>

Balaji, V. (2015). Climate Computing: The State of Play. *Computing in Science & Engineering*, 17(6), 9–13. <https://doi.org/10.1109/MCSE.2015.109>

Bao, Q., Lin, P., Zhou, T., Liu, Y., Yu, Y., Wu, G., He, B., He, J., Li, L., Li, J., Li, Y., Liu, H., Qiao, F., Song, Z., Wang, B., Wang, J., Wang, P., Wang, X., Wang, Z., ... Zhou, L. (2013). The Flexible Global Ocean-Atmosphere-Land system model, Spectral Version 2: FGOALS-s2. *Advances in Atmospheric Sciences*, 30(3), 561–576. <https://doi.org/10.1007/s00376-012-2113-9>

Baran-Gurgul, K. (2017). Stationarity of maximum low-flow periods duration in the right-bank area of the Upper Vistula catchment – Mann-Kendall versus Spearman test. *E3S Web of Conferences*, 17, 00004. <https://doi.org/10.1051/e3sconf/20171700004>

Bayer, D. M., Castro, N. M. dos R., Bayer, F. M. (2012). Modelagem e Previsão de Vazões Médias Mensais do Rio Potiribu Utilizando Modelos de Séries Temporais.

RBRH — Revista Brasileira de Recursos Hídricos, 17(2), 229–239.  
<https://doi.org/https://doi.org/10.21168/rbrh.v17n2.p229-239>

Berkeley Earth. (2024). Global temperatura Report. <https://berkeleyearth.org/global-temperature-report-for-2024/>. <https://berkeleyearth.org/global-temperature-report-for-2023/#:~:text=At%20present%2C%20Berkeley%20Earth%20shows,2023%20at%201.48%20%C2%B0C>.

Blanco, C. J., Secretan, Y., Favre, A.-C., Slivitzky, M. (2005). Modèle pluie–débit pour la simulation de courbes de débits classés sur des petits bassins non jaugés de l'Amazonie. Canadian Journal of Civil Engineering, 32(5), 803–811.  
<https://doi.org/10.1139/I05-037>

Braga, A., Carvalho, A., Ludermir, T. (2000). Redes neurais artificiais: teoria e aplicações (1a ed.). Editora LTC, 262 p.

Brasil. Lei Federal nº 9.433, de 8 de janeiro de 1997 (1997).

Boé, J., Terray, L., Habets, F., Martin, E. (2007). Statistical and dynamical downscaling of the Seine basin climate for hydro-meteorological studies. International Journal of Climatology, 27(12), 1643–1655. <https://doi.org/10.1002/joc.1602>

Bum Kim, K., Kwon, H.-H., Han, D. (2021). Bias-correction schemes for calibrated flow in a conceptual hydrological model. Hydrology Research, 52(1), 196–211.  
<https://doi.org/10.2166/nh.2021.043>

Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P. W., Trisos, C., Romero, J., Aldunce, P., Barrett, K., Blanco, G., Cheung, W. W. L., Connors, S., Denton, F., Diongue-Niang, A., Dodman, D., Garschagen, M., Geden, O., Hayward, B., Jones, C., ... Ha, M. (2023). 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. <https://doi.org/10.59327/IPCC/AR6-9789291691647>

Cannon, A. J. (2012). Neural networks for probabilistic environmental prediction: Conditional Density Estimation Network Creation and Evaluation (CaDENCE) in R. *Computers & Geosciences*, 41, 126–135. <https://doi.org/10.1016/j.cageo.2011.08.023>

Chai, T., Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>

Chow, T. V., Maidment, D. R., Mays, L. W. (1994). *Hidrología Aplicada*. McGRA W-HILL INTERAMERICANA, S.A.

Chow, V. T. (1964). *Handbook of Applied Hydrology*. Mc-Graw-Hill Book.

Clark, M. P., Kavetski, D., Fenicia, F. (2011). Pursuing the method of multiple working hypotheses for hydrological modeling. *Water Resources Research*, 47(9). <https://doi.org/10.1029/2010WR009827>

Cordeiro, I. M. C. C., Arbage, M. J. C., Schwartz, G. (2017). Nordeste do Pará: configuração atual e aspectos identitários. In *Nordeste Paraense: panorama geral e uso sustentável das florestas secundárias* (pp. 19–58). EDUFRA.

