unesp

PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS E MEIO AMBIENTE

MODELAGEM E PROGNÓSTICO HIDROLÓGICO DE FENÔMENOS HIDROMETEOROLÓGICOS NA BACIA HIDROGRÁFICA DO RIO PARANAPANEMA, BRASIL

CARLOS ANDRES MENDEZ VALLEJO

Instituto de Geociências e Ciências Exatas
Campus de Rio Claro

Rio Claro - SP

2024

UNIVERSIDADE ESTADUAL PAULISTA
"Júlio de Mesquita Filho"
Instituto de Geociências e Ciências Exatas
Câmpus de Rio Claro

CARLOS ANDRES MENDEZ VALLEJO

MODELAGEM E PROGNÓSTICO HIDROLÓGICO DE FENÔMENOS HIDROMETEOROLÓGICOS NA BACIA HIDROGRÁFICA DO RIO PARANAPANEMA, BRASIL

Dissertação de Mestrado apresentada ao Instituto de Geociências e Ciências Exatas do Câmpus de Rio Claro, da Universidade Estadual Paulista "Júlio de Mesquita Filho", como parte dos requisitos para obtenção do título de Mestre em Geociências e Meio Ambiente.

Orientador: Prof. Dr. Rodrigo Lilla Manzione

Rio Claro - SP

2024

M538m

Mendez Vallejo, Carlos Andres

Modelagem e prognóstico hidrológico de fenômenos hidrometeorológicos na bacia hidrográfica do rio Paranapanema, Brasil / Carlos Andres Mendez Vallejo. -- Rio Claro, 2024

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Instituto de Geociências e Ciências Exatas, Rio Claro

Orientador: Rodrigo Lilla Manzione

1. Aprendizado de Máquina. 2. SIG. 3. Sensoriamento Remoto. 4. Seca. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

Impacto potencial desta pesquisa[1]

Os Objetivos de Desenvolvimento Sustentável (ODS) são uma série de iniciativas globais lideradas pela Organização Nações Unidas (ONU), composta por 17 objetivos e 169 metas que visam promover um desenvolvimento sustentável no planeta Terra até 2030. Nesse sentido, a presente dissertação intitulada "Modelagem e Prognóstico Hidrológico de Fenômenos Hidrometeorológicos na Bacia Hidrográfica do Rio Paranapanema, Brasil" visou contribuir com grande ênfase nos seguintes ODS:

ODS (2) – Fome zero e agricultura sustentável: a modelagem e previsão de futuras secas e estiagens na BHRP, ajudam a reduzir seus possíveis impactos, como a fome e a escassez de alimentos.

ODS (6) – Água potável e saneamento: os estudos de possíveis cenários de secas e estiagens na BHRP, permitem um melhor gerenciamento e gestão dos recursos hídricos em situações prováveis de escassez de água.

ODS (7) – Energia Limpa e acessível: a possível ocorrência de secas e estiagens, podem provocar uma redução ou suspensão da produção de energia limpa nas 13 Usinas Hidrelétricas (UHE) e 18 Pequenas Centrais Hidrelétricas (PCH) instaladas na BHRP. Além disso, podem representar um desafio para o Operador Nacional do Sistema Elétrico (ONS), principal responsável no fornecimento de energia na bacia.

ODS (11) – Cidades e comunidades sustentáveis: a análise de fenômenos hidrometeorológicos como secas e estiagens, ajuda mitigar a vulnerabilidade e exposição dos 247 municípios da BRHP, em relação a eventos e desastres naturais.

ODS (13) – Ação contra a mudança global do clima: a simulação de cenários futuros de secas e estiagens, permite combater as alterações e mudanças climáticas e seus impactos na BHRP.

ODS (15) – Vida terrestre: A prevenção e o combate a fenômenos associados a secas e estiagens, como a desertificação e a degradação da terra na BHRP, ajudam a preservar e recuperar de forma sustentável as áreas mais afetadas por esses eventos.

[1] De acordo com a Portaria UNESP 117-2022 e Instrução AT-PROPG Nº02 (22/12/2022), indica-se que todas as dissertações e teses, defendidas a partir dessa data, apresentem uma descrição dos impactos esperados relacionados aos 17 Objetivos do Desenvolvimento Sustentável (ODS).

Potential impact of this research

The Sustainable Development Goals (SDGs) are a series of global initiatives led by the United Nations (UN), consisting of 17 goals and 169 targets that aim to promote sustainable development on planet Earth by 2030. In this sense, this dissertation entitled "Hydrological Modeling and Forecasting of Hydrometeorological Phenomena in the Paranapanema River Basin, Brazil" aimed to contribute with great emphasis on the following SDGs:

SDG (2) - Zero hunger: modeling and forecasting future droughts and dry spells in the PRB help reduce their possible impacts, such as hunger and food shortages.

SDG (6) - Clean water and sanitation: studies of possible drought scenarios in the PRB allow for better management of water resources in likely situations of water scarcity.

SDG (7) – Affordable and clean energy: the possible occurrence of droughts and dry spells could lead to a reduction or suspension of clean energy production at the 13 Hydroelectric Power Plants (HPPs) and 18 Small Hydroelectric Power Plants (SHPs) installed in the BHRP. In addition, they could represent a challenge for the National Electricity System Operator (ONS), which is primarily responsible for supplying energy in the basin.

SDG (11) - Sustainable cities and communities: the analysis of hydro-meteorological phenomena such as droughts and dry spells helps mitigate the vulnerability and exposure of the 247 municipalities of the BRHP to natural events and disasters.

SDG (13) – Climate action: simulating future scenarios of droughts and dry spells helps combat climate change and its impacts on the BHRP.

SDG (15) - Life on land: Preventing and combating phenomena associated with droughts and dry spells, such as desertification and land degradation in the BHRP, helps to preserve and sustainably recover the areas most affected by these events.

UNIVERSIDADE ESTADUAL PAULISTA
"Júlio de Mesquita Filho"
Instituto de Geociências e Ciências Exatas
Câmpus de Rio Claro

CARLOS ANDRES MENDEZ VALLEJO

MODELAGEM E PROGNÓSTICO HIDROLÓGICO DE FENÔMENOS HIDROMETEOROLÓGICOS NA BACIA HIDROGRÁFICA DO RIO PARANAPANEMA, BRASIL

Dissertação de Mestrado apresentada ao Instituto de Geociências e Ciências Exatas do Câmpus de Rio Claro, da Universidade Estadual Paulista "Júlio de Mesquita Filho", como parte dos requisitos para obtenção do título de Mestre em Geociências e Meio Ambiente.

Comissão Examinadora

Prof. Dr. Rodrigo Lilla Manzione

FCTE/UNESP/Ourinhos (SP)

Prof. Dr. Lucas Moreira Furlan

IGCE/UNESP/Rio Claro (SP)

Profa. Dra. Bárbara Barbosa Tsuyuguchi

UFERSA/Pau dos Ferros (RN)

Conceito: Aprovado.

Rio Claro (SP), 21 de outubro de 2024.

Agradecimentos

A Deus, acima de tudo, por me guiar e acompanhar durante o desenvolvimento desta dissertação, ao povo brasileiro, em especial ao Programa de Pós-graduação em Geociências e Meio Ambiente (PPGMA) da UNESP, por me permitir realizar meus estudos de mestrado.

Ao Prof. Dr. Rodrigo Manzione, pela orientação e oportunidades oferecidas durante as diferentes etapas deste trabalho.

Ao Prof. Dr. Didier Gastmans e aos membros do Laboratório de Recursos Hídricos e Isótopos Ambientais (LARHIA), pelos conselhos e apoio na minha formação como pesquisador.

À equipe do Centro de Estudos Ambientais (CEA), pelo disposição de equipamentos, espaço e infraestrutura desde o início da minha pesquisa.

À minha família e parceiros na Colômbia, pela motivação incondicional antes, durante e depois do meu mestrado na UNESP.

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

Escúchame bien.

Dinero y miedo, son dos cosas que nunca tuve!

Resumo

As previsões espaciais e temporais dos processos que ocorrem no ciclo hidrológico para projetar cenários de secas moderadas, severas e extremas, representam um desafio importante no planejamento, na gestão e no monitoramento dos recursos hídricos. A fim de mitigar os possíveis impactos das secas sobre o ambiente natural, a sociedade civil e a biodiversidade, resultantes das mudanças climáticas e do aquecimento global, os métodos de aprendizado de máquina ou Machine Learning (ML), podem apoiar essa tarefa combinando modelos de análise espacial e temporal de futuros episódios de seca. Esta dissertação investigou a modelagem e a previsão hidrológica de fenômenos hidrometeorológicos tais como secas e estiagens, na Bacia do Rio Paranapanema (BHRP) para o período de 2023-2025. A BHRP é uma região que fornece recursos hidrológicos, energéticos e agrícolas, localizada no sudeste do Brasil, que tem sofrido vários problemas relacionados ao déficit e ao estresse hídrico, bem como secas e estiagens nos últimos 10 anos. Por essas razões, tecnologias geoespaciais, como sensoriamento remoto e Sistemas de Informações Geográficas (SIG), foram aplicadas para gerar séries temporais de precipitação e Evapotranspiração Potencial (ETP) entre 2001 e o início de 2023 para um total de 22 Unidades de Planejamento Hidrológico (UPHs) na BHRP. Posteriormente, uma Rede Neural Autorregressiva (NNAR) foi usada para prever as medias mensais de precipitação e ETP para as UPHs entre 2023 e 2025, encontrando possíveis períodos de déficit hídrico nas regiões central e norte da BHRP para os meses de maio, junho, julho e agosto de 2024 e parte de 2025. Da mesma forma, foi calculado o Índice Padronizado de Precipitação e Evapotranspiração (SPEI) em escalas trimestrais e semestrais, com base na previsão desenvolvida pela rede NNAR nas UPHs, evidenciando possíveis impactos nos setores agrícola, energético e social, como resultado de prováveis períodos prolongados de secas e estiagens na BHRP. Por fim, foi possível concluir um baixo ajuste na precisão da rede NNAR (erros entre 60 e 100 milímetros), na fase de prognóstico, o que não garante a possível ocorrência de secas na BHRP, mas fornece um diagnóstico preliminar das mesmas com vistas a um adequado monitoramento e controle dos recursos hídricos.

Palavras chave: Aprendizado de Máquina, SIG, Sensoriamento Remoto, Seca

Abstract

Spatial and temporal forecasts of the processes that occur in the hydrological cycle in order to project scenarios of moderate, severe and extreme droughts represent a major challenge in the planning, management and monitoring of water resources. In order to mitigate the possible impacts of droughts on the natural environment, civil society and biodiversity resulting from climate change and global warming, Machine Learning (ML) methods can support this task by combining spatial and temporal analysis models of future drought episodes. This dissertation investigated the modeling and hydrological forecasting of hydrometeorological phenomena such as droughts and dry spells in the Paranapanema River Basin (PRB) for the period 2023-2025. The PRB is a region that provides hydrological, energy and agricultural resources, located in southeastern Brazil, which has suffered several problems related to water deficit and stress, as well as droughts and dry spells in the last 10 years. For these reasons, geospatial technologies, such as remote sensing and Geographic Information Systems (GIS), were applied to generate time series of precipitation and Potential Evapotranspiration (ETP) between 2001 and the beginning of 2023 for a total of 22 Hydrological Planning Units (HPUs) in the PRB. Subsequently, an Autoregressive Neural Network (NNAR) was used to predict the monthly precipitation and ETP averages for the HPUs between 2023 and 2025, finding possible periods of water deficit in the central and northern regions of the PRB for the months of May, June, July and August 2024 and part of 2025. Similarly, the Standardized Precipitation and Evapotranspiration Index (SPEI) was calculated on quarterly and six-monthly scales, based on the forecast developed by the NNAR network in the HPUs, showing possible impacts on the agricultural, energy and social sectors as a result of probable prolonged periods of droughts and dry spells in the PRB. Finally, it was possible to conclude that the accuracy of the NNAR network was low (errors between 60 and 100 millimeters) in the prognosis phase, which does not guarantee the possible occurrence of droughts in the PRB, but provides a preliminary diagnosis of them with a view to adequate monitoring and control of water resources.

Key Words: Drought**,** GIS, Machine Learning, Remote Sensing

Lista de Figuras

Figura 1. Mapa localização geográfica BHRP 19
Figura 2. Classificação climática Köppen-Geiger BHRP 21
Figura 3. Ciclo hidrológico..... 25
Figura 4. Distribuição hídrica na Terra 26
Figura 5. Ocorrência anual de estiagem e seca entre 1991 e 2012..... 31
Figura 6. Uso e aplicações de GeoAI 36
Figura 7. Metodologia de trabalho 38
Figura 8. Iterações e ciclos IDW 45
Figura 9. Rede Neural Artificial Feed-Forward 46
Figura 10. Hiperparâmetros rede NNAR..... 49
Figura 11. Variação 2001-2023 precipitação e evapotranspiração potencial..... 51
Figura 12. Variação 2001-2023 índices SPI e SPEI..... 52
Figura 13. Hiperparâmetros e métricas RMSE..... 53
Figura 14. Previsão 2023-2025 precipitação e ETP 55
Figura 15. Mapa previsão da precipitação para 2023-2025..... 56
Figura 16. Mapa previsão da ETP para 2023-2025..... 58
Figura 17. Previsão Índice SPEI-3 e SPEI-6 59
Figura 18. Semana de Trabalho de Campo BHRP 63

Lista de Tabelas

Tabela 1. População Urbana, Rural e Total por UGH 18
Tabela 2. Indicadores sociais IDHM e IFDM 20
Tabela 3. Características Usinas Hidrelétricas BHRP 22
Tabela 4. Características índice SPI 40
Tabela 5. Intensidade índice SPI 41
Tabela 6. Características índice SPEI 42
Tabela 7. Intensidade índice SPEI 43
Tabela 8. Parâmetros de interpolação IDW 44
Tabela 9. Hiperparâmetros Redes NNAR 48
Tabela 10. Métrica RMSE por UPHs 54
Tabela 11. Cronograma de atividades 62

Lista de abreviaturas e siglas

ANA	Agência Nacional de Águas e Saneamento Básico
ASAS	Alta subtropical do Atlântico Sul
AR	Assessment Report
BHRP	Bacia Hidrográfica do Rio Paranapanema
RCP	Representative Concentration Pathways
CGH	Centrais Geradoras Hidrelétricas
CMIP6	Coupled Model Intercomparison Project Phase 6
DL	Deep Learning
ENOS	El Niño-Oscilação Sul
GCM	Global Climate Models
ETP	Evapotranspiração Potencial
IA	Inteligência Artificial
IDHM	Índice de Desenvolvimento Humano Municipal
IDW	Inverso da Distância Ponderada
IFDM	Índice Firjan de Desenvolvimento Municipal
IPCC	Intergovernmental Panel on Climate Change
MDE	Modelo Digital de Elevação
ML	Machine Learning
NNAR	Neural Network Autoregressive
ONI	Oceanic Niño Index
PDSI	Palmer Drought Severity Index
PIB	Produto Interno Bruto
QMLT	Vazão média de longo termo
Q7_10	Vazão média de 7 dias com tempo de retorno de 10 anos
Q95	Vazão com permanência de 95%
RNAs	Redes Neurais Artificiais
RMSE	Root Mean Square Error
scPDSI	Self-Calibrated Palmer Drought Severity Index (sc-PDSI)
SIG	Sistemas de Informações Geográficas
SPEI	Standardized Precipitation Evapotranspiration Index (SPEI)
SPI	Standardized Precipitation Index
SRES	Special Report on Emissions Scenarios
UGRHIs	Unidades de Gestão Recursos Hídricos Integradas
UPHs	Unidades de Planejamento Hídrico
UHE	Usina Hidrelétrica
ZCAS	Zona de Convergência do Atlântico Sul

Sumário

1 INTRODUÇÃO 15
2 OBJETIVOS 17
2.1 Objetivo Geral 17
2.2 Objetivos específicos 17
3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO 18
3.1 Área de estudo 18
3.2 Justificativa 23
4 MARCO TEÓRICO 25
4.1 Fundamentação Teórica 25
4.1.1 Ciclo hidrológico e distribuição hídrica 25
4.1.2 Secas e estiagens 26
4.2 Estado da arte 28
4.2.1 Secas no mundo 28
4.2.2 Secas no Brasil 30
4.2.3 Secas na BHRP 31
4.3 Marcos regulatórios 33
4.4 Inteligência Artificial e geotecnologias aplicadas às geociências 35
5 MATERIAIS E MÉTODOS 37
5.1 Aquisição de dados 39
5.2 Índices SPI e SPEI 39
5.2.1 Índice de Precipitação Padronizado (SPI) 39
5.2.2 Índice de Precipitação - Evapotranspiração Padronizado (SPEI) 41
5.3 Inverso da Distância Ponderada (IDW) 43
5.4 Rede Neural Artificial (RNA) 45
5.4.1 Rede Neural Autorregressiva (NNAR) 47
6 RESULTADOS E DISCUSSÕES 51
6.2 Análise espacial e temporal 2001 - 2023 51
6.1 Ajuste hiperparâmetros rede NNAR 53
6.3 Previsão espacial e temporal 2023 - 2025 55
6.4 Construção índice SPEI 2023-2025 59
7 CONCLUSÕES 61
8 CRONOGRAMA E ATIVIDADE ACADÊMICA 62
8.1 Cronograma de atividades 62
8.2 Atividade Acadêmica 62

9 REFERÊNCIAS BIBLIOGRÁFICAS 64
ANEXOS 75
Anexo A - Índices de secas 75
Anexo B – Códigos de programação e repositórios GitHub 76

1 INTRODUÇÃO

Na antiguidade, filósofos como Aristóteles e Teofrasto, da civilização grega, relacionaram, por meio de observações empíricas, o estado do clima para diferentes fases do ciclo hidrológico (chuva, condensação, evaporação, etc.). Dessa forma, eles previram de forma continua a possível ocorrência de períodos curtos de umidade e seca (Cunha, 1997b, 1997a; Maia; Nogueira Maia, 2010), úteis na época para a agricultura e o cultivo de alimentos. No entanto, as secas e estiagens têm sido categorizadas como uns dos riscos naturais com maior complexidade e capacidade para gerar impactos e afetações numa área geográfica durante um determinado período (Ortega Gaucin, 2013; Spinoni *et al.*, 2014; Wilhite, 2000).

A seca pode ser definida como a ausência prolongada ou déficit notável de precipitação (WMO; OMM, 1966), associada com diferentes fases do ciclo hidrológico e possuindo características como: Intensidade (I), Duração (D), Magnitude (M) e Extensão (E) (Burton *et al.*, 1993). Por esse motivo, existem vários índices que avaliam o comportamento e a evolução das secas com base em registros de temperatura, precipitação, Evapotranspiração Potencial (ETP) e umidade do solo (Svoboda; Fuchs, 2017). Alguns destes índices são o Índice de Precipitação Padronizado (SPI), o Índice de Precipitação - Evapotranspiração Padronizado (SPEI) e o Índice de Severidade de Seca de Palmer (PDSI), utilizados amplamente de acordo com o tipo de seca a ser avaliada; seca meteorológica, seca agrícola, seca hidrológica e seca socioeconômica (Teixeira *et al.*, 2021)

O painel intergovernamental sobre mudanças climáticas *(Intergovernmental Panel on Climate Change - IPCC)* em sinergia com seu primeiro grupo de trabalho *(Working Group I - WGI)*, estabeleceu as bases teóricas que sustentam as mudanças climáticas no passado, no presente e no futuro, sendo incluídas nos relatórios de avaliação *(Assessment Report - AR)* desde o AR1 a AR3; alertando sobre possíveis aumentos na frequência e na intensidade de eventos como secas, desertificação e degradação da terra, especialmente nas regiões tropical e subtropical (Houghton *et al.*, 1995, 2001; IPCC, 1992). Do mesmo modo, o grupo de trabalho II *(Working Group II - WGII)* do IPCC avalia a vulnerabilidade em termos socioeconômicos e naturais produzida pelas mudanças climáticas e suas prováveis consequências e adaptações; no caso da seca, indicaram nos

AR4 e AR5 os impactos produzidos pelas secas na disponibilidade de água, geração de energia, migração humana e agricultura (Field; Barros; Change, 2014; Parry *et al.*, 2007). Além disso, o AR6 e o WGI estimaram durante a fase 6 do Projeto de Intercomparação de Modelos Acoplados *(Coupled Model Intercomparison Project Phase 6 – CMIP6),* um aumento nas secas agrícolas e ecológicas no cenário de aquecimento global de 2 °C em comparação com o período pré-industrial de 1850-1900 (Masson-Delmotte *et al.*, 2021).

O relatório especial sobre cenários de emissões *(Special Report on Emissions Scenarios - SRES)* em conjunto com os caminhos de concentração representativos *(Representative Concentration Pathways - RCPs),* usados principalmente através de modelos climáticos globais *(Global Climate Models - GCM),* permitiram projetar cenários sobre atividades socioeconômicas tais como: crescimento populacional e demográfico, crescimento econômico, gases de efeito estufa (CO2, CH4, N2O, 03) entre outros, para escalas temporais de curto prazo (até 2030), médio prazo (até 2050) e longo prazo (até 2100) (Collins *et al.*, 2013; Lecocq *et al.*, 2022; Lee *et al.*, 2021).

Os possíveis efeitos previamente descritos no AR1 a AR6 do IPCC referentes a secas, junto com os cenários e projeções dos SRES e RCPs, proporcionam desafios durante a simulação dos processos físico-matemáticos altamente complexos que acontecem principalmente na atmosfera, hidrosfera e litosfera terrestre. Além disso, exigem uma análise aprofundada para cada um desses cenários (Jones, 2000; Nakicenovic *et al.*, 2000; Webster *et al.*, 2002).

Em complemento aos relatórios de projeção (ARs) e aos modelos GCMs usados pelo IPCC, existem vários métodos matemáticos e estatísticos para projetar o possível comportamento de secas no curto prazo (meses e anos), sendo os métodos de Inteligência Artificial (IA) os mais avançados e desenvolvidos nos últimos anos (Aghakouchak *et al.*, 2022; Kousari *et al.*, 2017). Alguns dos métodos IA mais usados na projeção de secas são: redes neurais artificiais, árvores de decisão, máquinas de vectores de suporte e redes bayesianas. Esses algoritmos demonstraram uma alta capacidade de prever o comportamento a curto prazo de diferentes componentes do ciclo hidrológico (precipitação, evapotranspiração, armazenamento de águas subterrâneas ou umidade do solo, entre outros) (Ardabili et al., 2020; Huntingford et al., 2019; O'Gorman; Dwyer, 2018; Rasp; Pritchard; Gentine, 2018; Schultz et al., 2021).