Costa, D. M., Oliveira, M. R. da S., Sodré, G. R. C., Moraes, B. C. de. (2023). Meteorologia aplicada ao manejo ambiental: processo para o uso controlado do fogo no campo. *Nature and Conservation*, 15(1), 29–39. <https://doi.org/10.6008/CBPC2318-2881.2022.001.0003>

Danabasoglu, G., Lamarque, J. -F., Bacmeister, J., Bailey, D. A., DuVivier, A. K., Edwards, J., Emmons, L. K., Fasullo, J., Garcia, R., Gettelman, A., Hannay, C., Holland, M. M., Large, W. G., Lauritzen, P. H., Lawrence, D. M., Lenaerts, J. T. M., Lindsay, K., Lipscomb, W. H., Mills, M. J., ... Strand, W. G. (2020). The Community Earth System Model Version 2 (CESM2). *Journal of Advances in Modeling Earth Systems*, 12(2). <https://doi.org/10.1029/2019MS001916>

Daniel, E. B. (2011). Watershed Modeling and its Applications: A State-of-the-Art Review. *The Open Hydrology Journal*, 5(1), 26–50. <https://doi.org/10.2174/1874378101105010026>

Debastiani, A. B., Silva, R. D., Neto, S. L. R. (2016). Eficácia da arquitetura MLP em modo closed-loop para simulação de um Sistema Hidrológico. *RBRH*, 21(4), 821–831. <https://doi.org/10.1590/2318-0331.011615124>

Devia, G. K., Ganasri, B. P., Dwarakish, G. S. (2015). A Review on Hydrological Models. *Aquatic Procedia*, 4, 1001–1007. <https://doi.org/10.1016/j.aqpro.2015.02.126>

Dooge, J. C. I. (1973). Linear Theory of Hydrologic Systems. Technical Bulletin n. 468, ARS. US Department of Agriculture.

Dunne, J. P., Horowitz, L. W., Adcroft, A. J., Ginoux, P., Held, I. M., John, J. G., Krasting, J. P., Malyshev, S., Naik, V., Paulot, F., Shevliakova, E., Stock, C. A., Zadeh, N., Balaji, V., Blanton, C., Dunne, K. A., Dupuis, C., Durachta, J., Dussin, R., ... Zhao, M. (2020). The GFDL Earth System Model Version 4.1 (GFDL-ESM 4.1): Overall Coupled Model Description and Simulation Characteristics. *Journal of Advances in Modeling Earth Systems*, 12(11). <https://doi.org/10.1029/2019MS002015>

Edwards, P. N. (2011). History of climate modeling. *WIREs Climate Change*, 2(1), 128–139. <https://doi.org/10.1002/wcc.95>

Elman, J. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211. [https://doi.org/10.1016/0364-0213\(90\)90002-E](https://doi.org/10.1016/0364-0213(90)90002-E)

Fabio, D. N., Abba, S. I., Pham, B. Q., Towfiqul Islam, A. R. Md., Talukdar, S., Francesco, G. (2022). Groundwater level forecasting in Northern Bangladesh using nonlinear autoregressive exogenous (NARX) and extreme learning machine (ELM) neural networks. *Arabian Journal of Geosciences*, 15(7), 647. <https://doi.org/10.1007/s12517-022-09906-6>

Farber, R. (2011). CUDA for Machine Learning and Optimization. Em CUDA Application Design and Development (p. 33–61). Elsevier. <https://doi.org/10.1016/B978-0-12-388426-8.00002-1>

Fekete, B. M., Vörösmarty, C. J., Grabs, W. (2002). High-resolution fields of global runoff combining observed river discharge and simulated water balances. *Global Biogeochemical Cycles*, 16(3). <https://doi.org/10.1029/1999GB001254>

Fourier, J. (1824). Remarques Générales sur les Températures du Globe Terrestre et des Espaces Planétaires. *Annales de Chimie et de Physique*.