O objetivo estabelecido nesta presente pesquisa foi desenvolver um modelo de previsão hidrológica de fenômenos hidrometeorológicos numa área afetada pelas secas e estiagens. Para isso, foi selecionada como área de estudo a Bacia Hidrográfica do Rio Paranapanema (BHRP), que vem sofrendo um aumento significativo de secas e estiagens desde 2001, com um período máximo de seca em 2018, o que provocou o estabelecimento de uma sala de acompanhamento e de crise a partir desse período.

A fim de atingir o objetivo estabelecido, foram aplicadas tecnologias geoespaciais para analisar o comportamento e a evolução das secas e estiagens entre 2001 e 2023. Posteriormente, uma Rede Neural Autorregressiva (NNAR) foi usada para prever a precipitação, evapotranspiração potencial e índice SPEI entre 2023 e 2025, para estimar prováveis cenários de déficit hídrico, secas e estiagens e seus impactos nos setores agrícola, energético e social na BHRP.

2 OBJETIVOS

2.1 Objetivo Geral

Desenvolver um modelo de prognóstico hidrológico de fenômenos hidrometeorológicos, tais como estiagens e secas na Bacia Hidrográfica do Rio Paranapanema, para estimar prováveis cenários de déficit hídrico, secas e estiagens entre 2023 e 2025 e seus impactos nos setores agrícola, energético e social na bacia.

2.2 Objetivos específicos

1. Caracterizar a evolução e o comportamento dos fenômenos hidrometeorológicos nos últimos 20 anos para estabelecer sua frequência e duração .
2. Identificar a distribuição espacial de áreas suscetíveis a secas e estiagens para analisar a influência de fenômenos climáticos globais.
3. Simular e prognosticar cenários hidrológicos no período 2023-2025 para estimar a possível ocorrência de secas e estiagens.

3 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

3.1 Área de estudo

A Bacia Hidrográfica do Rio Paranapanema (BHRP) é uma região provedora de recursos hídricos, energéticos e agrícolas, localizada no sudeste do Brasil, com uma área total de 106.554,53 km² dividida em seis Unidades de Gestão Recursos Hídricos Integradas (UGRHIs): Alto Paranapanema, Médio Paranapanema e Pontal do Paranapanema no Estado de São Paulo (48,6% da BHRP) e Norte Pioneiro, Tibagi e Piraponema no Estado de Paraná (51,4% da BHRP). Essas seis UGRHIs compõem os comitês da BHRP e suas 22 Unidades de Planejamento Hídrico (UPHs) nomeadas como: Alto Cinzas, Alto Paranapanema M. D, Alto Paranapanema M. E, Alto Tibagi, Baixo Cinzas, Baixo Paranapanema M. D, Baixo Paranapanema M. E, Baixo Tibagi, Capivara, Itararé Alto Paranapanema, Itararé Norte Pioneiro, Laranja Doce, Médio-Alto Tibagi, Pardo, Pari/Novo, Pirapozinho, Pirapó, Santo Anastácio, Taquari, Tributários Rio Paraná, Turvo e Vermelho/Capim (Figura 1).

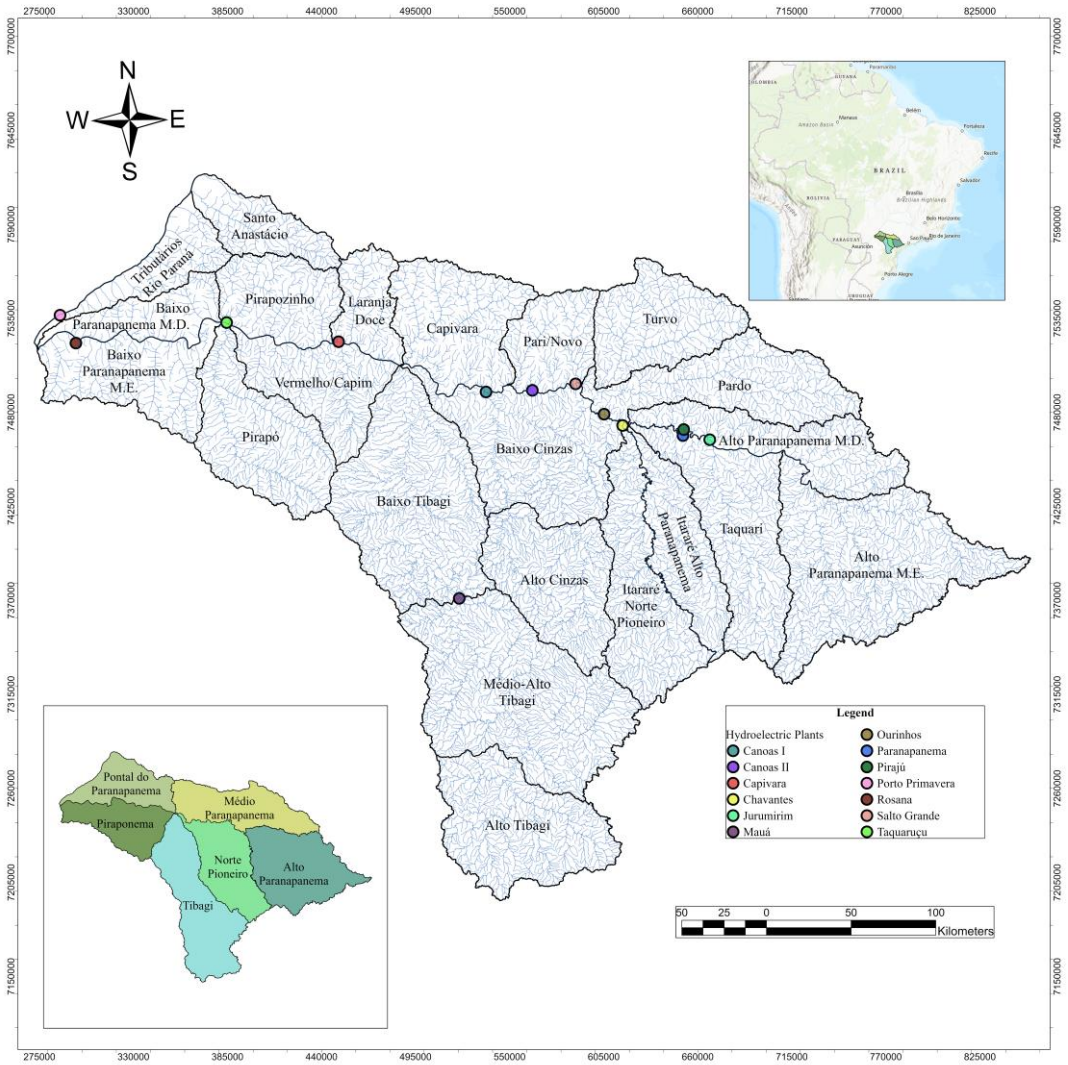
No setor demográfico, a BHRP abriga quase cinco milhões de habitantes (4.680.725) entre população urbana (4.120.313) e rural (560.410) (IBGE, 2012b). A população encontra-se distribuída em 247 municípios da bacia, com 132 municípios pertencentes ao Estado do Paraná e 115 municípios no Estado de São Paulo (Tabela 1).

Tabela 1. População Urbana, Rural e Total por UGH

UF	UGH	População Urbana	População Rural	População Total
PR	Piraponema	1.161.466	74.114	1.246.034
	Tibagi	1.275.857	155.171	1.464.654
	Norte Pioneiro	384.453	98.140	482.593
SP	Alto Paranapanema	586.369	152.859	732.498
	Médio Paranapanema	607.238	59.772	671.068
	Pontal do Paranapanema	432.750	41.799	482.677

Fonte: (IBGE, 2012)

Figura 1. Mapa localização geográfica BHRP[2]



Elaborado pelo autor

No setor social, os indicadores de Índice de Desenvolvimento Humano Municipal (IDHM) que considera a renda, educação e longevidade indicam para os municípios da BHRP níveis médios, altos e muito altos de IDHM (Tabela 2). Por outra parte, o Índice Firjan de Desenvolvimento Municipal (IFDM) baseado em emprego e renda, educação e saúde apontam níveis regulares, moderados e altos de IFDM para os municípios da bacia, mostrando comportamentos entre o IFDM e o IDHM semelhantes (Brasil, 2013).

[2] A versão on-line da Figura 1, está disponível de forma livre e aberta em: https://arcg.is/0bvvn1

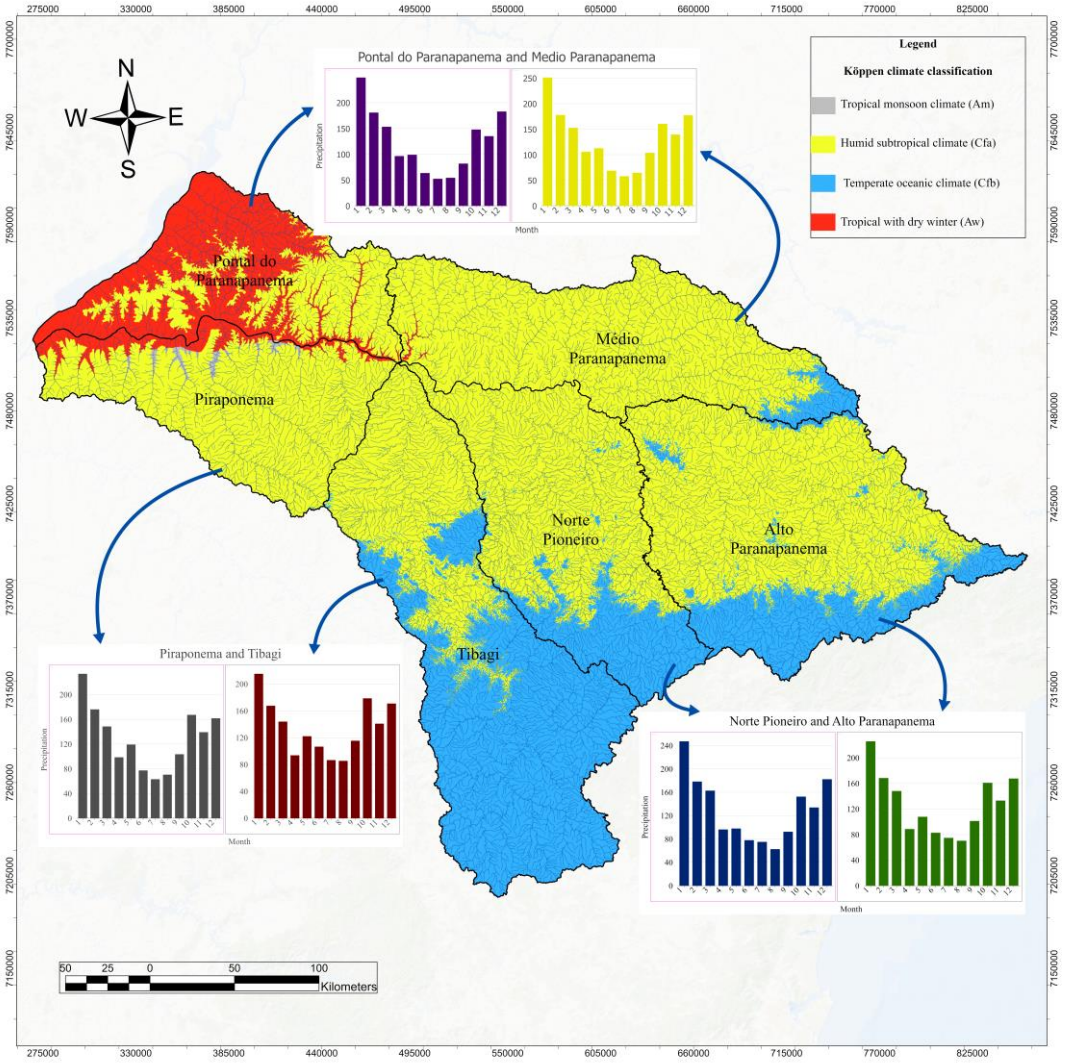
Tabela 2. Indicadores sociais IDHM e IFDM

UGH	IDHM (n° de municípios)			
	Médio (0,6-0,69)	Alto Inferior (0,7-0,74)	Alto Superior (0,75-0,79)	Muito alto (0,8-1,0)
Alto Paranapanema	15	22	2	0
Médio (SP) Paranapanema (SP)	4	31	14	2
Pontal do Paranapanema (SP)	2	13	9	1
Piraponema (PR)	12	40	4	1
Tibagi (PR)	19	17	3	0
Norte Pioneiro (PR)	15	21	0	0
UGH	IFDM (n° de municípios)			
	Regular (0,5-0,59)	Moderado Inferior (0,6-0,69)	Moderado Superior (0,7-0,79)	Alto (0,8-1,0)
Alto Paranapanema	0	12	25	2
Médio (SP) Paranapanema (SP)	0	6	37	8
Pontal do Paranapanema (SP)	0	4	19	2
Piraponema (PR)	0	19	32	6
Tibagi (PR)	3	21	13	2
Norte Pioneiro (PR)	0	25	11	0

Fonte: Brasil (2013)

Quanto ao clima, esta bacia é caracterizada por temperaturas médias anuais inferiores a 18 °C no sul e sudeste e superiores a 21 °C no norte e noroeste (Figura 2). A precipitação média anual da bacia é de 1.450 mm, com valores de até 1.800 mm na região centro-sul, e valores inferiores a 1.300 mm nas regiões leste e noroeste. O regime unimodal da bacia é caracterizado por uma estação chuvosa nos meses de dezembro, janeiro e fevereiro, enquanto que, a estação seca acontece nos meses de junho, julho e agosto (ANA, 2016). A classificação climática de Köppen-Geiger na BHRP é dividida em duas zonas climáticas: tropical (A) e subtropical (C), com quatro subtipos climáticos: Cfa (clima subtropical úmido oceânico sem estação seca com verão quente), Cfb (clima subtropical úmido oceânico sem estação seca com verão temperado), Aw (clima tropical com inverno seco) e Am (clima monção tropical) (Alvares *et al.*, 2013).

Figura 2. Classificação climática Köppen-Geiger BHRP[3]



Elaborado pelo autor

Quanto à hidrologia, a BHRP possui como principal corpo de água o rio Paranapanema com um percurso aproximado de 930 km desde a sua nascente na Serra de Agudos Grandes, no sudeste do Estado de São Paulo com uma altitude aproximada de 900 metros até a sua foz no rio Paraná. Da mesma forma, a BHRP apresenta uma disponibilidade hídrica nos períodos de estiagem com vazão média de longo termo (QMLT) de 1.597 m³/s, vazão com permanência de 95% (Q95) de 534 m³/s e vazão média de 7 dias com tempo de retorno de 10 anos (Q7_10) de 350 m³/s (ANA; MMA, 2015b).

[3] A versão on-line da Figura 2, está disponível de forma livre e aberta em: https://arcg.is/mzGbz0

O abastecimento de água na BHRP indica que do total de 247 municípios da BHRP, 141 municípios (57%) são abastecidos por águas subterrâneas, 52 municípios (21,1%) são abastecidos por águas tanto superficiais como subterrâneas, os 54 municípios restantes (21,5%) são abastecidos por águas superficiais (ANA; MMA, 2015a), inferindo uma alta demanda de água no setor energético, social e agrícola. No setor energético, a BHRP tem um total de 13 Usinas Hidrelétricas (UHEs) (Tabela 3), com potência de 4.287,8 Megawatt (MW), 18 Pequenas Centrais Hidrelétricas (PCHs) com potência de 73,6 MW e 7 Centrais Geradoras Hidrelétricas (CGHs) com potência de 5,1 MW, atingindo uma potência máxima total instalada de 4.366,5 MW (ANA, 2014; ONS, 2012).

Tabela 3. Características Usinas Hidrelétricas BHRP

Usina Hidrelétrica	Rio	Potência Megawatt (MW)	Área Reservatório (km²)	Volume (hm³)		
				Máximo	Mínimo	Útil
Jurumirim	Paranapanema	101	413,6	7.008	3.843	3165
Paranapanema		31,5	1,5	1050	1.050	0
Pirajú		70	14,1	84	84	0
Chavantes		414	362,6	8.795	5.754	3041
Ourinhos		44	1,2	20,8	20,8	0
Salto Grande		73,8	5,1	45	45	0
Canoas II		72	19,4	151	151	0
Canoas I		82,5	24,9	212	212	0
Capivara		619	562,5	10.540	4.816	5724
Taquaruçu		525	84,7	677	677	0
Rosana		354	196,1	1.918	1.918	0
Mauá	Tibagi	361	83,9	2.137	1.473	644
∑ BHRP		**2.747,8**	**1.769,6**	**32.638**	**20.044**	**12.594**
Porto Primavera	Paraná	1.540	2.093,8	14.400	20.000	5.600
∑ BHRP e Porto Primavera		**4.287,8**	**3.862,8**	**47.038**	**40.044**	**18.194**

Fonte: (ANA, 2014; ONS, 2012)

No uso e atividade agrícola da BHRP, esta é caracterizada por uma área total de 4,96 milhões de hectares plantadas no ano 2012, onde as maiores culturas foram a soja (33,7%) e o milho (26,1%) na região centro-sul, seguidas pela cana-de-açúcar (20,5%), trigo (7,4%), feijão (4,0%), café (1,7%) e citros (1,7%) (IBGE, 2012a). Porém, de acordo com Manzione (2024), em análise realizada para o ano de 2020, o uso e a atividade agrícola na BHRP apresentaram alterações, quando foram identificadas as culturas de soja (20,42%), cana-de-açúcar (8,30%), citros (0,77%) e café (0,27%). Além disso, houve Formação Florestal (17,15%), Plantio Florestal (8,78%), Pastagem (16,80%) e Mosaico de Usos (18,69%).

No setor econômico, o Produto Interno Bruto (PIB) total dos 247 municípios pertencentes à BHRP para o ano 2011 foi aproximadamente 11,85 bilhões de reais (12 %) referente ao setor industrial, 23,98 bilhões de reais (24%) ao setor agropecuário e 64,40 bilhões de reais (64%) aos serviços incluindo administração, saúde e educação pública, seguridade social) (IGBE, 2013), evidenciando uma ampla variabilidade na produção econômica da BHRP.

3.2 Justificativa

O Programa de Pós-Graduação em Geociências e Meio Ambiente (PPGMA) do Instituto de Geociências e Ciências Exatas (IGCE) da UNESP Campus Rio Claro, visa a formação de profissionais com alta capacidade técnico-científica para geração de mudanças positivas no meio físico a partir da aplicação de conhecimentos e tecnologias de vanguarda. Nesse panorama, o presente trabalho pretendeu abordar estudos relacionados com a linhas de pesquisa Recursos Hídricos, Minerais e Energéticos e Planejamento e Gestão do Meio Físico, procurando contribuir com novas informações que levem à redução e mitigação dos possíveis impactos futuros gerados pelos fenômenos hidrometeorológicos na BHRP em resposta aos problemas gerados por estes fenômenos em áreas como o setor agrícola, a segurança alimentar e da água, o setor energético e a preservação do meio ambiente natural.

A consecução deste trabalho espera ajudar a fortalecer entidades governamentais e não governamentais, centros de pesquisa e em geral a população relacionada com a BHRP em termos de gestão e desenvolvimento sustentável da água como uma fonte vital

de saúde e vida. Finalmente, cabe destacar o uso de tecnologias geoespaciais como sensoriamento remoto e os Sistemas de Informações Geográficas (SIG) que em união com algoritmos de aprendizado de máquina, proporcionam ferramentas para o estudo e análise de fenômenos extremos como as secas e estiagens na BHRP.

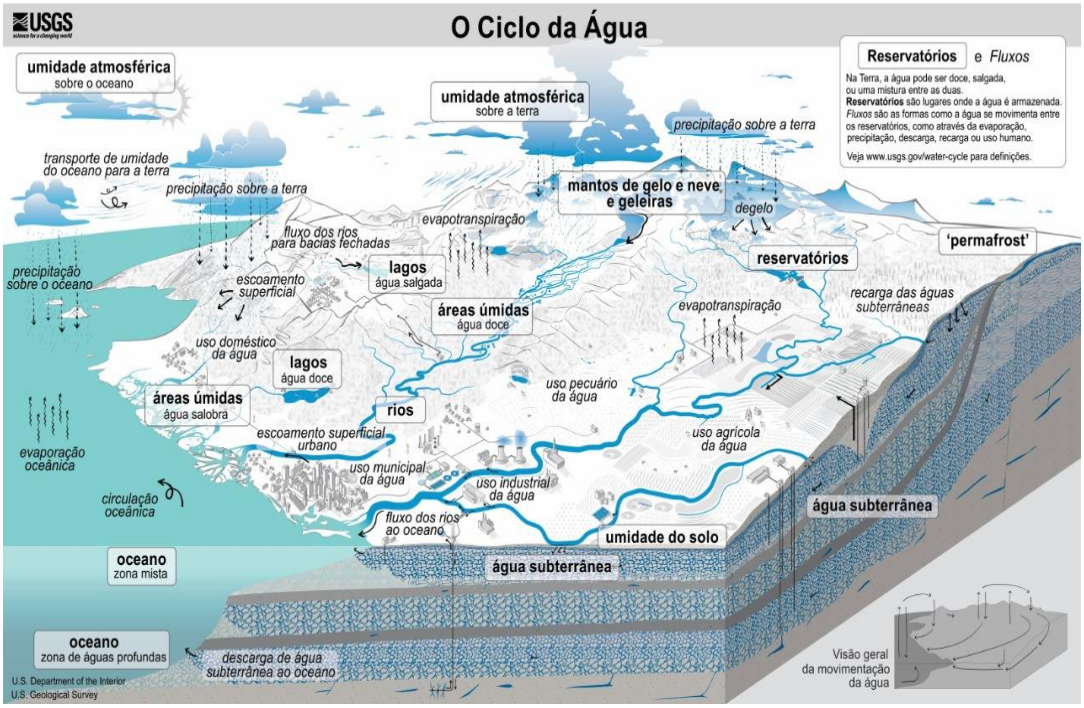
4 MARCO TEÓRICO

4.1 Fundamentação Teórica

4.1.1 Ciclo hidrológico e distribuição hídrica

O ciclo hidrológico ou ciclo da água, é um dos maiores recursos naturais renováveis do Planeta Terra, sendo relevante para o desenvolvimento social, econômico, político, ambiental e humano (Simonovic, 2002). Este recurso de vital importância, encontra-se distribuído nas diferentes fases físicas do ciclo hidrológico ou ciclo da água tais como: evaporação, transpiração, condensação, precipitação e escoamento (Figura 3).

Figura 3. Ciclo hidrológico



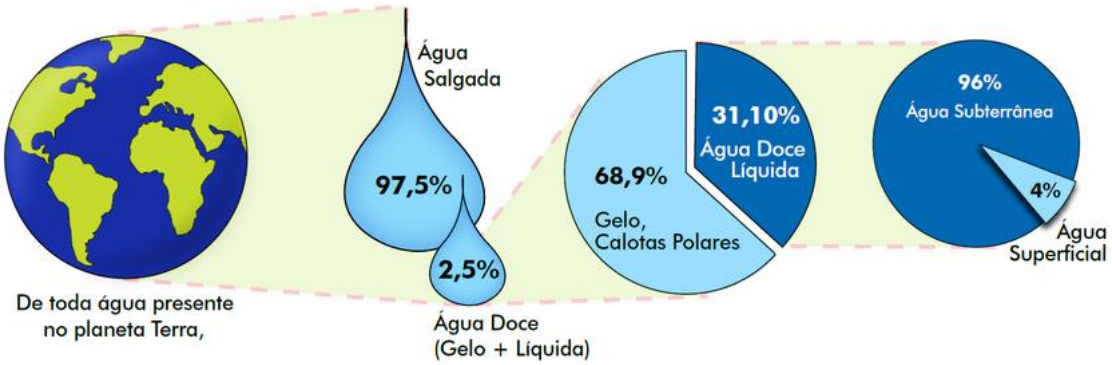
Fonte: adaptado de Corson-Dosch et al. (2022).

O ciclo global da água, é impulsionado fundamentalmente pela energia térmica solar, força dos ventos, força da gravidade e rotação terrestre, motivo pelo qual a água atravessa os diferentes sistemas terrestres (atmosfera, hidrosfera, criosfera, litosfera e biosfera). Entretanto, existem zonas da Terra onde este ciclo não é distribuído de forma homogênea ou regular, provocando alterações na disponibilidade das águas superficiais

e subterrâneas tais como: rios, riachos, lagos, pântanos e aquíferos (Gunasekara *et al.*, 2014).

A figura 4 mostra a distribuição hídrica no mundo, com um valor total aproximado de 1.386.000.000 km³ (um bilhão e trezentos e oitenta e seis milhões quilômetros cúbicos de água) (Shiklomanov, 1998). Em termos de percentagem, a maioria é água salgada (97,5%) concentrada nos oceanos e mares, seguida por água doce (2,5%) contida nas regiões polares e subterrâneas, junto com outras águas salinas. A água doce (2,5%), está dividida e armazenada em 2 grandes grupos: as geleiras e calotas polares (68,9%), a água doce liquida (águas subterrâneas equivalentes a 30,1% e água doce superficial referentes a 1,2%). Nessa perspectiva, os recursos hídricos utilizados para atividades como produção energética, produção agrícola, abastecimento humano e animal, comércio e indústrias, estão representados maiormente naquela porção de água doce superficial (1,2%) (Jackson *et al.*, 2001). A água doce superficial, é possível encontrá-la em gelo terrestre e permafrost (69%), lagos (20,9%), umidade do solo (3,8%), atmosfera (3%), pântanos (2,6%), rios (0,49%) e seres vivos (0,26%).

Figura 4. Distribuição hídrica na Terra



Fonte: Brasil (2007)

4.1.2 Secas e estiagens

Segundo o vocabulário meteorológico internacional (WMO; OMM, 1966), secas e estiagens referem-se a períodos anormalmente secos com deficiência ou ausência na precipitação, a principal diferença entre estes eventos radica na intensidade e nos impactos, caso acontecer. Conforme de Castro (1998), um período curto/longo de baixa

ou ausência de pluviosidade caracterizado por uma maior perda da umidade em referência a sua reposição denomina-se estiagem. No entanto, a seca é concebida como um período de estiagem prolongado com a capacidade de provocar desequilíbrio hidrológico junto com impactos principalmente no setor meteorológico, hidrológico, agrícola e socioeconômico (Mata-Lima *et al.*, 2013; Tavares; Arruda; Silva, 2019). Os produtos desses impactos foram definidos em diferentes tipos e índices de secas conforme o seguinte:

- **Seca meteorológica:** Período de tempo seco suficientemente prolongado para que a falta de precipitação cause sério desequilíbrio hidrológico (WMO; OMM, 1966).

- **Seca agrícola:** Intervalo de tempo em que o fornecimento de água na umidade do solo de uma região é menor que seu valor esperado, provocando uma insuficiência na reposição das perdas por evapotranspiração potencial das plantas e culturas durante a etapa de crescimento (Liu *et al.*, 2016; Quiring; Papakryiakou, 2003).

- **Seca hidrológica:** Tempo prolongado marcado pela diminuição considerável na disponibilidade de água em qualquer fase do sistema hidrológico e fluxos de água, caracterizado por níveis anormalmente baixos nos rios, lagos, reservatórios e águas subterrâneas (Nalbantis; Tsakiris, 2009; Van Loon, 2015).

- **Seca socioeconômica:** lapso de tempo caracterizado pela carência no abastecimento de água em referência à demanda, causando impactos sociais, econômicos e ambientais (Mehran; Mazdiyasni; AghaKouchak, 2015; Tu *et al.*, 2018).

Esses aspectos descritos previamente, impossibilitam a determinação ou consenso único sobre definições exatas das secas e estiagens (Blain; Brunini, 2006; Santos *et al.*, 2012), considerando características próprias como ser fenômenos imperceptíveis e silenciosos em referência a seus parâmetros de avaliação (magnitude, duração, frequência e extensão espacial) (Ponvert-Delisles Batista, 2016). De outro lado, tem sido demonstrado que estes acontecimentos variam de acordo com as condições geográficas, hidrológicas, climatológicas e edafológicas da área de estudo (Patel; Chopra; Dadhwal, 2007; Sio-Se Mardeh *et al.*, 2006).

As atividades de planejamento, gestão e previsão das secas e estiagens estão subordinadas à ocorrência de outros fenômenos de variabilidade climática como: Zona de Convergência do Atlântico Sul (ZCAS), El Niño Oscilação do Sul (ENOS), Alta subtropical do Atlântico Sul (ASAS) (Carpenedo; Ambrizzi, 2020; Kayano; Moura, 2018; Verdan; Júnior; Silva, 2023). Portanto, é importante estabelecer diferentes cenários nos quais estes eventos desenvolvem-se e os possíveis impactos/efeitos que podem gerar.

A continuação, conforme os vocabulários internacionais de meteorologia e hidrologia (WMO; OMM, 1966; WMO; UNESCO, 2012), são recopiladas algumas definições de termos hidrometeorológicos associados com secas e estiagens:

- **Balanço hídrico**: período no qual o fluxo de saída de água de uma bacia ou massa de água deve ser equivalente ao fluxo de entrada mais ou menos a variação no armazenamento de água.

- **Déficit hídrico**: período anormalmente seco, longo o suficiente para causar escassez de água, conforme refletido por uma diminuição considerável nos fluxos dos rios e nos níveis dos lagos e/ou esgotamento da umidade do solo e redução dos níveis de água subterrânea abaixo de seus valores normais.

- **Excedente de água**: diferença cumulativa (positiva) entre a precipitação e a evapotranspiração potencial em um determinado período, quantidade de água em um reservatório ou sistema de abastecimento que excede a demanda.

4.2 Estado da arte

4.2.1 Secas no mundo

Registros históricos que evidenciam as características passadas do clima em relação à ocorrência de secas no mundo, foram demonstrados nos últimos anos através do uso de técnicas da paleoclimatologia e paleolimnologia tais como: cronologia de anéis de árvores, análise de sedimentos e rochas, isótopos e datação radiométrica, entre outros (Andreu-Hayles *et al.*, 2017; Riehl *et al.*, 2014; Smerdon; Cook; Steiger, 2023),

permitindo recopilar medições da precipitação, temperatura, umidade do solo em eras passadas. Nessa ordem de ideias, diversas pesquisas realizadas na América do Norte, Europa, Ásia, África equatorial e América do Sul integraram algumas destas técnicas para reconstruir índices da seca como o Índice de Severidade de Seca de Palmer autocalibrado (scPDSI) para identificar os principais eventos da seca e seus efeitos potenciais.

De acordo com Cook et al. (2015), na Europa foram usados registros de 106 anéis cronológicos de árvores e 5414 pontos de grade do índice scPDSI nos períodos de verão (junho, julho e agosto) que comprovaram períodos de seca em referência a pesquisas datadas anteriormente como as grandes secas de 1893 e 1921 na Europa continental, a super seca entre 1798 a 1808 na Inglaterra e no País de Gales, a fome irlandesa entre 1740 a 1741, as grandes secas de 1616 e 1540 na república Checa, a seca prolongada entre 1437 e 1473 no centro norte da Europa e finalmente a grande fome europeia entre 1315 e 1317.

Conforme Cook et al. (2010), foi implementada uma rede cronológica de anéis de árvores na Ásia em mais de 300 locais nas áreas de floresta de monção asiática, construindo o índice PDSI para a estação de verão (junho - julho - agosto), revelando secas históricas como a seca que acabou com a dinastia Ming (1638 a 1641), a seca do leste da Índia (1790 a 1796) e a seca tardia da Grande Vitória (1876 a 1878).

Em concordância com Verschuren; Lalrd; Cumming (2000), na África equatorial foram efetuadas análises de três índices paleolimnológicos: estratigrafia de sedimentos e as composições fósseis de espécies de diatomáceas e mosquitos no lago Naivasha, Quênia. Os resultados dos índices paleolimnológicos indicaram a presença de três grandes secas no intervalo 1390-1420 em Wamara, 1560-1625 em Nyarubanga e 1760-1840 em Lapanarat-Mahlatule, todas localizadas no leste do continente africano.

Segundo Stahle et al. (2007), na América do Norte foram utilizados 835 registros de cronologias de anéis de árvores para reconstruir o PDSI desde o século XVI em uma grade de 2,5°× 2,5° de latitude/longitude, evidenciando super secas de maior intensidade e duração nas década de 1930 conhecida como *'Dust Bowl'* e na década de 1950 a denominada '*Southwestern drought*', super secas que afetaram a agricultura e o desenvolvimento econômico provocando a emigração social massiva de pessoas.

Em harmonia com Morales et al. (2020), na América do Sul foram analisados 286 registros de anéis de árvores e estimativas instrumentais de umidade do solo no trimestre (dezembro, janeiro, fevereiro) desde século XV até finais do século XX para uma grade

latitude-longitude de resolução espacial de 0,5°. Os resultados evidenciaram a seca severa nos anos 1800-1804 em Potosí (Bolívia) e a super seca de 1863 em Puerto Varas e Puerto Montt (Chile). Da mesma forma, mostraram um aumento progressivo na frequência de secas desde 1930, ressaltando as maiores frequências desde a década de 1960 com um evento por cada 10 anos.

4.2.2 Secas no Brasil

No território brasileiro, as secas estiveram registradas em diversas épocas e episódios desde o Brasil colonial, começando pela seca de 1583 descrita pelo padre jesuíta Fernão Cardim como um período que provocou o movimento de quatro a cinco mil índios para o litoral produto da seca (Cardim; Garcia, 1925). No período 1723 a 1727, foi transcrito por Irineu Ferreira Pinto, o primeiro documento oficial referente à seca, no qual os oficiais da câmara solicitaram ao rei de Portugal D. João, o envio de novos escravos como resposta às mortes acontecidas pela fome e pelos danos na plantação da cana de açúcar (Alves, 1953).

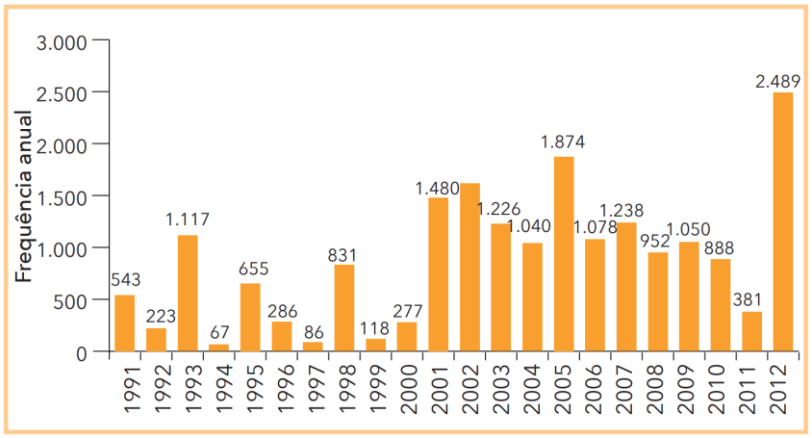
Nos anos 1776, 1777 e 1778 aconteceu a seca conhecida como "seca dos três setes" no Estado de Ceará, com alto índice de mortandade humana e gado bovino, estima-se que foram reduzidos a um oitavo do gado da capitania e suas vizinhanças próximas (Campos, 1997). Uma das maiores secas no país na época colonial ocorreu no intervalo entre 1790 e 1796, principalmente no estado da Bahia e Rio de Janeiro, provocando uma crise alimentar, produto do desabastecimento agrícola e pecuário (Da Silva, 1993).

No século XIX, apareceu a grande seca nordestina dos anos 1877, 1878 e 1879 com estimativas aproximadas de 500 mil mortes no Estado do Ceará (MEDEIROS FILHO; Souza, 1983). Posteriormente, os séculos XX e XXI, foram marcados por 19 eventos de secas. Enquanto que, no século XXI foram registrados 12 episódios de secas, evidenciando uma potencialização na frequência destes fenômenos (Alpino; Freitas; Costa, 2014).

O início do século XXI no Brasil foi marcado pelo denominado 'apagão' que aconteceu entre o verão e outono de 2001 produto do déficit prolongado de precipitação que atingiu a categoria de seca meteorológica, provocando uma redução relevante nas

vazões dos rios e reservatórios nas regiões Nordeste, Centro-Oeste e Sudeste do Brasil. Posteriormente, devido aos baixos níveis nos rios e reservatórios, foram instauradas a nível nacional, medidas de racionamento energético para assim evitar uma suspensão total do serviço elétrico (Cavalcanti; Kousky, 2001). No entanto, segundo CEPED e UFSC (2013), os fenômenos hidrometeorológicos mais representativos no período entre 1991 e 2012 foram estiagens e secas com um total de 19.517 registros oficiais de secas e estiagens, seguidos por enxurradas e inundações com um total de 8.056 e 4.694 registros respectivamente. No caso das secas e estiagens (Figura 5), os picos maiores aconteceram durante os anos 1991, 2002, 2003, 2005, 2009 e 2012, com um aumento significativo na quantidade desses eventos a partir do ano 2001 (aproximadamente 70% do total).

Figura 5. Ocorrência anual de estiagem e seca entre 1991 e 2012



Fonte: CEPED e UFSC (2013)

4.2.3 Secas na BHRP

A BHRP tem sido objeto de diversos estudos e análises de caráter hidrológico, geológico, ambiental e socioeconômico desde finais da década 1990, através do uso de registros históricos das estações pluviométricas e pluviográficas instaladas na rede hidrometeorológica nacional em formato de séries de tempo. No entanto, desde inícios da década 2020 existem estudos que aplicaram tecnologias geoespaciais como o sensoriamento remoto e imagens de satélite que permitiram obter dados hidrometeorológicos com alta resolução espacial (0,1° x 0,1°), cobrindo a extensão geográfica da BHRP. A continuação, descrevem-se as principais pesquisas realizadas na BHRP e os resultados encontrados.

Segundo Cury e Ronca (1999), a reconstrução histórica sobre o uso e ocupação físico do território, rede urbana e planos regionais/locais durante o intervalo de 1950 a 1997 na vertente paulista da BHRP, apontaram que os rios Tietê, Paraíba do Sul e Ribeira de Iguape tiveram um papel fundamental no desenvolvimento da BHRP em aspectos demográficos, econômicos e sociais daquela época. Além disso, as construções de Usinas Hidrelétricas (UHE) no Rio Paranapanema promoveram o desenvolvimento do setor elétrico e energético.

Em congruência com Parizotto (2008), tendências de regressão linear e modelos estatísticos em estações pluviométricas da BHRP, evidenciaram a correlação existente entre a precipitação da bacia com fenômenos climáticos globais como El Niño-Oscilação Sul (ENOS) tanto na fase quente "El Niño" e fase fria "La Niña", evidenciando a influência deste evento climático com anos categorizados como secos e chuvosos.

Em harmonia com Araújo (2011), os testes estatísticos de Kolmogovov-Smimov e t-Students junto com Modelos Digitais de Elevação (MDE) tipo (*Shuttle Radar Topography Mission - SRTM),* demonstraram um aumento das vazões anuais durante a década de 1970 e intensas alterações no uso e cobertura do solo referentes ao comportamento da dinâmica fluvial e regime hidrológico na BHRP.

Em concordância com Carmello e Neto (2015), técnicas estatísticas como testes de Mann-Kendall e distribuição Percentil avaliaram a variabilidade anual da chuva em 89 postos pluviométricos da vertente paranaense da BHRP desde o período 1999-2000 até 2009-2010, os resultados apontaram os períodos 1999-2000 com 31 postos secos (35%), 2003-2004 com 29 postos secos (33%) e 15 postos extremamente secos (17%). Finalmente, 2008-2009 com 43 postos secos (48%) e 10 postos extremamente secos (11%). Também, corroboraram uma menor produção de plantio de soja durante aqueles períodos categorizados como secos e extremamente secos.

Conforme Batista (2015), a aplicação de diferentes técnicas tais como: Índice de Anomalia de Chuva (IAC), Fator R da Equação Universal de Perda de Solo e Índices de Concentrações (IC) sobre séries de precipitação pluviométricas para duas escalas de tempo (1976 - 2010 e 1950 - 2010), mostraram que na região sul e sudeste da BHRP estão localizadas as maiores precipitações pluviométricas com altitudes mais elevadas. De outra modo, evidenciou-se que os eventos El Niño e La Niña são os responsáveis pelo

excesso (temporada de outubro a março) e déficit (temporada de abril a setembro) de precipitação na BHRP.

Em sintonia com Manzione (2023), mudanças espaciais e temporais da precipitação a partir do uso de sensoriamento remoto com resolução espacial aproximada de (0,1° x 0,1°) no intervalo de 2000 a 2021 na BHRP, foram verificadas com técnicas de autocorrelação espacial local, estimando assim agrupamentos de pontos quentes/frios, tendências temporais e testes estatísticos de mudanças de ponto significativas no regime da precipitação em torno ao período 2015-2017 na BHRP, determinando assim um decréscimo nos volumes totais.

4.3 Marcos regulatórios

Eventos descritos anteriormente na seção 4.2 referentes à presença de eventos extremos como as secas e estiagens no Brasil, contribuíram para a declaração de políticas e diretrizes por parte do poder legislativo nacional e estadual relacionadas a temáticas como; gerenciamento e planejamento de recursos hídricos, desastres naturais, mudança climática, entre outros.

A Lei Nº 9.433 de 8 de janeiro 1997 que criou a Política Nacional de Recursos Hídricos (PNRH) e o Sistema Nacional de Gerenciamento de Recursos Hídricos (SNGRH), estabelece no art. 1° inciso III "[...] em situações de escassez, o uso prioritário dos recursos hídricos é o consumo humano e a dessedentação de animais [...]" (Brasil, 1997, art.1, inc. III). Da mesma forma, determina a bacia hidrográfica como a unidade territorial da PNRH e do SNGRH.

A Lei Nº 12.187 de 29 de dezembro de 2009 originou a Política Nacional sobre Mudança do Clima (PNMC), descrevendo no art. 2° inciso X o conceito de vulnerabilidade alusivo a eventos extremos da variabilidade climática.

> [...] vulnerabilidade: grau de suscetibilidade e incapacidade de um sistema, em função de sua sensibilidade, capacidade de adaptação, e do caráter, magnitude e taxa de mudança e variação do clima a que está exposto, de lidar com os efeitos adversos da mudança do clima, entre os quais a variabilidade climática e os eventos extremos (Brasil, 2009, art. 2, inc. X).

A Lei Nº 12.608 de 10 de abril de 2012 concebeu a Política Nacional de Proteção e Defesa Civil (PNPDEC) e autorizou a criação do sistema de informações e monitoramento de desastres, indicando no art. 6° inciso IX a importância de monitorar áreas de risco por eventos meteorológicos e hidrológicos.

> [...] realizar o monitoramento meteorológico, hidrológico e geológico das áreas de risco, bem como dos riscos biológicos, nucleares e químicos, e produzir alertas sobre a possibilidade de ocorrência de desastres, em articulação com os Estados, o Distrito Federal e os Municípios (Brasil, 2012, art. 6, inc. IX).

A Lei Nº 13.153 de 30 de julho de 2015 institui a Política Nacional de Combate à Desertificação e Mitigação dos Efeitos da Seca e prevê a criação da Comissão Nacional de Combate à Desertificação. Esta lei decreta no art. 2° inciso X uma definição da seca e seus efeitos potenciais. Do mesmo modo, estipula diretrizes relacionadas à prevenção, adaptação e mitigação das secas através de instrumentos como o Sistema de Alerta Precoce (SAP) de Seca e Desertificação e os Planos de Ação Nacionais/Estaduais (PAN/PAE) de Combate à Desertificação e Mitigação dos Efeitos da Seca.

> [...] seca: fenômeno que ocorre naturalmente quando a precipitação registrada é significativamente inferior aos valores normais, provocando um sério desequilíbrio hídrico que afeta negativamente os sistemas de produção e de consumo (Brasil, 2015, art. 2, inc. X).

A resolução conjunta Nº 613 de 09 de novembro de 2010 criou o Comitê da Bacia Hidrográfica do Rio Paranapanema (CBH Paranapanema), integrado por 50 membros procedentes do Governo Federal, dos Estados de Paraná e São Paulo, Organizações Civis de Recursos Hídricos, entre outros (ANA; SÃO PAULO (Estado); PARANÁ (Estado), 2010). Nesse contexto, o CBH Paranapanema foi instituída mediante o Decreto de 5 junho de 2012, conferindo competências e atuação na resolução de conflitos, aprovação de planos e cobrança pelo uso de recursos hídricos na BHRP (Brasil, 2012a).

No intervalo 2018-2023 a BHRP apresentou registros mínimos categorizados como críticos de precipitação e vazão nos diferentes reservatórios da bacia (ANA, 2019), forçando a instauração da Sala de Crise por parte da Agência Nacional de Águas e Saneamento Básico (ANA), que estava composta por membros das seguintes instituições: ANA, Operador Nacional do Sistema Elétrico (ONS), CTG Brasil, Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), Departamento de Água e Energia Elétrica pelo Estado de São Paulo (DAEE), Instituto Água e Terra (IAT), Agência

Nacional de Energia Elétrica (ANEEL) e o CBH Paranapanema (CBH Paranapanema, 2019).

Algumas das funções das salas de crise e acompanhamento utilizadas na BHRP foram reguladas na Resolução ANA Nº 155 de 18 de maio de 2023, estabelecendo no Art.1° medidas na gestão de sistemas hídricos para prever e mitigar os impactos de eventos hidrológicos críticos. Também, o Art.2° estipula a necessidade de manter o compromisso na segurança hídrica e usos múltiplos da água (ANA, 2023). Atualmente, a BHRP passou a Sala de acompanhamento por parte da ANA com ênfase no monitoramento das condições de operação de reservatórios estabelecidas pela ANA.