Gauthier, T. (2001). Detecting Trends Using Spearman's Rank Correlation Coefficient. *Environmental Forensics*, 2(4), 359–362. <https://doi.org/10.1006/enfo.2001.0061>

Ghose, D., Das, U., Roy, P. (2018). Modeling response of runoff and evapotranspiration for predicting water table depth in arid region using dynamic recurrent neural network. *Groundwater for Sustainable Development*, 6, 263–269. <https://doi.org/10.1016/j.gsd.2018.01.007>

Gleditsch, N. P. (2020). Lewis Fry Richardson—A Pioneer Not Forgotten. In: Lewis Fry Richardson: His Intellectual Legacy and Influence in the Social Sciences. Springer.

Goring, D. G. (1984). Flood routing by a linear systems analysis technique. *Journal of Hydrology*, 69, 59–76.

Gramelsberger, G. (2010). Conceiving processes in atmospheric models—general equations, subscale parameterizations, and 'superparameterizations'. *Studies in History and Philosophy of Modern Physics*, 41, 233–241.

Grünig, M., Razavi, E., Calanca, P., Mazzi, D., Wegner, J. D., Pellissier, L. (2021). Applying deep neural networks to predict incidence and phenology of plant pests and diseases. *Ecosphere*, 12(10). <https://doi.org/10.1002/ecs2.3791>

Gudmundsson, L., Bremnes, J. B., Haugen, J. E., Engen Skaugen, T. (2012). Technical Note: Downscaling RCM precipitation to the station scale using quantile mapping – a comparison of methods. <https://doi.org/10.5194/hessd-9-6185-2012>

Gupta, H. V., Kling, H., Yilmaz, K. K., Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>

Gutjahr, O., Putrasahan, D., Lohmann, K., Jungclaus, J. H., von Storch, J.-S., Brüggemann, N., Haak, H., Stössel, A. (2019). Max Planck Institute Earth System Model (MPI-ESM1.2) for the High-Resolution Model Intercomparison Project (HighResMIP). *Geoscientific Model Development*, 12(7), 3241–3281. <https://doi.org/10.5194/gmd-12-3241-2019>

Guzman, S. M., Paz, J. O., Tagert, M. L. M. (2017). The Use of NARX Neural Networks to Forecast Daily Groundwater Levels. *Water Resources Management*, 31(5), 1591–1603. <https://doi.org/10.1007/s11269-017-1598-5>

Hamed, K. H. (2009). Exact distribution of the Mann–Kendall trend test statistic for persistent data. *Journal of Hydrology*, 365(1–2), 86–94. <https://doi.org/10.1016/j.jhydrol.2008.11.024>

Hamed, K. H. (2016). The distribution of Spearman's rho trend statistic for persistent hydrologic data. *Hydrological Sciences Journal*, 61(1), 214–223. <https://doi.org/10.1080/02626667.2014.968573>

Haykin, S. S. (2009). *Neural Networks and Learning Machines* (3rd ed). Pearson International Edition.

Hebb, D. O. (1949). *The organization of behavior; a neuropsychological theory* (Vol. 62). A Wiley Book in Clinical Psychology.

Held, I. M., Guo, H., Adcroft, A., Dunne, J. P., Horowitz, L. W., Krasting, J., Shevliakova, E., Winton, M., Zhao, M., Bushuk, M., Wittenberg, A. T., Wyman, B., Xiang, B., Zhang, R., Anderson, W., Balaji, V., Donner, L., Dunne, K., Durachta, J., Zadeh, N. (2019). Structure and Performance of GFDL's CM4.0 Climate Model. *Journal of Advances in Modeling Earth Systems*, 11(11), 3691–3727. <https://doi.org/10.1029/2019MS001829>

Helsel, D. R., Hirsch, R. M., Ryberg, K. R., Archfield, S. A., Gilroy, E. J. (2020). Statistical methods in water resources. <https://doi.org/10.3133/tm4A3>

Hirsch, R. M., Alexander, R. B., Smith, R. A. (1991). Selection of methods for the detection and estimation of trends in water quality. *Water Resources Research*, 27(5), 803–813. <https://doi.org/10.1029/91WR00259>

Holthuijzen, M., Beckage, B., Clemins, P. J., Higdon, D., Winter, J. M. (2022). Robust bias-correction of precipitation extremes using a novel hybrid empirical quantile-mapping method. *Theoretical and Applied Climatology*, 149(1–2), 863–882. <https://doi.org/10.1007/s00704-022-04035-2>

Hornik, K., Stinchcombe, M., White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)

IPCC. (1990). The IPCC scientific assessment.