4.4 Inteligência Artificial e geotecnologias aplicadas às geociências

O uso de algoritmos de Inteligência Artificial (IA) em campos relacionados às geociências e ao meio ambiente, como hidrologia, meteorologia, geologia, geofísica etc., vem ganhando cada vez mais participação na identificação, modelagem e resolução de problemas altamente complexos que ocorrem no sistema e na dinâmica da Terra (Karpatne *et al.*, 2019; Zhao *et al.*, 2024). Por outro lado, as geotecnologias tornaram possível analisar as variações espaciais e temporais dos fenômenos naturais e seus possíveis impactos ou consequências (Chaminé *et al.*, 2023). No entanto, a integração da IA com as geotecnologias em softwares especializados de geoprocessamento e GIS, como ArcGIS, QGIS e Google Earth Engine (GEE), vem se desenvolvendo desde o início do século XXI (Yang *et al.*, 2022).

No caso do ArcGIS, a articulação da IA com as geotecnologias surgiu com GeoAI, o GeoAI é um poderoso aplicativo disponível a partir da versão 3.2 do software ArcGIS Pro (Figura 6), que integra subconjuntos de (IA) como Machine Learning (ML) e Deep Learning (DL), em união com geotecnologias e técnicas de análise espacial tais como extração, classificação e detecção de padrões, clustering e previsões espaço-temporais (Gao; Hu; Li, 2023).

Figura 6. Uso e aplicações de GeoAI



Fonte: adaptado de GINER (2022)

As previsões espaço-temporais usando ML e DL de GeoAI, usam a ferramenta ou toolbox (Time Series AI), que incorpora os modelos de Redes Neurais Artificiais (RNAs): Fully Connected Network (FCN), Long Short-Term Memory (LSTM), InceptionTime, ResNet e ResCNN. Esses modelos estruturados em formato de séries de tempo, permitem às RNAs treinar, validar e prognosticar valores futuros das séries de tempo. Algumas aplicações dos modelos GeoAI nas geociências e meio ambiente, estão relacionadas com o monitoramento em tempo real e sistemas de alerta de inundações, mudanças espaço-temporais no uso e cobertura da terra, planejamento urbano e desenvolvimento sustentável, entre outros (Choi, 2023; Codling; Ramlal; Davis, 2024; Hadid; Chakraborty; Busby, 2024).

5 MATERIAIS E MÉTODOS

Este capítulo apresenta os materiais e métodos utilizados na consecução dos objetivos estabelecidos na seção 2.2 da presente pesquisa, para isso foram definidas quatro etapas ou fases desde a aquisição dos dados de precipitação e evapotranspiração potencial até a construção do índice SPEI por secas como produto final (Figura 7).

A primeira fase iniciou com a aquisição de registros de precipitação e evapotranspiração potencial provenientes de imagens de satélite e sensoriamento remoto de resolução espacial 0.1°, logrando desta forma criar séries de tempo entre 01/2001 e 05/2023 para uma grade de 152 pontos distribuídos na BHRP.

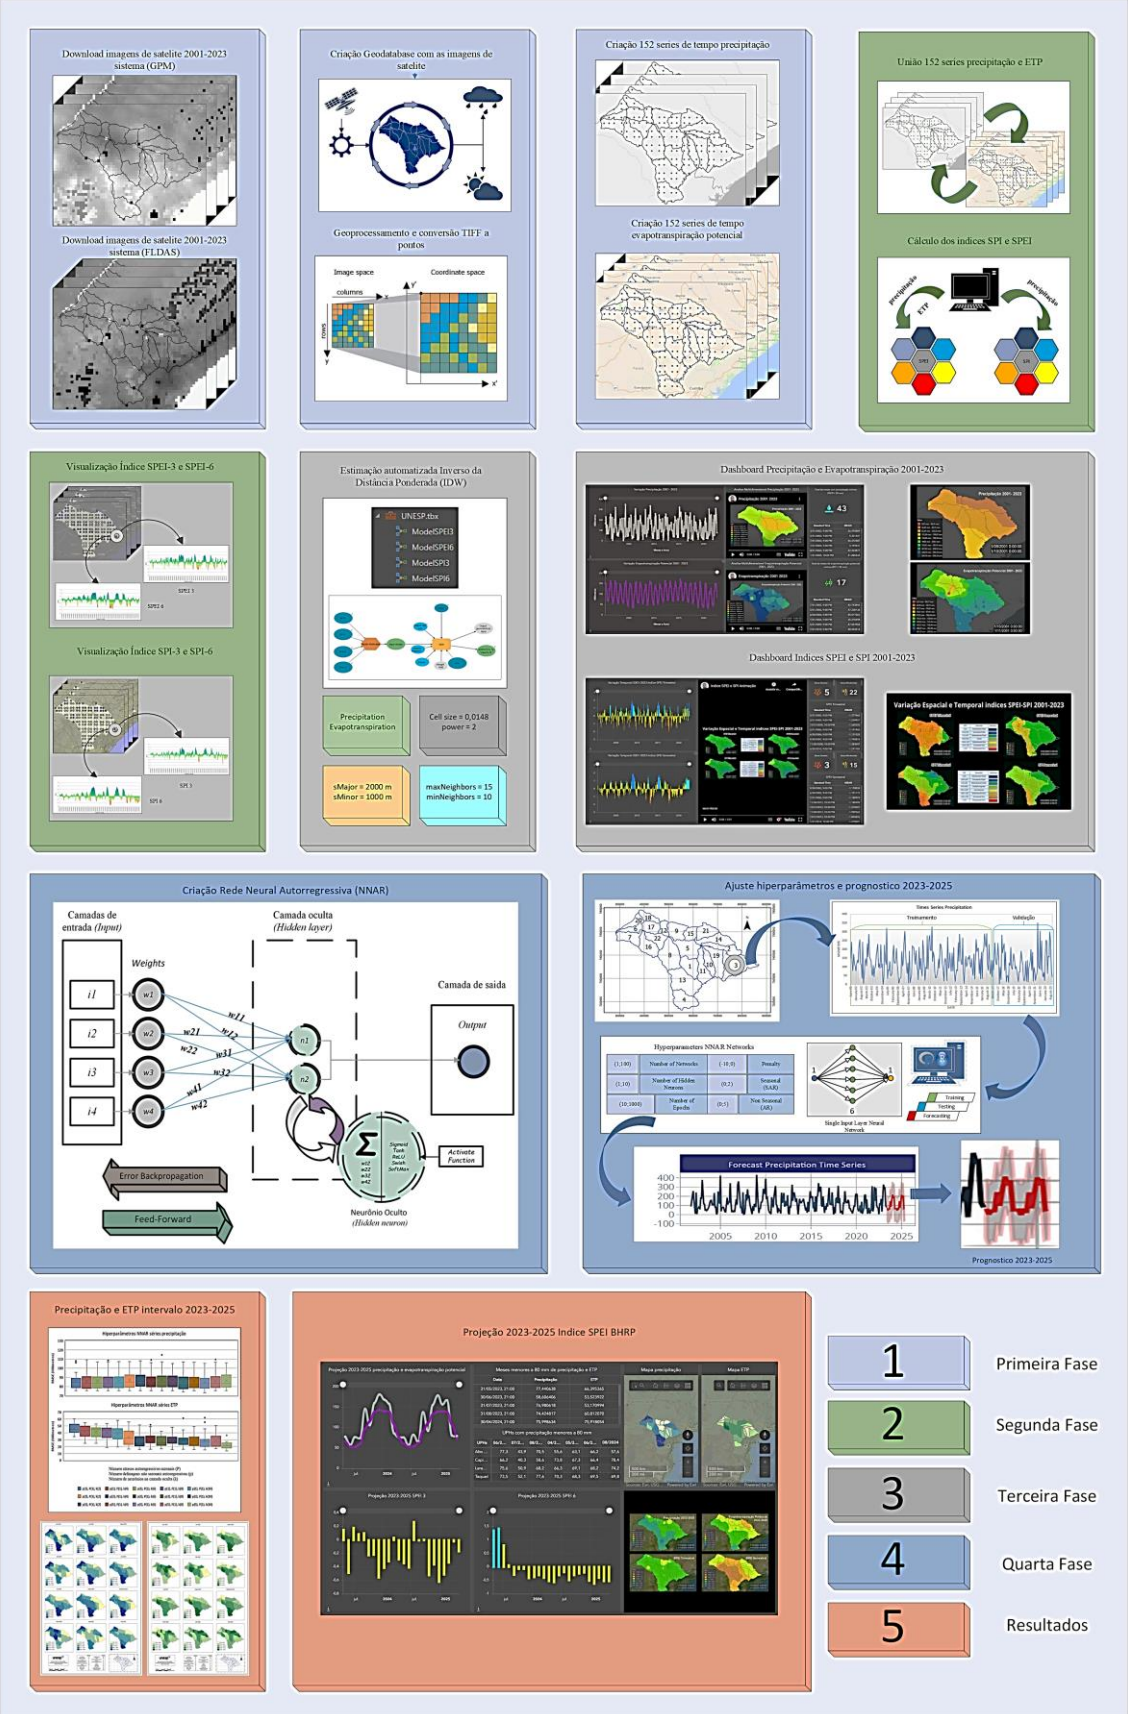
Na segunda fase foram calculados os índices SPEI e SPI nos 152 pontos da BHRP, caracterizando no intervalo de tempo (06/2001 - 05/2023) a evolução e comportamento das secas e estiagens com base em parâmetros como: intensidade, duração, magnitude e extensão.

Na terceira fase, devido à extensão geográfica da BHRP e quantidade de pontos (152) com medições dos índices SPI e SPEI em séries de tempo, foi necessária a implementação da técnica geoestatística Inverso da Distância Ponderada (IDW), para estimar valores ou pontos não amostrados a partir dos 152 pontos previamente amostrados. Desta forma, foram transformados os 152 pontos da bacia, em áreas zonais por UPH (22 no total) com categorias de secas leves, moderadas e severas na BHRP.

Antes do início da quarta fase, foi requerido calcular o IDW nos registros de precipitação e ETP na rede NNAR, impossibilitando o uso do SPEI devido a inconsistências na função de ativação da rede neural NNAR (função matemática definida para valores ≥ 0), motivo pelo qual os valores negativos do SPEI referidos a secas não foram considerados durante a criação da rede.

Na quarta fase, foi criada uma rede neural NNAR com os dados de precipitação e ETP, para períodos de treinamento (01-2001 – 09/2021), validação (10/2021 – 05/2023) e previsão (06/2023 - 05/2025), usando uma busca por teste e erro dos hiperparâmetros da rede NNAR e uma melhor métrica RMSE. Por fim, foi construído com base nas previsões de precipitação e ETP, o índice SPEI para analisar a possível ocorrência de secas e estiagens durante esse período na BHRP.

Figura 7. Metodologia de trabalho



Elaborado pelo autor

5.1 Aquisição de dados

A informação utilizada na BHRP para medições mensais e contínuas de precipitação e ETP em formato de séries de tempo para 23 anos hidrológicos (janeiro de 2001 - maio de 2023) são provenientes do repositório da *(National Aeronautics and Space Administration - NASA)* Earth, usando a ferramenta *(Geospatial Interactive Online Visualization ANd aNalysis Infrastructure - GIOVANNI)* desenvolvida pelo *(Goddard Earth Sciences Data and Information Services Center - GES DISC)* disponível no geoportal online e site (https://giovanni.gsfc.nasa.gov/giovanni/).

O sistema de análise geoespacial utilizado foi o (*Global Precipitation Mapping - GPM*) denominado (*Integrated Multi-satellitE Retrievals for GPM - IMERG*) Nível de Precipitação Final 3 (GPM_3IMERGDF) com resolução espacial de 0,1° × 0,1° (≅ 10 × 10 km) (Huffman *et al.*, 2019). Além de que, foi utilizado o sistema *(Land Data Assimilation System - FLDAS)* Noah Land Surface Model L4 Global Monthly Climatology, especificamente os sistemas *(Modern Era Retrospective analysis for Research and Applications Version 2 - MERRA-2)* e *(Climate Hazards Group InfraRed Precipitation with Station - CHIRPS)* disponível no sistema como (FLDAS_NOAH01_C_GL_M), este sistema conta com uma resolução espacial de 0,1° × 0,1° (≅ 10 × 10 km) (McNally *et al.*, 2018). Posteriormente, os dados e imagens de satélite adquiridos em formato (*Tag Image File Format - TIFF)* pelos sistemas geoespaciais GPM e FLDAS, foram geoprocessadas no software ArcGIS Pro versão 2.5.0 utilizando a ferramenta de conversão *(Raster to Point)*, transformando todos os pixels das imagens ráster de satélite de precipitação e ETP em 152 pontos distribuídos no BHRP com medidas nos centros das células (Cañada *et al.*, 2007).

5.2 Índices SPI e SPEI

5.2.1 Índice de Precipitação Padronizado (SPI)

O Índice de Precipitação Padronizado (Standard Precipitation Index - SPI), é um índice meteorológico de seca desenvolvido por McKee; Doesken; Kleist (1993), com o objetivo de quantificar o déficit de precipitação baseado numa distribuição de

probabilidade para diferentes escalas temporais (3, 6, 9, 12, 24 e 48 meses). Este índice caracteriza-se por sua simplicidade e facilidade de uso com apenas a precipitação como variável de entrada (Tabela 4). Também, permite comparar condições de seca em regiões com diferentes condições climáticas (Bonaccorso *et al.*, 2003).

Tabela 4. Características índice SPI

Característica	Descrição
Estimação	Índice baseado na distribuição de probabilidade normal padrão com escalas temporais de 1 mês até 48 meses
Parâmetros	Registros cronológicos da precipitação
Aplicação	Monitoramento e vigilância prematura de condições tanto úmidas como secas
Vantagens	1. Utilizado em diferentes regiões e condições climáticas 2. Simplicidade e facilidade de uso 3. Oferece monitoramento e seguimento da seca
Desvantagens	1. Inclui unicamente a precipitação 2. Não calcula balanço hídrico nem compara valores de evapotranspiração e umidade do solo.

Fonte: Svoboda et al. (2012)

Em concordância com Guttman (1999), a escala temporal de melhor aceitação do SPI varia entre 1 e 24 meses. Da mesma forma, Guttman (1998) afirma que o intervalo mínimo necessário para o cálculo do SPI deve estar situado entre 20 e 30 anos de registros contínuos da precipitação, No entanto, recomenda-se utilizar valores entre 50 e 60 anos de precipitação mensal para conseguir melhores resultados.

Em harmonia com Svoboda et al. (2012), cada escala temporal do SPI proporciona diferentes utilidades de análise, o SPI mensal (SPI-1) reflete as condições no curto prazo da umidade e estresse dos cultivos. A escala trimestral (SPI-3) revela as condições no curto e médio prazo de umidade junto com precipitações sazonais, o SPI semestral (SPI-6) indica tendências e transições para diferentes estações junto com algumas anomalias no fluxo de água. Finalmente, as escalas maiores de 12 meses (SPI-12) inferem as variações de longo prazo no nível de reservatórios ou aquíferos.

Segundo Angelidis et al. (2012), o SPI permite avaliar o impacto de secas sobre a disponibilidade hídrica de diferentes fontes de água tais como: água subterrânea, armazenamento de água em reservatórios, umidade do solo, entre outros. No caso da água subterrânea, por exemplo, o SPI permite avaliar anomalias da precipitação para escalas

de longo prazo. Enquanto, para escalas de curto prazo o SPI evidencia anomalias de precipitação na umidade do solo. A fundamentação teórica do SPI conforme (López *et al.*, 2007), é descrita inicialmente por uma distribuição de probabilidade contínua tipo Gama, que representa um melhor ajuste dos valores de precipitação. No entanto, devido a que o valor zero (0) não está definido nesta distribuição de probabilidade, é necessário transformar esta distribuição numa distribuição normal padrão com média igual a zero (0) e desvio-padrão de um (1) (Abramovitz; Stegun, 1966). Este ajuste na distribuição de probabilidade de acordo com Thom (1958), permite classificar os valores entre ± 3 na distribuição de probabilidade, obtendo como resultado as diferentes categorias do SPI em relação a períodos úmidos e secos mostrados na Tabela 5.

Tabela 5. Intensidade índice SPI

SPI	Intensidade
≥ 2,0	Extremamente Úmido
1,50 a 1,99	Severamente Úmido
1,0 a 1,49	Moderadamente Úmido
0,10 a 0,99	Umidade Incipiente
0,00 a -0,99	Seca Incipiente
-1,00 a -1,49	Moderadamente Seco
-1,50 a -1,99	Severamente Seco
≤ -2,0	Extremamente Seco

Fonte: McKee; Doesken; Kleist (1993)

5.2.2 Índice de Precipitação - Evapotranspiração Padronizado (SPEI)

O Índice Padronizado de Precipitação e Evapotranspiração *(Standardized Precipitation Evapotranspiration Index* - SPEI), é um índice de seca meteorológica desenvolvido por (Vicente-Serrano; Beguería; López-Moreno, 2010), com o objetivo de combinar as escalas múltiplas do índice SPI (mensal, trimestral, semestral, anual, etc.) junto com os efeitos do aquecimento global manifestados na variabilidade da temperatura. Nessa lógica, o SPEI envolve os cálculos de diversas variáveis como a evapotranspiração (baseada na temperatura), balanço hídrico climático e a relação déficit/excedente hídrico para diferentes escalas temporais de precipitação e evapotranspiração (Tabela 6).

Tabela 6. Características índice SPEI

Característica	Descrição
Estimação	Índice baseado na distribuição de probabilidade Log-logística para escalas temporais de 1 mês até 48 meses
Parâmetros	Registros cronológicos da precipitação e temperatura
Aplicação	Monitoramento e análise temporal - espacial de episódios secos quanto úmidos
Vantagens	1. Utilizado em diferentes regiões e condições climáticas 2. Simplicidade e facilidade de uso 3. Oferece um balanço hídrico climático
Desvantagens	1. A ETP é suscetível a variações conforme o método de cálculo 2. Não considera a capacidade de armazenamento de água no solo nem calcula balanço hídrico subterrâneo

Fonte: (Svoboda; Fuchs, 2017)

A principal utilidade do SPEI comparado com outros índices de seca como o Índice padronizado de Precipitação (SPI) e o Índice de Severidade de Seca de Palmer (PDSI), localiza-se na integração de características destes índices na estimação do SPEI (Vicente-Serrano *et al.*, 2010). No caso do SPI, o SPEI incorpora a sua simplicidade e facilidade no uso da precipitação em múltiplas escalas (Stagge *et al.*, 2015). No caso do PDSI, o SPEI agrega a sensibilidade na medição da demanda da Evapotranspiração Potencial (ETP) conforme o método a implementar: Thornthwaite, Penman–Monteith, Hargreaves, entre outros (Beguería *et al.*, 2014; Zhou *et al.*, 2020). Esta variável torna-se importante no momento do cálculo do balanço hídrico climático simples durante períodos de déficit hídrico ($\text{precipitação} < \text{ETP}$) e excedente hídrico ($\text{precipitação} > \text{ETP}$).

A fundamentação teórica do SPEI começa pelo cálculo da variável balanço hídrico simples sobre a relação entre precipitação e evapotranspiração, seguido da padronização da variável usando a distribuição estatística Log-Logistic para posteriormente calcular os parâmetros/coeficientes (β- α -γ) necessários para utilizar o método de momentos ponderados por probabilidade *(Probability Weighted Moment - PWM)* (Aryal; Zhu, 2020; Laimighofer; Laaha, 2022). O método PWM possibilita padronizar o SPEI de forma semelhante ao SPI com média de 0 e desvio padrão de 1. Desta forma, um SPEI de 0 indica um 50% da probabilidade acumulada do valor D_i

definido como a diferença entre precipitação e ETP (Dukat *et al.*, 2022). Na Tabela 7 são mostradas as diferentes categorias do SPEI.

Tabela 7. Intensidade índice SPEI

SPEI	Categoria
≥ 2,0	Extremamente Úmido
1,50 a 1,99	Severamente Úmido
1,0 a 1,49	Moderadamente Úmido
-0,99 a 0,99	Normal
-1,00 a -1,49	Moderadamente Seco
-1,50 a -1,99	Severamente Seco
≤ -2,0	Extremamente Seco

Fonte: Hayes (2006)

5.3 Inverso da Distância Ponderada (IDW)

O Inverso da Distância Ponderada (*Inverse Distance Weighting* - *IDW*) é um método determinístico de análise espacial desenvolvido pelo Serviço Nacional de Meteorologia dos EUA em 1972 (Chen; Liu, 2012). Este método é caracterizado por estimar a média linear ponderada em pontos desconhecidos com base em um conjunto de pontos esparsos previamente conhecidos dentro de uma vizinhança (Bartier; Keller, 1996; Lu; Wong, 2008). No entanto, como o IDW é uma média ponderada pela distância, o valor da média deve estar entre o valor máximo e mínimo do conjunto de dados (Philip; Watson, 1982; Watson; Philip, 1985). Os princípios matemáticos do método IDW estão descritos nas equações 1 e 2.

$$P_{x,y} = \sum_{i=1}^{N} z_i w_i \tag{1}$$

$$w_i = {d_i}^{-\alpha} \Big/ \sum_{i=1}^{N} {d_i}^{-\alpha} \tag{2}$$

onde $P_{x,y}$é o ponto desconhecido a calcular, z_i representa os valores médios dos pontos conhecidos para N pontos de quantidade e w_i significa a ponderação de cada estação pontual; $d_i$significa a distância de cada ponto ao ponto desconhecido.

A variável α significa a potência dos pontos conhecidos sobre os valores interpolados em função da distância, quanto maior a potência α, maior a influência dos pontos mais próximos, reduzindo a influência dos pontos mais distantes, seu valor ótimo é 2 (Shepard, 1968; Yanto *et al.*, 2022).

A principal razão do uso IDW na presente pesquisa, era estimar a média linear estatística ponderada por zona ou UPH a partir dos 152 pontos obtidos previamente na seção 5.2 com séries de tempo SPEI e SPI, procurando em primeira medida reduzir o número de séries de tempo de 152 a unicamente 22 (cada série por UPH) e em segunda medida, ter um panorama geral por UPH das diferentes categorias dos índices SPEI e SPI na BHRP. O software utilizado para o cálculo do IDW foi ArcGIS Pro no pacote *'Spatial Analyst'*. No entanto, devido ao grande tamanho do conjunto de pontos com informações temporais e espaciais, foi necessário aplicar adicionalmente a ferramenta de geoprocessamento *'Model Builder'* para poder repetir de forma permanente e automática o cálculo do IDW mês a mês começando desde 2001 até 2023 nos 152 pontos na BHRP.

A primeira iteração do primeiro ciclo do Model Builder, inicia colocando os valores do primeiro mês da série de tempo (06/2001) dos 152 pontos de SPEI-3, calculando a média linear estatística ponderada por UPH de acordo com um conjunto de parâmetros constantes do método IDW (Tabela 8). Seguidamente, o primeiro resultado IDW é armazenado como arquivo raster tipo TIFF no sistema.

Tabela 8. Parâmetros de interpolação IDW

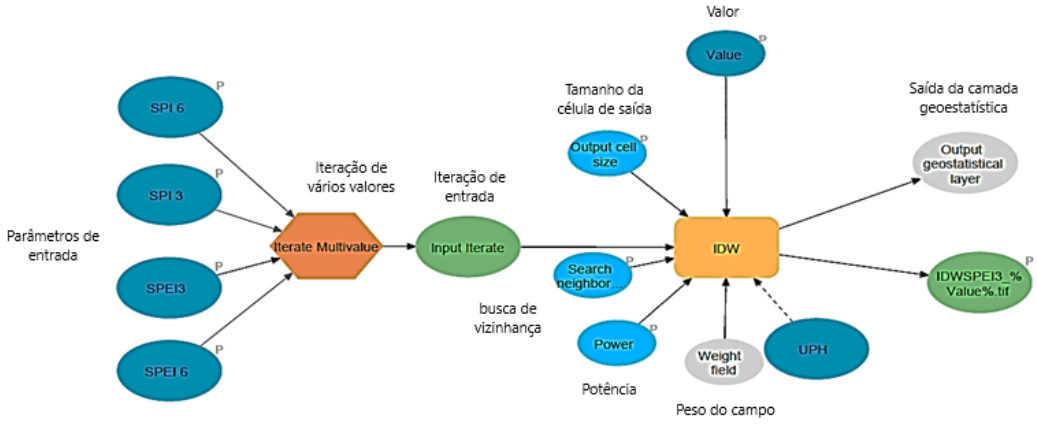
Parâmetro	Descrição	Valor
Tamanho da célula de saída	O tamanho da célula do ráster de saída, por padrão, (menor entre a largura ou a altura da extensão dos recursos do ponto de entrada) é dividido por 250.	0,0148
Semi Eixo maior	O valor do semi-eixo principal da vizinhança de pesquisa.	2.000 metros
Semi Eixo menor	O valor do semi-eixo menor da vizinhança de pesquisa.	1000 metros
Máximo de vizinhos	O número máximo de vizinhos para calcular o valor no local desconhecido.	15
Vizinhos mínimos	O número mínimo de vizinhos para estimar o valor no local desconhecido.	10

Fonte: ESRI (2024)

As seguintes iterações do primeiro ciclo, inicia colocando os valores de cada mês da série de tempo (começando desde 07/2001 até 05/2023) dos 152 pontos de SPEI-3, calculando de forma iterativa mês a mês a média linear estatística ponderada por UPH e guardando os registros em formato TIFF.

Uma vez terminado o primeiro ciclo do SPEI-3, começam os ciclos do SPEI-6, SPI-3 e SPI-6, iterando novamente o cálculo do IDW mês a mês por UPH e armazenando os resultados no sistema tipo TIFF. O Model Builder termina uma vez calculada a média estatística ponderada com IDW para todos os meses (23 anos) de cada escala temporal do SPI e SPEI. A figura 8 mostra graficamente as iterações e ciclos utilizados com IDW.

Figura 8. Iterações e ciclos IDW



Elaborado pelo autor

5.4 Rede Neural Artificial (RNA)

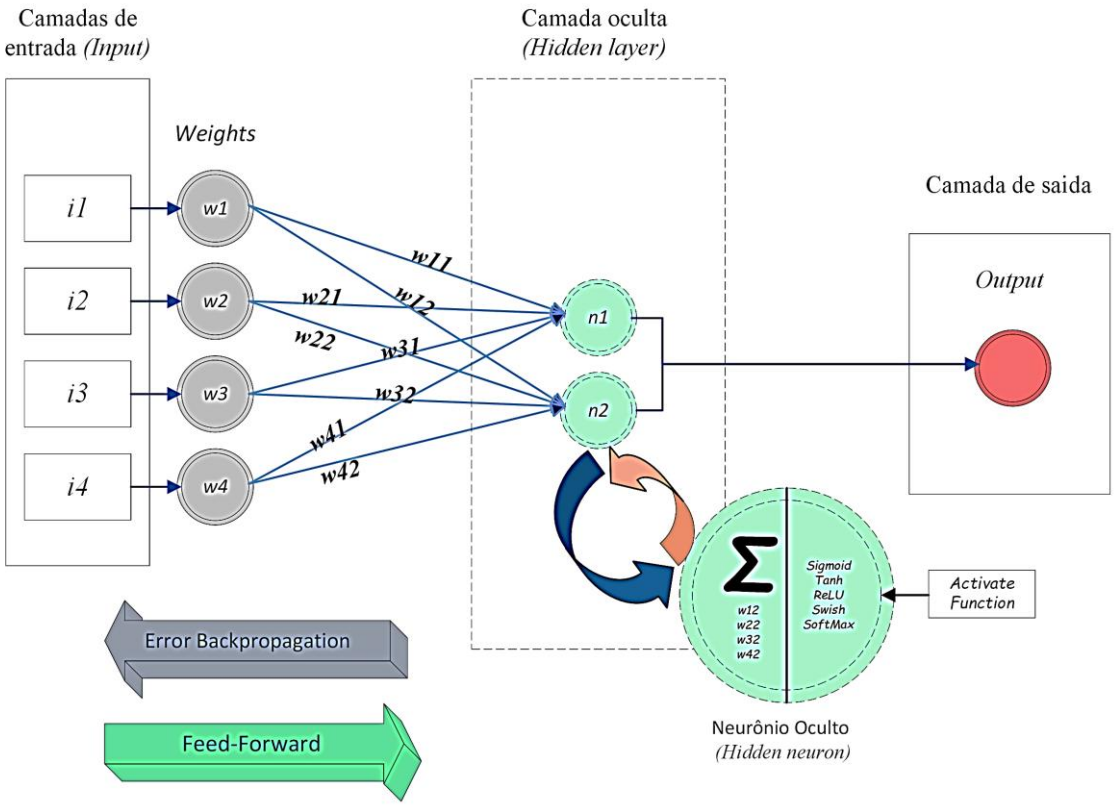
Um dos algoritmos avançados em Aprendizagem Automática *(Machine Learning)* e Aprendizagem Profunda *(Deep Learning)* aplicados à previsão de valores futuros em séries temporais são as Redes Neuronais Artificiais (RNAs) denominadas em inglês como *(Artificial Neural Networks - ANNs)* (Aggarwal, 2018).

Em harmonia com (Krogh, 2008; Wang, 2003), as RNAs são algoritmos interligados de forma paralela, inspirados nos neurônios biológicos do cérebro humano capazes de aprender, treinar e armazenar conjuntos de dados. Uma RNA caracteriza-se por uma arquitetura organizada de valores de entrada *(input)*, camadas intermediárias constituídas por camadas ocultas *(hidden layers)* e neurônios ocultos *(hidden neurons)* assim como por um valor de saída *(output)* (Figura 9).

O valor de saída ou valor esperado, pode ser estimado a partir de diferentes combinações lineares e não lineares no momento de definir os pesos *(weight)* e valores de entrada da RNA. Nesse sentido, existem diferentes funções de ativação que ajudam à RNA analisar, aprender e filtrar os pesos e valores de entrada ingressados previamente antes de ser transmitidos ou enviados como valores finais de saída (Ding; Qian; Zhou, 2018; Rasamoelina; Adjailia; Sinčák, 2020). Algumas das principais funções de ativação utilizadas pelas RNAs são: *Binary Step Function, Linear, Sigmoid, Tanh, ReLU, Leaky ReLU, Parametrized ReLU, Exponential Linear Unit, Swish e SoftMax* (Karlik; Olgac, 2011; Sharma; Sharma; Athaiya, 2017).

Complementares às funções de ativação, existe outro processo altamente considerado na aprendizagem e rendimento das RNAs conhecido como algoritmos *(backpropagation)*. Em conformidade com (Hecht-Nielsen, 1992; Wythoff, 1993), os algoritmos backpropagation são responsáveis por ajustar e diminuir o erro dos pesos e valores de entrada em comparação ao valor de saída da RNA.

Figura 9. Rede Neural Artificial Feed-Forward



Elaborado pelo autor

O gráfico anterior, mostra a arquitetura básica de uma RNA com quatro camadas de entrada, uma camada oculta contendo dois neurônios e uma camada de saída *(output)*. Este tipo de estrutura de RNA é conhecida como rede neural sem alimentação *(Feed-Forward)*, caracterizada por uma conexão sequencial dos neurônios da camada oculta rumo a camada de saída sem possibilidade de retorno ou volta atrás (Svozil; Kvasnička; Pospíchal, 1997). Além disso, cada valor de entrada tem um coeficiente de peso que conecta aos diferentes neurônios da camada oculta, nesta camada oculta são efetuados todos os cálculos da RNA para logo serem enviados à camada de saída (Mishra; Desai, 2006).

5.4.1 Rede Neural Autorregressiva (NNAR)

A Rede Neural Autorregressiva (NNAR), é uma rede neural não linear tipo Feed -Forward com uma única camada oculta e entradas atrasadas para a previsão de séries temporais univariadas (Equação 3). Este tipo de RNA conforme (Hyndman; Athanasopoulos, 2018), diferencia-se por efetuar previsões de séries temporais com padrões não sazonais (p, k) e sazonais (p, P, k).

No caso das séries temporais sazonais, a rede NNAR é utilizada com autorregressivos sazonais (*Seasonal AutoRegressive - SAR*) de forma iterativa. Para prognósticos a único passo, são utilizados os dados históricos disponíveis. Para prognósticos de dois passos, é utilizado o prognóstico do primeiro passo junto com os dados históricos da série de tempo (Equação 4).

$$y_t = f(y_{t-1}) + \varepsilon_t \tag{3}$$

$$y_{t-1} = \left(y_{t-1}, y_{t-2}, \dots\dots\dots y_{t-p}, y_{t-m}, y_{t-2m}, \dots\dots\dots, y_{t-Pm}\right) \tag{4}$$

Onde y_{t-1} é um vetor que contém os valores desfasados da série, ε_t é o erro da série temporal, *(p)* representa o número de observações passadas usadas como camadas de entrada, *(P)* o número de defasagens sazonais usadas como entradas, *(k)* o número de neurônios da única camada oculta que por padrão está definido como $(k) = \frac{(p+P+1)}{2}$ Finalmente, *(m)* representa a frequência dos valores na série temporal.

O ajuste e melhor performance de qualquer tipo de RNA, representa um fator relevante no aprendizado profundo, isso devido às múltiplas configurações e combinações possíveis dos parâmetros definidos pela RNA (p, P, k, m). Nessa ordem de ideias, torna-se importante encontrar as melhores combinações de parâmetros ou também conhecidos como hiperparâmetros, que acrescentem a capacidade de aprendizagem da RNA durante as fases de treinamento, validação e prognóstico (Nielsen, 2015; Weerts; Mueller; Vanschoren, 2020).

Segundo Hyndman e Khandakar (2008), alguns hiperparâmetros considerados nas redes NNAR são: número de redes, número de neurônios ocultos, penalidade e número de épocas. Adicionalmente, podem considerar-se os autorregressivos sazonais (SAR) e autorregressivos não sazonais *(non seasonal AutoRegressive – AR)* como hiperparâmetros de redes NNAR. (Tabela 9).

Tabela 9. Hiperparâmetros Redes NNAR

Hiperparâmetros	Descrição	Intervalo padrão
Número de redes	número de redes a ser ajustadas com pesos iniciais aleatórios. Logo, é calculada a média daqueles pesos.	$(1; 100)$
Neurônios ocultos	número de neurônios na camada oculta (k)	$(1; 10)$
Penalidade	valor numérico não negativo para a quantidade de redução dos pesos	$(-10; 0)$
Épocas	número de iterações na fase de treinamento	$(10; 1000)$
SAR	atrasos autoregressivos sazonais (SAR), denotados como (P)	$(0; 2)$
AR	defasagens não sazonais autoregressivas (AR), denotadas como (p)	$(0; 5)$

Fonte: Hyndman e Khandakar (2008)

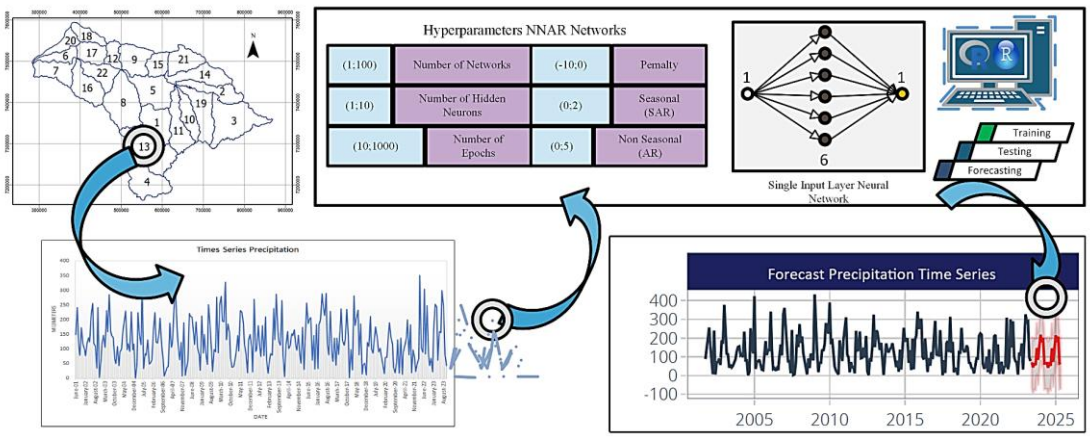
A busca automática dos melhores hiperparâmetros, é possível através do uso de técnicas como a pesquisa em grade e pesquisa aleatória (Bergstra *et al.*, 2011; Bergstra; Bengio, 2012). No entanto, considerando que a rede NNAR tem uma única camada oculta com usualmente poucos neurônios, optou-se por um ajuste manual dos hiperparâmetros por testes e erros, começando por variar os intervalos padrões dos parâmetros *SAR(P)*, *AR(p)* e neurônios ocultos *(k)* representados na equação $(p, P, k)_m$ enquanto foram mantidos os demais como constantes. Posteriormente, múltiplas combinações lineares

foram usadas para estimar o desempenho da rede NNAR representado na métrica estatística (*Root Mean Square Error - RMSE).*

A presente metodologia desenvolvida até a seção 5.3, onde foram calculadas 22 séries de tempo (uma por UPH) através do método IDW com valores do SPEI-3, SPEI-6, SPI-3 e SPI-6 que vão desde o ano 2001 a 2023, precisou ser ajustada antes da criação da rede NNAR em vésperas de poder implementar as fases iniciais de treinamento e validação, assim como a fase prognósticos da rede para o período 2023 – 2025. A continuação, são explicadas as razões pelas quais a metodologia sofreu um ajuste na rede neural NNAR.

Os índices SPI e SPEI caracterizados na seção 5.2, categorizam as secas como moderadas $(-1{,}00 \leq SPEI - SPI \leq -1{,}49)$, severas $(-1{,}50 \leq SPEI - SPI \leq -1{,}99)$ e extremas $(SPEI - SPI \leq -2{,}00)$. Em referência a valores negativos do SPI e SPEI. Entretanto, as funções de ativação tais como: *Binary Step Function, Sigmoid, ReLU e Leaky ReLU.* Encontrassem definidas para valores $(x = 0\ ou\ x > 0)$, dificultando consideravelmente a capacidade da RNA para analisar, aprender e filtrar os valores inseridos como negativos do SPEI e SPI na camada de entrada assim como os diferentes pesos atribuídos. Em consequência, os valores de saída *(output)* poderiam ser encontrados ligados a erros durante a fase final de análise de resultados e prognósticos (Figura 10).

Figura 10. Hiperparâmetros rede NNAR



Elaborado pelo autor

A solução instalada foi basicamente, trocar as 22 séries dos índices SPI e SPEI pelas séries originais de precipitação e ETP da seção 5.1, repetindo uma vez mais o processo IDW para calcular a média linear estatística ponderada por UPH. Esta solução

pensada como alternativa permite utilizar qualquer função de ativação da rede NNAR, já que os valores da precipitação e ETP estão definidos como positivos e uma mínima de zero. Em contrapartida, uma vez estimados os prognósticos da precipitação e ETP na rede NNAR para 2023-2025, é possível reconstruir ou recalcular o índice SPEI para escalas trimestrais (SPEI-3) e semestrais (SPEI-6).

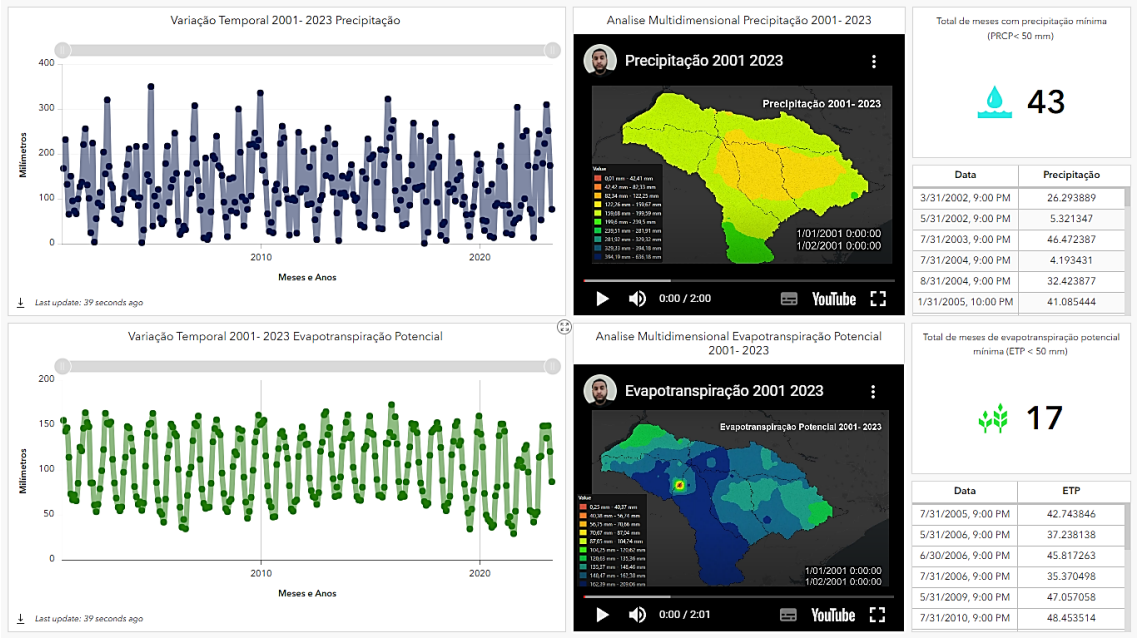
O software utilizado na criação, treinamento (70%), validação (20%) e prognóstico (10%) da precipitação e ETP, foi Rstudio na linguagem de programação R, a rede neural NNAR foi criada com a função ‘nnetar’ do pacote ‘forecast’ versão 8.21.1, das bibliotecas de programação TensorFlow e Keras (Hyndman *et al.*, 2015).

6 RESULTADOS E DISCUSSÕES

6.2 Análise espacial e temporal 2001 - 2023

O período entre 2001 e 2023 na BHRP, evidenciou um comportamento e evolução da precipitação, caracterizada maiormente pela flutuação de períodos úmidos e secos próprios da classificação climática Köppen-Geiger e suas 4 zonas climáticas presentes na bacia (Am, Aw, Cfa e Cfb). Porém, existiram um total de 42 meses com anomalias negativas de chuva entre 2001 e 2023, em relação ao seu valor mensal médio histórico durante a temporada seca (70 milímetros em junho, 65 milímetros em julho e 67 milímetros em agosto). Uma primeira análise dessas anomalias, indicaram que os anos 2006, 2007, 2010, 2018, 2021 e 2022, estiveram determinados por valores mínimos abaixo dos 50 milímetros na precipitação, principalmente na estação seca (Figura 11).

Figura 11. Variação 2001-2023 precipitação e evapotranspiração potencial[4]



Elaborado pelo autor

Da mesma forma, identificou-se uma duração média na diminuição da chuva entre dois a três meses. Esses anos categorizados de déficit hídrico e escassez de água, promoveram entre 2003 e 2012 a declaração de 46 decretos de Situação de Emergência (SE) e Estado de Calamidade Pública (ECP) em 45 municípios da bacia, distribuídos entre

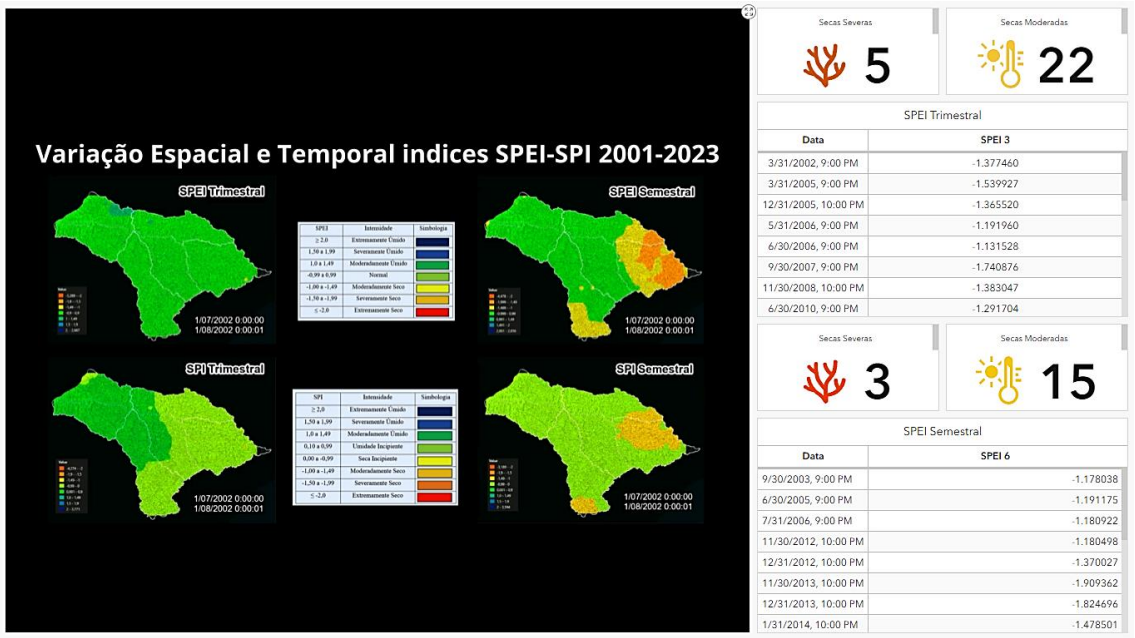
[4] A versão on-line da Figura 11, está disponível de forma livre e aberta em: https://arcg.is/185W143

as UPHs Santo Anastácio, Pirapozinho, Laranja Doce, Capivara, Pari Novo, Pardo e Itararé Alto Paranapanema, no Estado de São Paulo. Enquanto no Estado do Paraná, os eventos críticos aconteceram nas UPHs Alto Tibagi, Baixo Cinzas, Vermelho Capim e Pirapozinho (ANA, 2022).