IPCC. (1992). First Assessment Report Overview and Policymaker Summaries and 1992 IPCC Supplement.

IPCC. (2021). *Mudanças Climáticas 2021: A Base da Ciência Física* (eds Masson-Delmotte, V. et al.). <https://www.ipcc.ch/report/ar6/wg1/#FullReport> (Cambridge Univ. Press, 2021).

Izady, A., Davary, K., Alizadeh, A., Moghaddam Nia, A., Ziaei, A. N., Hasheminia, S. M. (2013). Application of NN-ARX Model to Predict Groundwater Levels in the

Neishaboor Plain, Iran. *Water Resources Management*, 27(14), 4773–4794.  
<https://doi.org/10.1007/s11269-013-0432-y>

Jones, N. (2023). When will global warming actually hit the landmark 1.5 oC limit? *Nature*, 618(7963), 20–20. <https://doi.org/10.1038/d41586-023-01702-w>

Kattenborn, T., Leitloff, J., Schiefer, F., Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49.  
<https://doi.org/10.1016/j.isprsjprs.2020.12.010>

Kendall, M. G. (1975). *Rank Correlation Methods*. Griffin.

Kouwen, N. (2000). WATFLOOD/SPL9: Hydrological Model & Flood Forecasting System.

Kouwen, N., Soulis, E. D., Pietroniro, A., Donald, J., Harrington, R. A. (1993). Grouped Response Units for Distributed Hydrologic Modeling. *Journal of Water Resources Planning and Management*, 119(3), 289–305. [https://doi.org/10.1061/\(ASCE\)0733-9496\(1993\)119:3\(289\)](https://doi.org/10.1061/(ASCE)0733-9496(1993)119:3(289))

Kovacs, Z. (2002). *Redes neurais artificiais: fundamentos e aplicações* (2a ed.). Editora Livraria da Física.

Labat, D., Ababou, R., Mangin, A. (2000). Rainfall–runoff relations for karstic springs. Part I: convolution and spectral analyses. *Journal of Hydrology*, 238(3–4), 123–148.  
[https://doi.org/10.1016/S0022-1694\(00\)00321-8](https://doi.org/10.1016/S0022-1694(00)00321-8)

Leimbach, M., Kriegler, E., Roming, N., Schwanitz, J. (2017). Future growth patterns of world regions – A GDP scenario approach. *Global Environmental Change*, 42, 215–225. <https://doi.org/https://doi.org/10.1016/j.gloenvcha.2015.02.005>

Li, H., Sheffield, J., Wood, E. F. (2010). Bias correction of monthly precipitation and temperature fields from Intergovernmental Panel on Climate Change AR4 models

using equidistant quantile matching. *Journal of Geophysical Research: Atmospheres*, 115(D10). <https://doi.org/10.1029/2009JD012882>

Li, L., Yu, Y., Tang, Y., Lin, P., Xie, J., Song, M., Dong, L., Zhou, T., Liu, L., Wang, L., Pu, Y., Chen, X., Chen, L., Xie, Z., Liu, H., Zhang, L., Huang, X., Feng, T., Zheng, W., ... Wei, J. (2020). The Flexible Global Ocean-Atmosphere-Land System Model Grid-Point Version 3 (FGOALS-g3): Description and Evaluation. *Journal of Advances in Modeling Earth Systems*, 12(9). <https://doi.org/10.1029/2019MS002012>

Lin, T., Horne, B. G., Giles, C. L. (1998). How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies. *Neural Networks*, 11(5), 861–868. [https://doi.org/10.1016/S0893-6080\(98\)00018-5](https://doi.org/10.1016/S0893-6080(98)00018-5)