Um fator externo a ser considerado durante o intervalo de 2001 a 2023, é a hipsometria e a orografia na BHRP, que mostraram uma forte influência nos valores de precipitação e ETP. As áreas de maior altitude localizadas no sul e sudeste da bacia, com valores máximos de até 1.363 metros acima do nível do mar, tiveram um regime de precipitação e ETP mais alto em comparação com as áreas de menor altitude localizadas no noroeste e norte, com valores mínimos de até 185 metros acima do nível do mar.

Uma análise do índice SPEI, revelou a ocorrência de secas de intensidade moderadas $(-1{,}00 \leq SPEI - SPI \leq -1{,}49)$ e severas $(-1{,}50 \leq SPEI - SPI \leq -1{,}99)$ nos 23 anos de registros (Figura 12).

Figura 12. Variação 2001-2023 índices SPI e SPEI[5]



Elaborado pelo autor

No caso da escala trimestral (SPEI-3), foram identificados 5 meses de secas severas e 22 meses de secas moderadas. De forma paralela, na escala semestral (SPEI-6), foram detectados 3 meses de secas severas e 15 meses de secas moderadas. Em

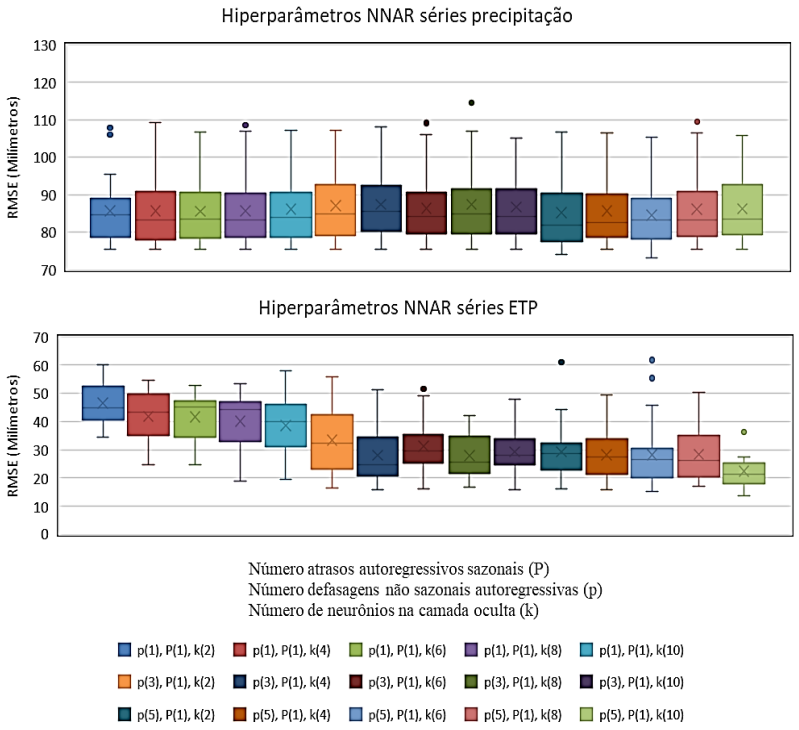
[5] A versão on-line da Figura 12, está disponível de forma livre e aberta em: https://arcg.is/zH9n50

consequência, é possível concluir em termos de intensidade, que a BHRP durante o período 2001-2023, sofreu uma alta susceptibilidade a secas moderadas. Uma última análise, mostraram que os anos 2006, 2012, 2013 e 2018, foram os anos com maior duração da seca, entre três a seis meses contínuos. Nesses anos, as áreas mais afetadas pela seca foram as regiões central, centro-sul e centro-leste da BHRP.

6.1 Ajuste hiperparâmetros rede NNAR

O ajuste dos hiperparâmetros da rede NNAR, usando diferentes combinações dos parâmetros $(p, P, k)_m = \{(1,1,2), \ldots (3,1,6), \ldots (5,1,10)\}$, evidenciaram múltiplos valores de erro RMSE para as 22 UPHs com séries de precipitação e ETP (Figura 13).

Figura 13. Hiperparâmetros e métricas RMSE



Elaborado pelo autor

As séries de precipitação evidenciaram variações de RMSE entre os 75 e 110 milímetros, com a melhor combinação de hiperparâmetros p(5), P(1), k(6) e menor valor RMSE de aproximadamente 84,54 milímetros. No entanto, a séries temporais de ETP evidenciaram variações RMSE entre os 10 e 60 milímetros, com a melhor combinação de

hiperparâmetros p(5), P(1), k(10) e menor valor RMSE aproximadamente 22,35 milímetros.

Uma primeira análise sobre a diferença RMSE entre as séries temporais de precipitação e ETP com base numa distribuição (70% treinamento), (20% validação) e (10% prognósticos) das séries de tempo, revelaram que a rede NNAR conseguiu prever com melhor performance e menor erro a séries de ETP, em comparação com a séries de precipitação. A continuação, são descritos os valores RMSE de acordo com as melhores combinações de hiperparâmetros (Tabela 10).

Tabela 10. Métrica RMSE por UPHs

UPHs	Métrica RMSE	
	Precipitação (mm)	ETP (mm)
	p(5), P(1), k(6)	p(5), P(1), k(10)
Alto Cinzas	77.66	17.55
Alto Paranapanema M.D.	85.19	19.23
Alto Paranapanema M.E.	78.65	18.1
Alto Tibagi	75.53	15.14
Baixo Cinzas	77.79	21.85
Baixo Paranapanema M.D.	95.79	27.38
Baixo Paranapanema M.E.	90.33	24.07
Baixo Tibagi	83.0	20.78
Capivara	73.22	21.14
Itararé Alto Paranapanema	76.79	16.45
Itararé Norte Pioneiro	79.36	16.16
Laranja Doce	85.17	25.03
Médio Alto Tibagi	80.49	13.77
Pardo	84.46	20.62
Pari/Novo	80.85	36.19
Pirapó	88.73	37.3
Pirapozinho	91.13	21.52
Santo Anastácio	103.65	25.78
Taquari	78.33	19.01
Tributários Rio Paraná	105.23	22.16
Turvo	85.1	25.04
Vermelho/Capim	83.55	27.46

Elaborado pelo autor

Uma segunda analise, demonstrou que existem UPHs com valores RMSE da precipitação, acima dos 90 e 100 milímetros, provavelmente influenciados por valores atípicos ou “outliers” nas UPHs: Tributários Rio Paraná, Santo Anastácio, Baixo Paranapanema M.D, Pirapozinho e Baixo Paranapanema M.E.

Uma primeira razão nos valores atípicos da precipitação, pode estar relacionada com a alta proximidade em termos de distância entre UPHs (localizadas maiormente na região nordeste da BHRP), sendo o fator distância o principal parâmetro geoestatístico usado na interpolação IDW antes da criação da rede NNAR.

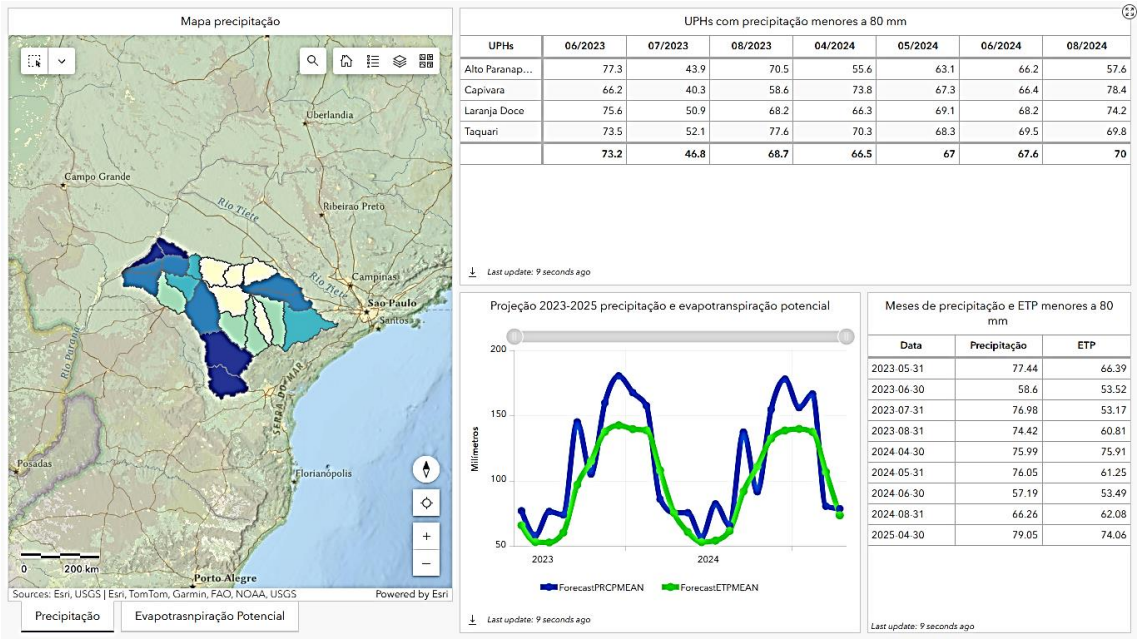
Uma segunda razão, segundo Manzione (2023), pode ser provocada por uma alta variação no regime da precipitação, registrado naquelas UPHs durante o período 2001 a

2021. Em consequência, valores muito altos e baixos de chuva categorizados como atípicos fora da média da UPH, teriam a capacidade de reduzir a aprendizagem da rede NNAR durante as fases de treinamento, validação e prognostico (Petneházi, 2019).

6.3 Previsão espacial e temporal 2023 - 2025

A previsão para o intervalo de 2023-2024 de precipitação e ETP, estaria determinada por um regime de precipitação unimodal com duas estações ao longo do ano, uma estação chuvosa com valores entre 150 e 200 milímetros nos meses de novembro, dezembro, janeiro e fevereiro. Também, uma estação seca com valores entre 0 e 50 milímetros nos meses de abril, maio, junho, julho, agosto e setembro (Figura 14).

Figura 14. Previsão 2023-2025 precipitação e ETP[6]



UPHs	06/2023	07/2023	08/2023	04/2024	05/2024	06/2024	08/2024
Alto Paranap...	77.3	43.9	70.5	55.6	63.1	66.2	57.6
Capivara	66.2	40.3	58.6	73.8	67.3	66.4	78.4
Laranja Doce	75.6	50.9	68.2	66.3	69.1	68.2	74.2
Taquari	73.5	52.1	77.6	70.3	68.3	69.5	69.8
	73.2	**46.8**	**68.7**	**66.5**	**67**	**67.6**	**70**

Data	Precipitação	ETP
2023-05-31	77.44	66.39
2023-06-30	58.6	53.52
2023-07-31	76.98	53.17
2023-08-31	74.42	60.81
2024-04-30	75.99	75.91
2024-05-31	76.05	61.25
2024-06-30	57.19	53.49
2024-08-31	66.26	62.08
2025-04-30	79.05	74.06

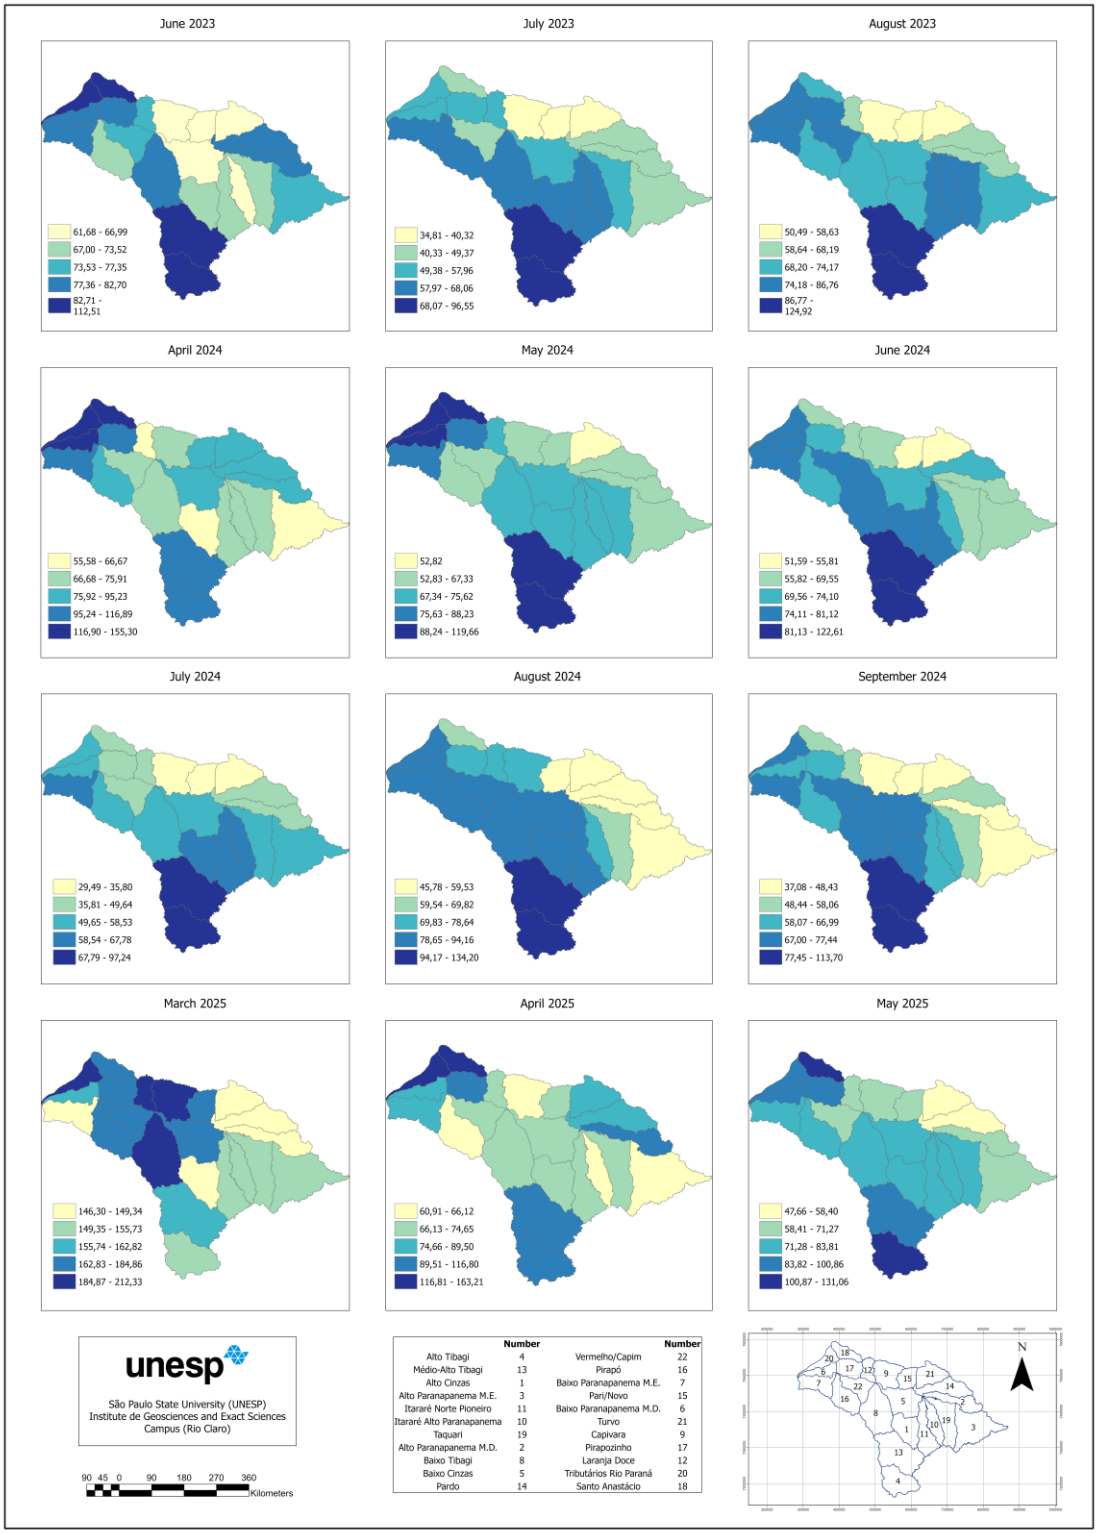
Elaborado pelo autor

A ocorrência de eventos de estresse hídrico na BHRP, determinados por valores baixos de precipitação em referência a evapotranspiração potencial ($p < ETP$) durante a estação seca, apareceriam com alta concentração nas regiões central e norte da BHRP (onde o Rio Paranapanema está localizado), especialmente nas UPHs Alto Cinzas, Capivara, Itararé Norte Pioneiro, Laranja Doce, Pirapó, Taquari e Turvo. Portanto, é importante estabelecer essas UPHs como as áreas de maior suscetibilidade e

[6] A versão on-line da Figura 14, está disponível de forma livre e aberta em: https://arcg.is/1mLHbr

vulnerabilidade a problemas de desabastecimento e escassez hídrica durante a estação seca (Figura 15).

Figura 15. Mapa previsão da precipitação para 2023-2025



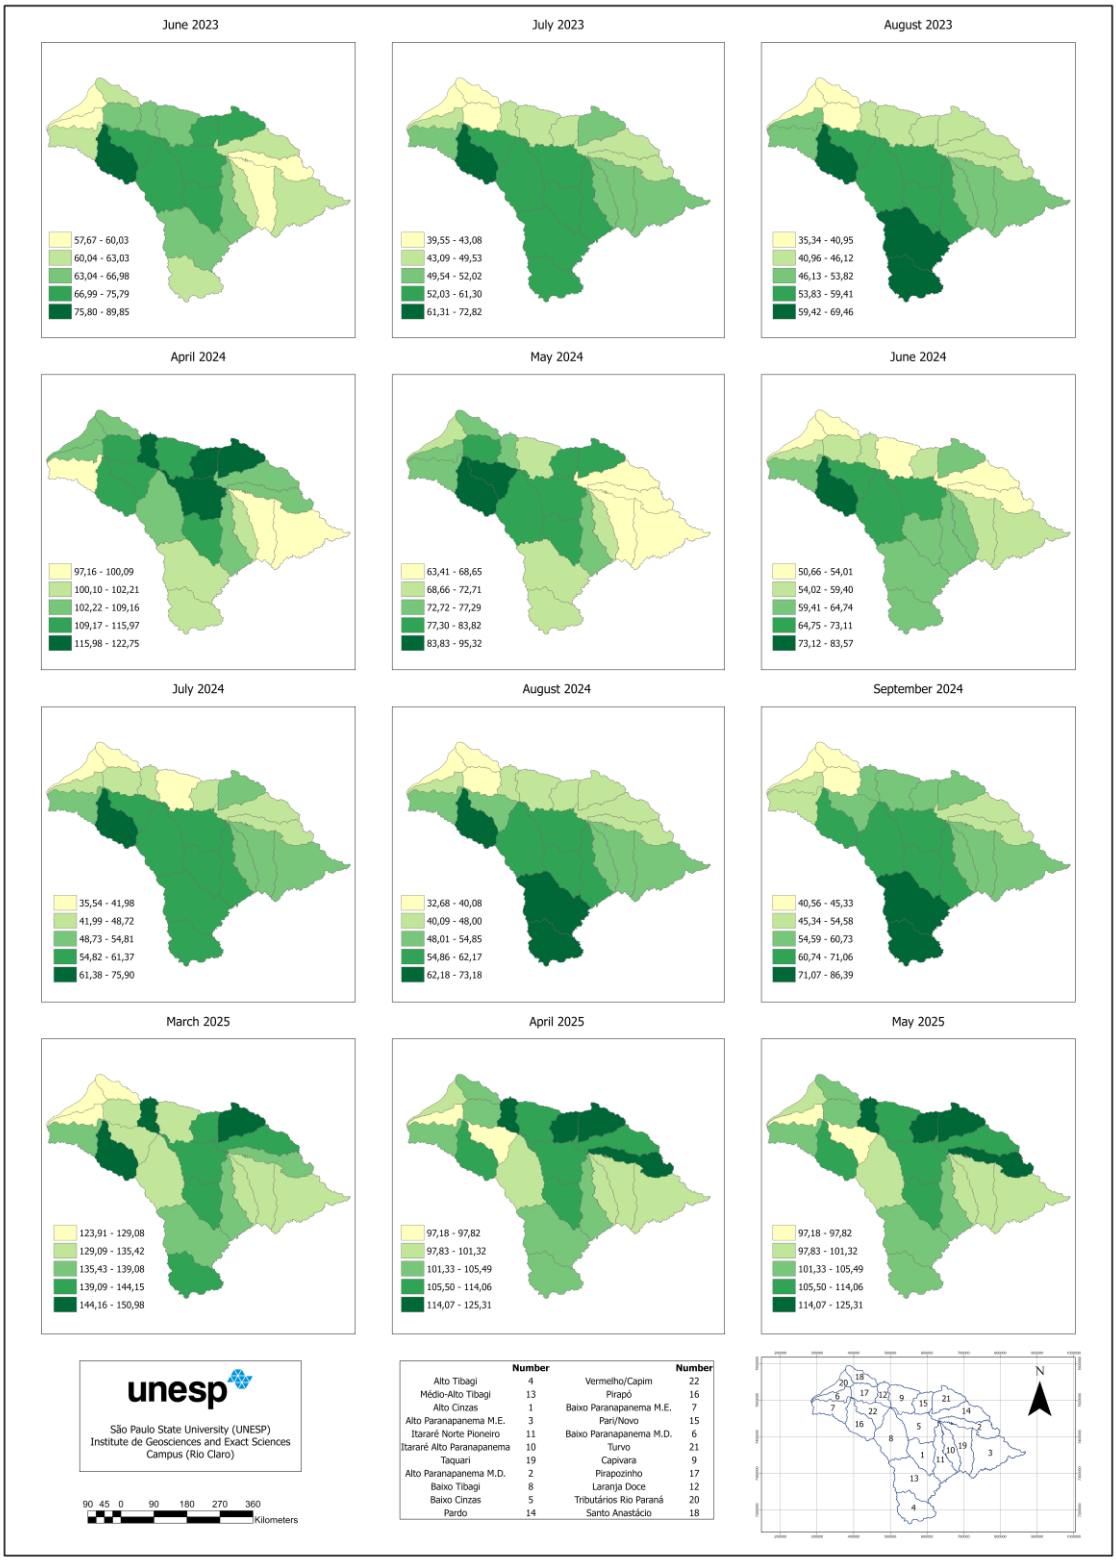
Elaborado pelo autor

Esse primeiro cenário da precipitação catalogado como prioritário, poderia impactar a produção de energia hidrelétrica instalada nas 13 (UHEs), 18 (PCHs) e 7 (CGHs), em relação às vazões e aos níveis dos reservatórios instalados, criando períodos de redução na produção de energia. Também, afetaria o desenvolvimento socioeconômico da BHRP em atividades como: abastecimento de água e disponibilidade hídrica (Tiezzi et al., 2018). Adicionalmente, durante a ocorrência desse primeiro cenário (abril - agosto 2024), espera-se uma menor precipitação especialmente nas UPHs: Alto Paranapanema M.D, Itararé Alto Paranapanema, Itararé Norte Pioneiro, Pari/Novo Turvo, Pardo e Alto Cinzas.

O segundo cenário referente ao prognóstico da ETP, teria uma alta concentração de valores ETP na região centro e sul (Figura 16), particularmente nas UPHs Alto Tibagi, Baixo Cinzas, Laranja Doce, Médio-Alto Tibagi, Pari/Novo, Pirapó, Turvo e Vermelho/Capim. Nessa perspectiva, espera-se que a ocorrência de estresse hídrico tenha maior afetação sobre o uso do solo e a atividade agrícola, especialmente nas culturas de soja e milho durante a etapa de crescimento e produtividade (Mishra & Cherkauer, 2010).

No caso do cenário da ETP, é importante adicionar que numa possível redução prolongada maior a 3 meses na precipitação, a demanda de água dos cultivos e das plantas para satisfazer seus ciclos bioquímicos, estaria unicamente associada com a capacidade de armazenamento de água do solo e com a recarga potencial do aquífero, provocando inicialmente o desabastecimento *(oferta < demanda)* no setor agrícola, para posteriormente atingir o setor ambiental, social e humano (Liu et al., 2008; Silva et al., 2018; Valipour, 2015).

Figura 16. Mapa previsão da ETP para 2023-2025



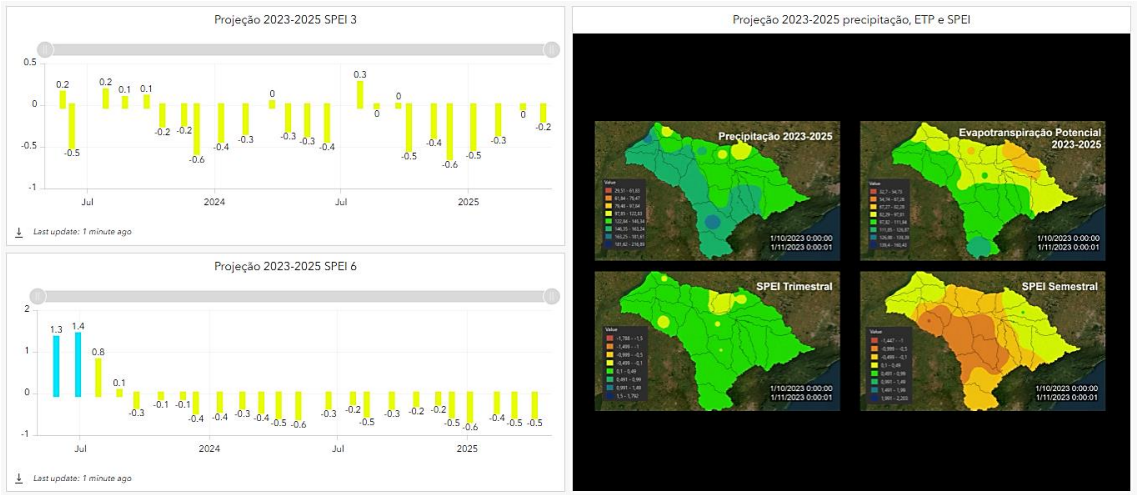
Elaborado pelo autor

6.4 Construção índice SPEI 2023-2025

A construção do índice SPEI no período 2023-2025, utilizou os prognósticos da precipitação e ETP, mencionados na seção anterior, para escalas trimestrais (SPEI-3) e semestrais (SPEI-6) nas 6 UGRHIs e 22 UPHs da BHRP. Em termos gerais, os resultados do SPEI comprovariam a transição de períodos normais ($-0{,}99 \leq SPEI \leq 0{,}99$) úmidos ($SPEI \geq 1{,}0$) e secos ($SPEI \leq -1{,}0$) para 2023-2025. No caso das secas e estiagens, demonstrariam uma marcada presença de estiagens a partir de outubro de 2023 até maio de 2025, com uma leve existência de secas de intensidade moderadas ($-1{,}0 \leq SPEI \leq -1{,}49$) em algumas UGRHIs e UPHs da BHRP. Em consequência, espera-se uma baixa tendência ou probabilidade de secas com intensidade severa ($-1{,}49 \leq SPEI \leq -1{,}99$) e extrema ($SPEI \leq -2{,}00$). A seguir, são discutidos os resultados trimestrais e semestrais do índice SPEI.

Uma primeira análise da escala trimestral (SPEI-3), evidenciaria valores de normalidade nas UGRHIs Alto Paranapanema, Médio Paranapanema e Norte Pioneiro, com uma leve tendência a secas moderadas nos primeiros semestres de 2024 e 2025. Por outra parte, as UGRHIs Piraponema, Pontal do Paranapanema e Tibagi, mostrariam períodos normais com pouca alternância entre seca e umidade de intensidade moderada ao longo de 2023-2025 (Figura 17).

Figura 17. Previsão Índice SPEI-3 e SPEI-6[7]



Elaborado pelo autor

[7] A versão on-line da Figura 17, está disponível de forma livre e aberta em: https://arcg.is/XLmSa

Uma segunda análise do SPEI-3, permite inferir que mudanças na relação precipitação e ETP, responderiam rapidamente com tendências a valores secos e úmidos do SPEI-3. Em outras palavras, qualquer desequilíbrio hidrológico entre a precipitação e ETP em escala trimestral, apontaria por exemplo ao início de déficit hídrico *(P < ETP)* e não necessariamente ao início de períodos de secas, já que não supera valores ($SPEI \leq -1{,}0$). Isto pode ser observado nas UGRHIs Alto Paranapanema, Norte Pioneiro e Piraponema no intervalo entre novembro de 2024 a maio de 2025, onde os valores do SPEI-3 durante quase 6 meses aproximam-se a dar início a secas de intensidade moderada ($-1{,}0 \leq SPEI \leq -1{,}49$).

Os resultados do SPEI-6, mostram uma forte marcação de períodos de déficit hídrico e escassez de água maiores a 6 meses nas UGRHIs Alto Paranapanema, Médio Paranapanema, Norte Pioneiro e Piraponema, começando desde outubro de 2023 até maio de 2025. Nesta escala semestral, a diferença do SPEI-3 é possível notar a aparição de estiagens o suficientemente prolongadas sem a intensidade ou magnitude de seca. De acordo com a fundamentação teórica do SPEI, estabelecida na seção 5.2. As escalas SPEI-3 e SPEI-6, utilizam os registros prévios acumulados da precipitação e ETP para calcular o valor de referência. Por exemplo, para calcular o SPEI-6 do mês de junho de 2023 o índice utilizou a precipitação e ETP de 6 meses anteriores (dezembro, janeiro, fevereiro, março, abril e maio). Motivo pelo qual, se os meses anteriores foram catalogados úmidos com intensidade moderada e severa, conforme o evidenciado no segundo semestre de 2023 nas UGRHIs Alto Paranapanema, Médio Paranapanema, Norte Pioneiro, Piraponema e Pontal do Paranapanema. A aparição de estiagens e secas utilizando o SPEI-6 responderia com menor rapidez do que o SPEI-3, que trabalha com registros acumulados trimestrais.

7 CONCLUSÕES

A ocorrência de eventos futuros relacionados à seca, estresse hídrico, escassez e disponibilidade hídrica para os próximos 2 anos na BHRP, com base nas previsões de precipitação e ETP, fornecem um diagnóstico preliminar nas UGRHIs em relação à gestão e ao monitoramento dos recursos hídricos e suas aplicações nos setores energético, agrícola, socioeconômico e ambiental da bacia. Portanto, em termos probabilísticos, esta pesquisa não estabelece ou garante com alto grau de certeza a presença desses eventos na BHRP, mas alerta para a sua possível ocorrência.

Os dois cenários de precipitação e ETP, categorizados como relevantes e com maior probabilidade de seca podem ocorrer no período de abril a setembro de 2024. Nesse intervalo, os valores de precipitação e ETP seriam reduzidos a 50 milésimos de ter/ mês, podendo afetar os níveis dos reservatórios e a produção de energia das 13 usinas hidrelétricas da BHRP. Nesse sentido, seria recomendável promover o trabalho de monitoramento e controle em tempo real para evitar a suspensão do fornecimento de energia.

O uso de algoritmos de Machine Learning como a rede NNAR, para a previsão de valores futuros de precipitação e ETP na BHRP, pode representar uma técnica alternativa e complementar para a previsão de variações de precipitação e ETP no curto prazo. No entanto, é aconselhável tentar prever e integrar a rede NNAR com diferentes métodos e índices de seca tais como: Índice de Severidade de Seca de Palmer (PDSI) e Índice de Aridez (AI). Recomenda-se também, que as previsões da NNAR incluam a possível influência do fenômeno El Niño-Oscilação Sul (ENSO) usando por exemplo, o Oceanic Niño Index (ONI).

O ajuste dos hiperparâmetros nas redes NNAR usando técnicas de busca em grade e busca aleatória poderia otimizar e reduzir a métrica RMSE encontrada nas UPHs. Além disso, melhora o desempenho no caso do uso de séries temporais com mais registros de precipitação e ETP (registros iguais ou superiores a 30 anos de medição).

A aplicação de tecnologias geoespaciais como as imagens de satélite do sistema GPM e GLDAS para a previsão de precipitação e ETP na BHRP, estabelece uma técnica alternativa para a aquisição de dados hidrológicos referentes às estações pluviométricas e fluviométricas da Rede Hidrometeorológica Nacional (RHN) no Brasil.

8 CRONOGRAMA E ATIVIDADE ACADÊMICA

8.1 Cronograma de atividades

Tabela 11. Cronograma de atividades

cronograma de atividades projeto de pesquisa																								
atividade / mês	out 2022	nov 2022	dez 2022	jan 2023	fev 2023	mar 2023	abr 2023	mai 2023	jun 2023	jul 2023	ago 2023	set 2023	out 2023	nov 2023	dez 2023	jan 2024	fev 2024	mar 2024	abr 2024	mai 2024	jun 2024	jul 2024	ago 2024	set 2024
Primeira fase																								
Elaboração do projeto	x	x																						
Delimitação do problema		x	x																					
Área de estudo			x	x																				
Aquisição de dados				x	x																			
Revisão bibliográfica e teórica					x	x																		
Segunda fase																								
Aplicação índices SPI-SPEI						x	x																	
Ponderação Inverso da Distância (IDW)							x	X																
Analise de resultados								X	x															
Terceira fase																								
Implementação rede NNAR										x	x													
Validação e correlação dos prognósticos											x	X												
Interpretação de prognósticos e tendências												X	X											
quarta fase																								
Construção índice SPEI														x	x									
Análise dos resultados e conclusões finais															x	x								
quinta fase																								
Desenvolvimento e redação do documento																	x	x	x					
Verificação e entrega inicial do documento																		x	x	X				
Correções da banca examinadora																			X	x	x			
Correções finais ao documento																				X	x	x		
Defesa do projeto																					x	x	x	x

Elaborado pelo autor

8.2 Atividade Acadêmica

O discente em acompanhamento do orientador realizaram uma semana de trabalho de campo entre os dias 06/11/2023 – 10/11/2023 na BHRP, durante aquela semana foi realizada uma visita técnica às Usinas Hidroelétricas Chavantes e Jurumirim, com o

objetivo de conhecer o processo de formação de energia hidroelétrica e sua relação com as gestão e planejamento dos recursos hídricos. Além disso, foi realizada uma visita a Faculdade de Ciências, Tecnologia e Educação (FCTE) da UNESP localizada no Campus Ourinhos – São Paulo, durante aquela visita o discente conheceu os laboratórios de climatologia e geoprocessamento na obtenção de dados meteorológicos provenientes de estacões meteorológicas instaladas no Campus de Ourinhos (Figura 18).

Figura 18. Semana de Trabalho de Campo BHRP



Elaborado pelo autor

Na atividade acadêmica, o discente apresentou em diferentes eventos acadêmicos e científicos, resultados parciais quanto totais da presente dissertação como por exemplo, no XIV encontro do programa de pós-graduação em geociências e meio ambiente. Também, no II encontro do Laboratório de Recursos Hídricos e Isótopos Ambientais (LARHIA), encontros realizados na UNESP Campus de Rio Claro. A participação desses eventos possibilitou ao candidato, discutir com outros discentes, professores e pesquisadores do PPGMA e LARHIA, sobre os resultados da presente dissertação e as possíveis recomendações a considerar durante a sua elaboração final.

Na produção acadêmica, o discente em conjunto com o orientador publicaram como autor e coautor na revista científica internacional Journal of South American Earth Sciences (JSAES), o artigo intitulado “Multidimensional forecasting of precipitation and potential evapotranspiration in the Paranapanema river basin using neural network time series”, cumprindo desta forma o discente, com doze (12) créditos em atividades complementares do PPGMA.

9 REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMOVITZ, M.; STEGUN, I. Handbook of mathematical formulas graphs and mathematical tables. **US Department of Commerce, National Bureau of Standards, Washington, DC**, [*s. l.*], 1966.

AGGARWAL, C. C. Neural Networks and Deep Learning. **Neural Networks and Deep Learning**, [*s. l.*], 2018.

AGHAKOUCHAK, A. *et al.* Status and prospects for drought forecasting: opportunities in artificial intelligence and hybrid physical–statistical forecasting. **Philosophical Transactions of the Royal Society A**, [*s. l.*], v. 380, n. 2238, 2022. Disponível em: https://royalsocietypublishing.org/doi/10.1098/rsta.2021.0288. Acesso em: 18 set. 2024.

ALPINO, T. de M. A.; FREITAS, C. M.; COSTA, A. M. Seca como um desastre. [*s. l.*], 2014.

ALVARES, C. A. *et al.* Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, [*s. l.*], v. 22, n. 6, p. 711–728, 2013.

ALVES, J. **História das secas (séculos XVII a XIX)**. [*S. l.*]: Edições do Instituto do Ceará, 1953. v. 1

ANA. **Hidroweb–Sistema de informações Hidrológicas** [*S. l.: s. n.*], 2014. Disponível em: http://hidroweb.ana.gov.br/. Acesso em: 6 mar. 2024.

ANA. **Plano Integrado de Recursos Hídricos da Unidade de Gestão de Recursos Hídricos Paranapanema**. Brasilia: Agência Nacional de Águas, 2016.

ANA. **RESOLUÇÃO ANA Nº 155, DE 18 DE MAIO DE 2023**. Brasil: Institui as Salas de Crise e as Salas de Acompanhamento como ambientes de articulação e informação para a gestão de eventos hidrológicos críticos e sistemas hídricos., 2023.

ANA; MMA. UGRH Paranapanema: AVALIAÇÃO DO QUADRO ATUAL DOS USOS DA ÁGUA E DAS DEMANDAS HÍDRICAS ASSOCIADAS. *In*: Brasília - DF: Agência Nacional de Águas & Ministério do Meio Ambiente, 2015a.

ANA; MMA. **UGRH Paranapanema: Estudos hidrológicos para definição das disponibilidades hídricas da UGRH Paranapanema**. Brasília - DF: Agência Nacional de Águas & Ministério do Meio Ambiente, 2015b.

ANA; SÃO PAULO (ESTADO); PARANÁ (ESTADO). **Resolução Conjunta Nº 613**. RESOLUÇÃO CONJUNTA PARA A CRIAÇÃO DO COMITÊ DA BACIA HIDROGRÁFICA DO RIO PARANAPANEMA., 2010.

ANDREU-HAYLES, L. *et al.* 400 Years of summer hydroclimate from stable isotopes in Iberian trees. **Climate Dynamics**, [*s. l.*], v. 49, n. 1–2, p. 143–161, 2017. Disponível em: https://link.springer.com/article/10.1007/s00382-016-3332-z. Acesso em: 27 mar. 2024.

ANGELIDIS, P. *et al.* Computation of Drought Index SPI with Alternative Distribution Functions. **Water Resources Management**, [*s. l.*], v. 26, n. 9, p. 2453–2473, 2012. Disponível em: https://link.springer.com/article/10.1007/s11269-012-0026-0. Acesso em: 17 mar. 2024.

ARAÚJO, A. P. Dinâmica fluvial e regime hidrológico na bacia hidrográfica do rio Paranapanema. **Aleph**, [*s. l.*], p. 197, 2011. Disponível em: https://repositorio.unesp.br/handle/11449/96733. Acesso em: 22 maio 2023.

ARYAL, Y.; ZHU, J. Multimodel ensemble projection of meteorological drought scenarios and connection with climate based on spectral analysis. **International Journal of Climatology**, [*s. l.*], v. 40, n. 7, p. 3360–3379, 2020. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/joc.6402. Acesso em: 28 mar. 2024.

BARTIER, P. M.; KELLER, C. P. Multivariate interpolation to incorporate thematic surface data using inverse distance weighting (IDW). **Computers & Geosciences**, [*s. l.*], v. 22, n. 7, p. 795–799, 1996.

BATISTA, M. A. B. Análise da variabilidade da precipitação pluvial na bacia do rio Paranapanema, em diferentes escalas. Campinas, SP, 2015. Disponível em: https://repositorio.unicamp.br/Busca/Download?codigoArquivo=502285. Acesso em: 11 nov. 2023.

BEGUERÍA, S. *et al.* Standardized precipitation evapotranspiration index (SPEI) revisited: parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. **International journal of climatology**, [*s. l.*], v. 34, n. 10, p. 3001–3023, 2014.

BERGSTRA, J. *et al.* Algorithms for Hyper-Parameter Optimization. *In*: , 2011. (J. Shawe-Taylor et al., Org.) **Advances in Neural Information Processing Systems**. [*S. l.*]: Curran Associates, Inc., 2011.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **Journal of machine learning research**, [*s. l.*], v. 13, n. 2, 2012.

BLAIN, G. C.; BRUNINI, O. Quantificação da seca agrícola pelo índice padronizado de evapotranspiração real (IPER) no estado de São Paulo. **Bragantia**, [*s. l.*], v. 65, n. 3, p. 517–525, 2006.

BONACCORSO, B. *et al.* Spatial variability of drought: an analysis of the SPI in Sicily. **Water resources management**, [*s. l.*], v. 17, p. 273–296, 2003.

BRASIL. **Atlas do desenvolvimento humano no Brasil 2013**. Ranking. Disponível em: http://www. atlasbrasil. org. br/2013/pt/ranking/. Acesso em: 27 mar. 2024

BRASIL. **Decreto 5 de Junho de 2012**. Brasília: Institui o Comitê da Bacia Hidrográfica do Rio Paranapanema, com área de atuação localizada nos Estados do Paraná e de São Paulo, e dá outras providências, jun. 2012a. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/dsn/dsn13326.htm. Acesso em: 27 mar. 2024.

BRASIL. **Lei N° 9.433**. Brasília: Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos, jan. 1997. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l9433.htm. Acesso em: 12 fev. 2023.

BRASIL. **Lei N° 12.608**. Brasília: Institui a Política Nacional de Proteção e Defesa Civil - PNPDEC; dispõe sobre o Sistema Nacional de Proteção e Defesa Civil - SINPDEC e o Conselho Nacional de Proteção e Defesa Civil - CONPDEC, abr. 2012b. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12608.htm#art31. Acesso em: 12 fev. 2023.

BRASIL. **Lei N° 13.153**. Brasília: Institui a Política Nacional de Combate à Desertificação e Mitigação dos Efeitos da Seca e seus instrumentos; prevê a criação da Comissão Nacional de Combate à Desertificação, jul. 2015. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/l13153.htm. Acesso em: 27 mar. 2024.

BRASIL. **Lei Nº 12.187**. Brasília: Institui a Política Nacional sobre Mudança do Clima - PNMC e dá outras providências., dez. 2009. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2007-2010/2009/lei/l12187.htm. Acesso em: 27 mar. 2024.

BRASIL; MINISTÉRIO DO MEIO AMBIENTE; SECRETARIA DE RECURSOS HÍDRICOS E AMBIENTE URBANO. ÀGUAS subterrâneas: um recurso a ser conhecido e protegido. [S. l.]: Ministério do Meio Ambiente. Secretaria de Recursos Hídricos e Ambiente Urbano, 2007. Disponível em: https://books.google.com.br/books?id=ha3LZwEACAAJ.

BURTON *et al.* **The environment as hazard**. [*S. l.*]: Oxford University Press, 1993. Acesso em: 3 out. 2023.

CAMPOS, J. N. B. VULNERABILIDADES HIDROLÓGICAS DO SEMI-ÁRIDO ÀS SECAS. **Planejamento e Políticas Públicas**, [*s. l.*], n. 16, 1997. Disponível em: //www.ipea.gov.br/ppp/index.php/PPP/article/view/120. Acesso em: 27 mar. 2024.

CAÑADA, M. R. *et al.* **Sistemas y Análisis de la Información Geográfica. Manual de autoaprendizaje con ArcGIS**. [*S. l.: s. n.*], 2007.

CARDIM, F.; GARCIA, R. **Tratados da terra e gente do Brasil**. [*S. l.*]: J. Leite & cia., 1925.

CARMELLO, V.; NETO, J. L. S. Variabilidade das chuvas na vertente paranaense da bacia do rio Paranapanema-1999-2000 a 2009-2010. **Raega-O Espaço Geográfico em Análise**, [*s. l.*], v. 33, p. 225–247, 2015.

CARPENEDO, C. B.; AMBRIZZI, T. Anticiclone Subtropical do Atlântico Sul Associado ao Modo Anular Sul e Impactos Climáticos no Brasil. **Revista Brasileira de Meteorologia**, [*s. l.*], v. 35, n. 4, p. 605–613, 2020.

CARTWRIGHT, E. D. The Hottest Year in Record and What Sea Sponge Tells Us About Climate Change. **Climate and Energy**, [*s. l.*], v. 40, n. 9, p. 13–19, 2024. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/gas.22396. Acesso em: 24 mar. 2024.

CAVALCANTI, I. F. A.; KOUSKY, V. E. Drought in Brazil during summer and fall 2001 and associated atmospheric circulation features. **Rev. Climanálise**, [*s. l.*], v. 1, p. 1–10, 2001.

CBH PARANAPANEMA. **Sala de Situação/Crise**. [*S. l.*], 2019. Disponível em: https://www.paranapanema.org/comite/sala-de-situacao/. Acesso em: 27 mar. 2024.

CEPED; UFSC. **Atlas brasileiro de desastres naturais: 1991 a 2012**. [*S. l.: s. n.*], 2013.

CHAMINÉ, H. I. *et al.* Engineering geosciences, geotechnics and functional geomaterials: new trends on GIS mapping, geotechnologies and design with geohazards. **SN Applied Sciences**, [*s. l.*], v. 5, n. 1, p. 1–3, 2023. Disponível em: https://link.springer.com/article/10.1007/s42452-022-05213-7. Acesso em: 18 set. 2024.