Lovato, T., Peano, D., Butenschön, M., Materia, S., Iovino, D., Scoccimarro, E., Fogli, P. G., Cherchi, A., Bellucci, A., Gualdi, S., Masina, S., Navarra, A. (2022). CMIP6 Simulations With the CMCC Earth System Model (CMCC-ESM2). *Journal of Advances in Modeling Earth Systems*, 14(3). <https://doi.org/10.1029/2021MS002814>

Mai, J., Shen, H., Tolson, B. A., Gaborit, É., Arsenault, R., Craig, J. R., Fortin, V., Fry, L. M., Gauch, M., Klotz, D., Kratzert, F., O'Brien, N., Princz, D. G., Rasiya Koya, S., Roy, T., Seglenieks, F., Shrestha, N. K., Temgoua, A. G. T., Vionnet, V., Waddell, J. W. (2022). The Great Lakes Runoff Intercomparison Project Phase 4: the Great Lakes (GRIP-GL). *Hydrology and Earth System Sciences*, 26(13), 3537–3572. <https://doi.org/10.5194/hess-26-3537-2022>

Mapbiomas Brasil. Coleções. Cobertura e Uso da Terra (Coleção 9). Acesso em: dez. 2024. Disponível em: <https://brasil.mapbiomas.org/colecoes-mapbiomas/>.

Maraun, D., Wetterhall, F., Ireson, A. M., Chandler, R. E., Kendon, E. J., Widmann, M., Brien, S., Rust, H. W., Sauter, T., Themeßl, M., Venema, V. K. C., Chun, K. P., Goodess, C. M., Jones, R. G., Onof, C., Vrac, M., Thiele-Eich, I. (2010). Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics*, 48(3), RG3003. <https://doi.org/10.1029/2009RG000314>

Marengo, J. A., Souza, C. M., Thonicke, K., Burton, C., Halladay, K., Betts, R. A., Alves, L. M., Soares, W. R. (2018). Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends. *Frontiers in Earth Science*, 6. <https://doi.org/10.3389/feart.2018.00228>

Marengo, J. A., Cunha, A. P., Espinoza, J. C., Fu, R., Schöngart, J., Jimenez, J. C., ... & Zhao, S. (2024). The drought of Amazonia in 2023-2024. *American Journal of Climate Change*, 13(03), 567-597. <https://doi.org/10.4236/ajcc.2024.133026>

Markstrom, S. L., Regan, R. S., Hay, L. E., Viger, R. J., Webb, R. M. T., Payn, R. A., LaFontaine, J. H. (2015). PRMS-IV, the Precipitation-Runoff Modeling System, Version 4. <https://doi.org/10.3133/tm6B7>

McCulloch, W. S., Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>

McSweeney, C. F., Jones, R. G. (2016). How representative is the spread of climate projections from the 5 CMIP5 GCMs used in ISI-MIP? *Climate Services*, 1, 24–29. <https://doi.org/10.1016/j.cliser.2016.02.001>

McWilliams, J. C. (2019). A Perspective on the Legacy of Edward Lorenz. *Earth and Space Science*, 6(3), 336–350. <https://doi.org/10.1029/2018EA000434>

Mendonça, L. M., Blanco, C. J. C., Cruz, J. da S. (2024). Performance and projections of the NEX-GDDP-CMIP6 in simulating precipitation in the Brazilian Amazon and Cerrado biomes. *International Journal of Climatology*, 44(11), 3726–3741. <https://doi.org/10.1002/joc.8547>

Melsen, L., Teuling, A., Torfs, P., Zappa, M., Mizukami, N., Clark, M., Uijlenhoet, R. (2016). Representation of spatial and temporal variability in large-domain hydrological models: case study for a mesoscale pre-Alpine basin. *Hydrology and Earth System Sciences*, 20(6), 2207–2226. <https://doi.org/10.5194/hess-20-2207-2016>

Mendonça, L. M., Blanco, C. J. C., Oliveira, F. C. (2023). Recurrent neural networks for rainfall-runoff modeling of small Amazon catchments. *Modeling Earth Systems and Environment*, 9(2), 2517–2531. <https://doi.org/10.1007/s40808-022-01626-w>

Mendonça, L., Gomide, I., Sousa, J., Blanco, C. (2021). Modelagem chuva-vazão via redes neurais artificiais para simulação de vazões de uma bacia hidrográfica da Amazônia. *Revista de Gestão de Água da América Latina*, 18(1), 2–0. <https://doi.org/10.21168/reg.v18e2>

Menezes, J. M. P., Barreto, G. A. (2008). Long-term time series prediction with the NARX network: An empirical evaluation. *Neurocomputing*, 71(16–18), 3335–3343. <https://doi.org/10.1016/j.neucom.2008.01.030>

Mulvaney, T. J. (1851). On the use of self-registering rain and flood gauges in making observations of the relations of rainfall and flood discharges in a catchment (Vol. 4). Transactions - Institution of Civil Engineers of Ireland.

Nações Unidas. (2015). Acordo de Paris (Vol. 55, Número 7, p. 111). [https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/acordo-de-paris-e-ndc/arquivos/pdf/acordo\\_paris.pdf](https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/publicacoes/acordo-de-paris-e-ndc/arquivos/pdf/acordo_paris.pdf)

Naghattini, M., Pinto, É. J. de A. (2007). Hidrologia estatística. CPRM- Serviço Geológico do Brasil.

Nouri, M., Homaei, M. (2018). On modeling reference crop evapotranspiration under lack of reliable data over Iran. *Journal of Hydrology*, 566, 705–718. <https://doi.org/10.1016/j.jhydrol.2018.09.037>

Nouri, M., Veysi, S. (2024). CMIP6 multi-model ensemble projection of reference evapotranspiration using machine learning algorithms. *Agricultural Water Management*, 306, 109190. <https://doi.org/10.1016/j.agwat.2024.109190>

O'Neill, B. C., Tebaldi, C., van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J.-F., Lowe, J., Meehl, G. A., Moss, R., Riahi, K.,

Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geoscientific Model Development*, 9(9), 3461–3482. <https://doi.org/10.5194/gmd-9-3461-2016>

Oki, T., Kanae, S. (2006). Global Hydrological Cycles and World Water Resources. *Science*, 313(5790), 1068–1072. <https://doi.org/10.1126/science.1128845>

Papazafiriou, Z. G. (1976). Linear and nonlinear approaches for short-term runoff estimations in time-invariant open hydrologic systems. *Journal of Hydrology*, 30(1–2), 63–80. [https://doi.org/10.1016/0022-1694\(76\)90089-5](https://doi.org/10.1016/0022-1694(76)90089-5)

Pechlivanidis, I. G., Jackson, B. M., McIntyre, N. R., Wheeler, H. S. (2013). Catchment scale hydrological modelling: A review of model types, calibration approaches and uncertainty analysis methods in the context of recent developments in technology and applications. *Global NEST Journal*, 13(3), 193–214. <https://doi.org/10.30955/gnj.000778>

Peel, M. C., McMahon, T. A. (2020). Historical development of rainfall-runoff modeling. *WIREs Water*, 7(5). <https://doi.org/10.1002/wat2.1471>

Phillips, N. A. (1956). The general circulation of the atmosphere: A numerical experiment. *Quarterly Journal of the Royal Meteorological Society*, 82(352), 123–164. <https://doi.org/10.1002/qj.49708235202>

Piani, C., Weedon, G. P., Best, M., Gomes, S. M., Viterbo, P., Hagemann, S., Haerter, J. O. (2010). Statistical bias correction of global simulated daily precipitation and temperature for the application of hydrological models. *Journal of Hydrology*, 395(3–4), 199–215. <https://doi.org/10.1016/j.jhydrol.2010.10.024>

Reichle, R. H., Koster, R. D. (2004). Bias reduction in short records of satellite soil moisture. *Geophysical Research Letters*, 31(19). <https://doi.org/10.1029/2004GL020938>

Rezaeian Zadeh, M., Amin, S., Khalili, D., Singh, V. P. (2010). Daily Outflow Prediction by Multi-layer Perceptron with Logistic Sigmoid and Tangent Sigmoid Activation Functions. *Water Resources Management*, 24(11), 2673–2688. <https://doi.org/10.1007/s11269-009-9573-4>

Rodriguez, I. (1967). The application of cross-spectral analysis to hydrologic time series. *Hydrology Papers*, Colorado State University, Fort Collins, 24.

Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back-Propagating Errors. In *Cognitive Modeling* (pp. 213–222). The MIT Press. <https://doi.org/10.7551/mitpress/1888.003.0013>

Saavedra, D., Mendoza, P. A., Addor, N., Llauca, H., Vargas, X. (2022). A multi-objective approach to select hydrological models and constrain structural uncertainties for climate impact assessments. *Hydrological Processes*, 36(1). <https://doi.org/10.1002/hyp.14446>

Sahoo, S., Jha, M. K. (2013). Groundwater-level prediction using multiple linear regression and artificial neural network techniques: a comparative assessment. *Hydrogeology Journal*, 21(8), 1865–1887. <https://doi.org/10.1007/s10040-013-1029-5>

Scoccimarro, E., Peano, D., Gualdi, S., Bellucci, A., Lovato, T., Fogli, P. G., Navarra, A. (2022). Extreme events representation in CMCC-CM2 standard and high-resolution general circulation models. *Geoscientific Model Development*, 15(4), 1841–1854. <https://doi.org/10.5194/gmd-15-1841-2022>

Sen, P. K. (1968). Estimates of the Regression Coefficient Based on Kendall's Tau. *Journal of the American Statistical Association*, 63(324), 1379–1389. <https://doi.org/10.1080/01621459.1968.10480934>

Sherman, Jack. (1932). Crystal Energies of Ionic Compounds and Thermochemical Applications. *Chemical Reviews*, 11(1), 93–170. <https://doi.org/10.1021/cr60038a002>

Shiklomanov, I. A. (1998). World water resources: a new appraisal and assessment for the 21st century: a summary of the monograph World water resources. UNESCO.

Silva, E. V. A., Oliveira, N. S., Ferreira, R. T., Silva, C. C. (2018). Média móvel e a Curva de Phillips: previsões para a taxa de inflação em uma amostra de países desenvolvidos e em desenvolvimento. *Nova Economia*, 28(2), 499–521. <https://doi.org/10.1590/0103-6351/3102>

Singh, V. P. (1995). Computer models of watershed Hydrology. Baton Rouge: Water Resources Publications.

Sit, M., Demiray, B. Z., Xiang, Z., Ewing, G. J., Sermet, Y., Demir, I. (2020). A Comprehensive Review of Deep Learning Applications in Hydrology and Water Resources. *Water Science & Technology*, 82(12), 2635–2370. <https://doi.org/https://doi.org/10.2166/wst.2020.369>

Sola, J., Sevilla, J. (1997). Importance of input data normalization for the application of neural networks to complex industrial problems. *IEEE Transactions on Nuclear Science*, 44(3), 1464–1468. <https://doi.org/10.1109/23.589532>

Spearman, C. (1904). The Proof and Measurement of Association between Two Things. *The American Journal of Psychology*, 15(1), 72. <https://doi.org/10.2307/1412159>

Steel, R. G., James H. Torrie. (1981). Principles and procedures of statistics, a biometrical approach (2o ed).

Tebaldi, C., Debeire, K., Eyring, V., Fischer, E., Fyfe, J., Friedlingstein, P., Knutti, R., Lowe, J., O'Neill, B., Sanderson, B., van Vuuren, D., Riahi, K., Meinshausen, M., Nicholls, Z., Tokarska, K. B., Hurtt, G., Kriegler, E., Lamarque, J.-F., Meehl, G., ... Ziehn, T. (2021). Climate model projections from the Scenario Model Intercomparison

Project (ScenarioMIP) of CMIP6. *Earth System Dynamics*, 12(1), 253–293.  
<https://doi.org/10.5194/esd-12-253-2021>

Teutschbein, C., Seibert, J. (2012). Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*, 456–457, 12–29.  
<https://doi.org/10.1016/j.jhydrol.2012.05.052>

Thiemeßl, M. J., Gobiet, A., Heinrich, G. (2012). Empirical-statistical downscaling and error correction of regional climate models and its impact on the climate change signal. *Climatic Change*, 112(2), 449–468. <https://doi.org/10.1007/s10584-011-0224-4>

Tollefson, J. (2025). Earth breaches 1.5 °C climate limit for the first time: what does it mean? *Nature*, 637(8047), 769–770. <https://doi.org/https://doi.org/10.1038/d41586-025-00010-9>

Tucci, C. E. M. (2005). *Modelos Hidrológicos* (2o ed). Editora da UFRGS/ABRH.

Tucci, C. E. M. (2009). *Hidrologia: ciência e aplicação* (4o ed). Editora da UFRGS/ABRH.

Tyndall, J. (1859). On the Absorption and Radiation of Heat by Gases and Vapours. *Philosophical Transactions of the Royal Society*.

Usman, M., Manzanar, R., Ndehedehe, C. E., Ahmad, B., Adeyeri, O. E., Dudzai, C. (2022). On the Benefits of Bias Correction Techniques for Streamflow Simulation in Complex Terrain Catchments: A Case-Study for the Chitral River Basin in Pakistan. *Hydrology*, 9(11), 188. <https://doi.org/10.3390/hydrology9110188>

Walpole, R. E., Myers, R. H., Ye, K. E. (2016). *Probability & Statistics for Engineers & Scientists* (Global Edition). Pearson Education.

Wang, J., Chen, Y. (2022). Using NARX neural network to forecast droughts and floods over Yangtze River Basin. *Natural Hazards*, 110(1), 225–246.  
<https://doi.org/10.1007/s11069-021-04944-x>

Waqas, M., Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. *MethodsX*, 13, 102946. <https://doi.org/10.1016/j.mex.2024.102946>

WCRP, W. C. R. P. (2024, janeiro 18). CMIP Phase 6 (CMIP6). <https://wcrp-cmip.org/cmip-phase-6-cmip6/>. <https://wcrp-cmip.org/cmip6/>

Weart, S. (2010). The development of general circulation models of climate. *Studies in History and Philosophy of Science Part B: Studies in History and Philosophy of Modern Physics*, 41(3), 208–217. <https://doi.org/10.1016/j.shpsb.2010.06.002>

Xu, Z. X., Li, J. Y., Liu, C. M. (2007). Long-term trend analysis for major climate variables in the Yellow River basin\*. *Hydrological Processes*, 21(14), 1935–1948. <https://doi.org/10.1002/hyp.6405>

Xu, Z. X., Takeuchi, K., Ishidaira, H. (2003). Monotonic trend and step changes in Japanese precipitation. *Journal of Hydrology*, 279(1–4), 144–150. [https://doi.org/10.1016/S0022-1694\(03\)00178-1](https://doi.org/10.1016/S0022-1694(03)00178-1)

Yadav, N., Yadav, A., Kumar, M. (2015). *An Introduction to Neural Network Methods for Differential Equations*. Springer.

Yevjevich, V. (1993). General Introduction to Application of Stochastic Hydrology in Water Resources (J. B. Marco, R. Harboe, J. D. Salas, Orgs.). *Water Resources Systems Simulation and Optimization*. Kluwer Academic Publishers.

Yonaba, H., Anctil, F., Fortin, V. (2010). Comparing Sigmoid Transfer Functions for Neural Network Multistep Ahead Streamflow Forecasting. *Journal of Hydrologic Engineering*, 15(4), 275–283. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000188](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000188)

Yu, J., de Antonio, A., Villalba-Mora, E. (2022). Deep Learning (CNN, RNN) Applications for Smart Homes: A Systematic Review. *Computers*, 11(2), 26. <https://doi.org/10.3390/computers11020026>

Yue, S., Pilon, P., Cavadias, G. (2002). Power of the Mann–Kendall and Spearman's rho tests for detecting monotonic trends in hydrological series. *Journal of Hydrology*, 259(1–4), 254–271. [https://doi.org/10.1016/S0022-1694\(01\)00594-7](https://doi.org/10.1016/S0022-1694(01)00594-7)

Zhang, J., Morris, A. J. (1998). A Sequential Learning Approach for Single Hidden Layer Neural Networks. *Neural Networks*, 11(1), 65–80. [https://doi.org/10.1016/S0893-6080\(97\)00111-1](https://doi.org/10.1016/S0893-6080(97)00111-1)