CHEN, F. W.; LIU, C. W. Estimation of the spatial rainfall distribution using inverse distance weighting (IDW) in the middle of Taiwan. **Paddy and Water Environment**, [*s. l.*], v. 10, n. 3, p. 209–222, 2012. Disponível em: https://link.springer.com/article/10.1007/s10333-012-0319-1. Acesso em: 10 out. 2023.

CHOI, Y. GeoAI: Integration of Artificial Intelligence, Machine Learning, and Deep Learning with GIS. **Applied Sciences 2023, Vol. 13, Page 3895**, [*s. l.*], v. 13, n. 6, p. 3895, 2023. Disponível em: https://www.mdpi.com/2076-3417/13/6/3895/htm. Acesso em: 18 set. 2024.

CODLING, M.; RAMLAL, B.; DAVIS, D. Examining the Feasibility of GeoAI and IoT for Smart Flood Early Warning Systems in Local Communities for Caribbean Urban Spaces. **West Indian Journal of Engineering**, [*s. l.*], v. 46, n. 2, p. 91–101, 2024. Disponível em: https://journals.sta.uwi.edu/ojs/index.php/wije/article/view/8974. Acesso em: 18 set. 2024.

COLLINS, M. *et al.* Long-term climate change: projections, commitments and irreversibility. [*s. l.*], 2013.

COOK, E. R. *et al.* Asian monsoon failure and megadrought during the last millennium. **Science**, [*s. l.*], v. 328, n. 5977, p. 486–489, 2010. Disponível em: https://www.science.org/doi/10.1126/science.1185188. Acesso em: 27 mar. 2024.

CORSON-DOSCH *et al.* **The Water Cycle**. [*S. l.*], 2022. Disponível em: https://www.usgs.gov/media/images/water-cycle-png. Acesso em: 19 abr. 2024.

CUNHA, G. R. Meteorologia. **Fatos e mitos. Passo Fundo. EMBRAPA**, [*s. l.*], 1997a.

CUNHA, G. R. O fenômeno El Niño-Oscilação do Sul e suas aplicações na agricultura do sul do Brasil. **Passo Fundo: Embrapa Trigo**, [*s. l.*], 1997b.

CURY, J. F.; RONCA, J. L. C. **A região da bacia hidrográfica do Rio Paranapanema, vertente paulista: a sua ocupação e uso - 1950 a 1997**. 1999. - Universidade de São Paulo, [*s. l.*], 1999.

DA SILVA, F. C. T. Crises de fome e utilização dos recursos naturais no Brasil colonial (Paper 011). **Papers do NAEA**, [*s. l.*], v. 1, n. 1, 1993.

DE CASTRO, A. L. C. **Glossário de defesa civil estudos de riscos e medicina de desastres**. [*S. l.*]: Ministério do Planejamento e Orçamento, Secretaria Especial de Políticas …, 1998.

DING, B.; QIAN, H.; ZHOU, J. Activation functions and their characteristics in deep neural networks. **Proceedings of the 30th Chinese Control and Decision Conference, CCDC 2018**, [*s. l.*], p. 1836–1841, 2018.

DUKAT, P. *et al.* Trends in drought occurrence and severity at mid-latitude European stations (1951–2015) estimated using standardized precipitation (SPI) and precipitation and evapotranspiration (SPEI) indices.

Meteorology and Atmospheric Physics, [*s. l.*], v. 134, n. 1, p. 1–21, 2022. Disponível em: https://link.springer.com/article/10.1007/s00703-022-00858-w. Acesso em: 28 mar. 2024.

ESRI. **IDW (Spatial Analyst)**. [*S. l.*], 2024. Disponível em: https://pro.arcgis.com/en/pro-app/3.1/tool-reference/spatial-analyst/idw.htm. Acesso em: 28 mar. 2024.

FIELD, C. B.; BARROS, V. R.; CHANGE, I. P. on C. **Climate change 2014: impacts, adaptation, and vulnerability: Working Group II contribution to the fifth assessment report of the Intergovernmental Panel on Climate Change**. New York, NY: Cambridge University Press, 2014.

GAO, S.; HU, Y.; LI, W. Handbook of Geospatial Artificial Intelligence. **Handbook of Geospatial Artificial Intelligence**, [*s. l.*], p. 1–448, 2023.

GELLES, D. The crucial summit gets down to business a day after scientists said 2023 is set be the hottest year in human history. **The New York Times (Digital Edition)**, [*s. l.*], p. NA-NA, 2023.

GINER, N. **New GeoAI tools in ArcGIS Pro 3.0**. [*S. l.*], 2022. Disponível em: https://medium.com/@nmg5007/new-geoai-tools-in-arcgis-pro-3-0-5d142a65fa5c. Acesso em: 18 set. 2024.

GUNASEKARA, N. K. *et al.* Water Conflict Risk due to Water Resource Availability and Unequal Distribution. **Water Resources Management**, [*s. l.*], v. 28, n. 1, p. 169–184, 2014. Disponível em: https://link.springer.com/article/10.1007/s11269-013-0478-x. Acesso em: 19 abr. 2024.

GUTTMAN, N. B. Accepting the standardized precipitation index: a calculation algorithm 1. **JAWRA Journal of the American Water Resources Association**, [*s. l.*], v. 35, n. 2, p. 311–322, 1999.

GUTTMAN, N. B. Comparing the palmer drought index and the standardized precipitation index 1. **JAWRA Journal of the American Water Resources Association**, [*s. l.*], v. 34, n. 1, p. 113–121, 1998.

HADID, A.; CHAKRABORTY, T.; BUSBY, D. When geoscience meets generative AI and large language models: Foundations, trends, and future challenges. **Expert Systems**, [*s. l.*], v. 41, n. 10, p. e13654, 2024. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1111/exsy.13654. Acesso em: 18 set. 2024.

HAYES, M. J. Drought Indices. **Van Nostrand's Scientific Encyclopedia**, [*s. l.*], 2006. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/0471743984.vse8593. Acesso em: 21 mar. 2024.

HECHT-NIELSEN, R. Theory of the backpropagation neural network. *In*: NEURAL NETWORKS FOR PERCEPTION. [*S. l.*]: Elsevier, 1992. p. 65–93.

HOUGHTON *et al.* **Climate Change 1995: The Science of Climate Change: contribution of working group I to the second assessment report of the Intergovernmental Panel on Climate Change**. [*S. l.*]: Cambridge University Press, Cambridge, UK, 1995. Disponível em: Acesso em: 3 out. 2023.

HOUGHTON, J. E. T. *et al.* Climate Change 2001: The Scientific Basis. *In*: CONTRIBUTION OF WORKING GROUP I TO THE THIRD ASSESSMENT REPORT OF THE INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). [*S. l.: s. n.*], 2001. v. 881., p. 881.

HUFFMAN *et al.* **GPM IMERG Final Precipitation L3 1 day 0.1 degree x 0.1 degree V06**. [*S. l.*], 2019. Disponível em: https://disc.gsfc.nasa.gov/datasets/GPM_3IMERGDF_06/summary?keywords=imerg%20v06. Acesso em: 25 out. 2023.

HYNDMAN *et al.* **Forecasting functions for time series and linear models**. [*S. l.*]: R package version 8.21.1, 2015.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 3rd eded. Australia: OTexts: Melbourne, 2018.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic Time Series Forecasting: The forecast Package for R. **Journal of Statistical Software**, [*s. l.*], v. 27, n. 3, p. 1–22, 2008.

IBGE. **Produção Agrícola Municipal Culturas Temporárias e Permanentes**. Rio de Janeiro: [*s. n.*], 2012a. v. 39.

IBGE. Sinopse do censo demográfico : 2010 / IBGE. *In*: Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2012b. p. 265.

IGBE. **Produto interno bruto dos municípios : 2011**. IBGEed. Rio de Janeiro: [*s. n.*], 2013. Disponível em: https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=281946. Acesso em: 6 mar. 2024.

IPCC. **Climate Change: The IPCC 1990 and 1992 Assessments**. [*S. l.*]: World Meteorological Organization and United Nations Environment Programme, 1992.

JACKSON, R. B. *et al.* Water in a changing world. **Ecological applications**, [*s. l.*], v. 11, n. 4, p. 1027–1045, 2001.

JONES, R. N. Managing uncertainty in climate change projections - issues for impact assessment: An editorial comment. **Climatic Change**, [*s. l.*], v. 45, n. 3–4, p. 403–419, 2000. Disponível em: https://link.springer.com/article/10.1023/A:1005551626280. Acesso em: 9 jan. 2024.

KARLIK, B.; OLGAC, A. V. Performance analysis of various activation functions in generalized MLP architectures of neural networks. **International Journal of Artificial Intelligence and Expert Systems**, [*s. l.*], v. 1, n. 4, p. 111–122, 2011.

KARPATNE, A. *et al.* Machine Learning for the Geosciences: Challenges and Opportunities. **IEEE Transactions on Knowledge and Data Engineering**, [*s. l.*], v. 31, n. 8, p. 1544–1554, 2019.

KAYANO, M. T.; MOURA, A. D. O El Nino de 1982-83 e a Precipitação Sobre a América do Sul. **Brazilian Journal of Geophysics**, [*s. l.*], v. 4, n. 2, p. 201–214, 2018. Disponível em: https://sbgf.org.br/revista/index.php/rbgf/article/view/1055. Acesso em: 9 mar. 2024.

KOUSARI, M. R. *et al.* Introducing an operational method to forecast long-term regional drought based on the application of artificial intelligence capabilities. **Theoretical and Applied Climatology**, [*s. l.*], v. 127, n. 1–2, p. 361–380, 2017. Disponível em: https://link.springer.com/article/10.1007/s00704-015-1624-6. Acesso em: 18 set. 2024.

KROGH, A. What are artificial neural networks?. **Nature Biotechnology 2008 26:2**, [*s. l.*], v. 26, n. 2, p. 195–197, 2008. Disponível em: https://www.nature.com/articles/nbt1386. Acesso em: 28 mar. 2024.

LAIMIGHOFER, J.; LAAHA, G. How standard are standardized drought indices? Uncertainty components for the SPI & SPEI case. **Journal of Hydrology**, [*s. l.*], v. 613, p. 128385, 2022.

LECOCQ, F. *et al.* Mitigation and development pathways in the near-to mid-term (Chapter 4). [*s. l.*], 2022.

LEE, J.-Y. *et al.* Future global climate: scenario-based projections and near-term information. *In*: CLIMATE CHANGE 2021: THE PHYSICAL SCIENCE BASIS. CONTRIBUTION OF WORKING GROUP I TO THE SIXTH ASSESSMENT REPORT OF THE INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. [*S. l.*]: Cambridge University Press, 2021. p. 553–672.

LI, Z.; LI, Q.; CHEN, T. Record-breaking High-temperature Outlook for 2023: An Assessment Based on the China Global Merged Temperature (CMST) Dataset. **Advances in Atmospheric Sciences**, [*s. l.*], v. 41, n. 2, p. 369–376, 2024. Disponível em: https://link.springer.com/article/10.1007/s00376-023-3200-9. Acesso em: 24 mar. 2024.

LIU, X. *et al.* Agricultural drought monitoring: Progress, challenges, and prospects. **Journal of Geographical Sciences**, [*s. l.*], v. 26, n. 6, p. 750–767, 2016. Disponível em: https://link.springer.com/article/10.1007/s11442-016-1297-9. Acesso em: 25 mar. 2024.

LÓPEZ, D. N. *et al.* Caracterización de la sequía a diversas escalas de tiempo en Chihuahua, México. **Agrociencia**, [*s. l.*], v. 41, n. 3, p. 253–262, 2007.

LU, G. Y.; WONG, D. W. An adaptive inverse-distance weighting spatial interpolation technique. **Computers & Geosciences**, [*s. l.*], v. 34, n. 9, p. 1044–1055, 2008. Disponível em: Acesso em: 29 out. 2023.

MAIA, D. C.; NOGUEIRA MAIA, A. C. A utilização dos ditos populares e da observação do tempo para a Climatologia Escolar no Ensino Fundamental II. **GeoTextos**, [*s. l.*], v. 6, n. 1, 2010. Disponível em: https://periodicos.ufba.br/index.php/geotextos/article/view/4305.

MANZIONE, R. L. Detection of spatial and temporal precipitation patterns using remotely sensed data in the Paranapanema River Basin, Brazil from 2000 to 2021. **Discover Water 2023 3:1**, [*s. l.*], v. 3, n. 1, p. 1–20, 2023. Disponível em: https://link.springer.com/article/10.1007/s43832-023-00035-z. Acesso em: 11 nov. 2023.

MANZIONE, R. L. Interpretation of Land Use and Land Cover Changes at Different Classification Levels: The Paranapanema River Basin - Brazil Case. *In*: FUZZO DFS, et al. (org.). **Earth observation for monitoring and modeling land use**. Amsterdam: Elsevier, 2024.

MASSON-DELMOTTE *et al.* **Climate Change 2021: The Physical Science Basis**. [*S. l.*]: Contribution of working group I to the sixth assessment report of the intergovernmental panel on climate change, 2021.

MATA-LIMA, H. *et al.* Impactos dos desastres naturais nos sistemas ambiental e socioeconômico: o que faz a diferença? **Ambiente & Sociedade**, [*s. l.*], v. 16, n. 3, p. 45–64, 2013. Disponível em: https://www.scielo.br/j/asoc/a/b8D9BKhQXYsKhR3X7Lnsxfm/?lang=pt. Acesso em: 27 mar. 2024.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. The relationship of drought frequency and duration to time scales. *In*: , 1993. **Proceedings of the 8th Conference on Applied Climatology**. [*S. l.*]: California, 1993. p. 179–183.

MCNALLY *et al.* **FLDAS Noah Land Surface Model L4 Global Monthly 0.1 x 0.1 degree (MERRA-2 and CHIRPS)**. [*S. l.*], 2018. Disponível em: https://disc.gsfc.nasa.gov/datasets/FLDAS_NOAH01_C_GL_M_001/summary. Acesso em: 25 out. 2023.

MEDEIROS FILHO, J. de; SOUZA, I. de. Os degradados filhos da seca. [*s. l.*], 1983.

MEHRAN, A.; MAZDIYASNI, O.; AGHAKOUCHAK, A. A hybrid framework for assessing socioeconomic drought: Linking climate variability, local resilience, and demand. **Journal of Geophysical Research: Atmospheres**, [*s. l.*], v. 120, n. 15, p. 7520–7533, 2015. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/2015JD023147. Acesso em: 25 mar. 2024

MISHRA, A. K.; DESAI, V. R. Drought forecasting using feed-forward recursive neural network. **Ecological Modelling**, [*s. l.*], v. 198, n. 1, p. 127–138, 2006. Disponível em: http://www.sciencedirect.com/science/article/pii/S0304380006002055.

MORALES, M. S. *et al.* Six hundred years of South American tree rings reveal an increase in severe hydroclimatic events since mid-20th century. **Proceedings of the National Academy of Sciences of the United States of America**, [*s. l.*], v. 117, n. 29, p. 16816–16823, 2020. Disponível em: https://www.pnas.org/doi/abs/10.1073/pnas.2002411117. Acesso em: 3 out. 2023.

NAKICENOVIC, N. *et al.* Special report on emissions scenarios. [*s. l.*], 2000.

NALBANTIS, I.; TSAKIRIS, G. Assessment of hydrological drought revisited. **Water Resources Management**, [*s. l.*], v. 23, n. 5, p. 881–897, 2009. Disponível em: https://link.springer.com/article/10.1007/s11269-008-9305-1. Acesso em: 25 mar. 2024.

NIELSEN, M. A. **Neural Networks and Deep Learning**. Vol. 25ed. San Francisco, CA, USA: Determination Press, 2015.

ONS. **Inventário das restrições operativas hidráulicas dos aproveitamentos hidrelétricos**. [*S. l.*]: OPERADOR NACIONAL DO SISTEMA ELÉTRICO, 2012. Disponível em: https://docplayer.com.br/37707111-Inventario-das-restricoes-operativas-hidraulicas-dos-aproveitamentos-hidreletricos.html. Acesso em: 6 mar. 2024.

ONU. a Agenda 2030 para o Desenvolvimento Sustentável. **Recuperado em**, [*s. l.*], v. 15, p. 24, 2016.

ORTEGA GAUCIN, D. Sequía: causas y efectos de un fenómeno global. **Ciencia UANL (2007-1175), Vol. 16, No. 61**, [*s. l.*], 2013.

PARIZOTTO, T. M. Analise da precipitação pluvial na Bacia do Paranapanema. **Monografia de Graduação em Geografia, Universidade Estadual Paulista, Ourinhos**, [*s. l.*], 2008.

PARRY, M. L. *et al.* **Climate Change 2007 Impacts, Adaptation and Vulnerability: Working group II contribution to the fourth assessment report of the IPCC**. Vol 4ed. [*S. l.*]: Cambridge University Press, Cambridge, 2007. Disponível em: Acesso em: 5 out. 2023.

PATEL, N. R.; CHOPRA, P.; DADHWAL, V. K. Analyzing spatial patterns of meteorological drought using standardized precipitation index. **Meteorological Applications**, [*s. l.*], v. 14, n. 4, p. 329–336, 2007. Disponível em: http://doi.wiley.com/10.1002/met.33.

PHILIP, G. M.; WATSON, D. F. A precise method for determining contoured surfaces. **The APPEA Journal**, [*s. l.*], v. 22, n. 1, p. 205–212, 1982. Disponível em: https://www.publish.csiro.au/aj/aj81016. Acesso em: 10 out. 2023.

PONVERT-DELISLES BATISTA, D. R. Algunas consideraciones sobre el comportamiento de la sequía agrícola en la agricultura de Cuba y el uso de imágenes por satélites en su evaluación. **Cultivos Tropicales**, [*s. l.*], v. 37, n. 3, p. 22–41, 2016. Disponível em: http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0258593620160003000003&lng=es&nrm=iso&tlng=pt. Acesso em: 9 mar. 2024.

QUIRING, S. M.; PAPAKRYIAKOU, T. N. An evaluation of agricultural drought indices for the Canadian prairies. **Agricultural and Forest Meteorology**, [*s. l.*], v. 118, n. 1–2, p. 49–62, 2003.

RASAMOELINA, A. D.; ADJAILIA, F.; SINČÁK, P. A review of activation function for artificial neural network. *In*: , 2020. **2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)**. [*S. l.*]: IEEE, 2020. p. 281–286.

RIEHL, S. *et al.* Drought stress variability in ancient Near Eastern agricultural systems evidenced by δ13C in barley grain. **Proceedings of the National Academy of Sciences of the United States of America**, [*s. l.*], v. 111, n. 34, p. 12348–12353, 2014. Disponível em: https://www.pnas.org/doi/abs/10.1073/pnas.1409516111. Acesso em: 27 mar. 2024.

SANTOS, E. *et al.* A SECA NO NORDESTE NO ANO DE 2012: RELATO SOBRE A ESTIAGEM NA REGIÃO E O EXEMPLO DE PRÁTICA DE CONVIVÊNCIA COM O SEMIÁRIO NO DISTRITO DE IGUAÇU/CANINDÉ-CE. **Revista Geonorte**, [*s. l.*], v. 3, n. 8, p. 819–830, 2012.
SHARMA, Sagar; SHARMA, Simone; ATHAIYA, A. Activation functions in neural networks. **Towards Data Sci**, [*s. l.*], v. 6, n. 12, p. 310–316, 2017.

SHEPARD, D. A two-dimensional interpolation function for irregularly-spaced data. **Proceedings of the 1968 23rd ACM National Conference, ACM 1968**, [*s. l.*], p. 517–524, 1968. Disponível em: https://dl.acm.org/doi/10.1145/800186.810616. Acesso em: 1 abr. 2024.

SHIKLOMANOV, I. A. World water resources: a new appraisal and assessment for the 21st century. [*s. l.*], 1998.

SIMONOVIC, S. P. World water dynamics: global modeling of water resources. **Journal of Environmental Management**, [*s. l.*], v. 66, n. 3, p. 249–267, 2002.

SIO-SE MARDEH, A. *et al.* Evaluation of drought resistance indices under various environmental conditions. **Field Crops Research**, [*s. l.*], v. 98, n. 2–3, p. 222–229, 2006.

SMERDON, J. E.; COOK, E. R.; STEIGER, N. J. The Historical Development of Large-Scale Paleoclimate Field Reconstructions Over the Common Era. **Reviews of Geophysics**, [*s. l.*], v. 61, n. 4, p. e2022RG000782, 2023. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1029/2022RG000782. Acesso em: 27 mar. 2024.

SPINONI, J. *et al.* World drought frequency, duration, and severity for 1951–2010. **International Journal of Climatology**, [*s. l.*], v. 34, n. 8, p. 2792–2804, 2014. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/joc.3875. Acesso em: 9 mar. 2024.

STAGGE, J. H. *et al.* Candidate Distributions for Climatological Drought Indices (SPI and SPEI). **International Journal of Climatology**, [*s. l.*], v. 35, n. 13, p. 4027–4040, 2015. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/joc.4267. Acesso em: 17 mar. 2024.

STAHLE, D. W. *et al.* Tree-ring reconstructed megadroughts over North America since A.D. 1300. **Climatic Change**, [*s. l.*], v. 83, n. 1–2, p. 133–149, 2007. Disponível em: https://link.springer.com/article/10.1007/s10584-006-9171-x. Acesso em: 20 fev. 2024

SVOBODA, M. *et al.* **Standardized Precipitation Index User Guide**. Geneva: WMO, 2012. (WMO). Disponível em: http://library.wmo.int/opac/index.php?lvl=notice_display&id=13682. Acesso em: 17 maio 2023.

SVOBODA, M. D.; FUCHS, B. A. Handbook of Drought Indicators and Indices*. **Drought and Water Crises**, [*s. l.*], p. 155–208, 2017. Disponível em: https://www.taylorfrancis.com/chapters/edit/10.1201/b22009-11/handbook-drought-indicators-indices-mark-svoboda-brian-fuchs. Acesso em: 28 mar. 2024.

SVOZIL, D.; KVASNIČKA, V.; POSPÍCHAL, J. Introduction to multi-layer feed-forward neural networks. **Chemometrics and Intelligent Laboratory Systems**, [*s. l.*], v. 39, n. 1, p. 43–62, 1997. Disponível em: Acesso em: 22 out. 2023.

TAVARES, V. C.; ARRUDA, Í. R. P. de; SILVA, D. G. da. Desertificação, mudanças climáticas e secas no semiárido brasileiro: uma revisão bibliográfica. **Geosul**, [*s. l.*], v. 34, n. 70, p. 385–405, 2019. Disponível em: https://periodicos.ufsc.br/index.php/geosul/article/view/2177-5230.2019v34n70p385. Acesso em: 27 mar. 2024.

TEIXEIRA, S. *et al.* Índices e Metodologias de Monitoramento de Secas: Uma Revisão. **Revista Brasileira de Meteorologia**, [*s. l.*], v. 36, n. 3 suppl, p. 495–511, 2021. Disponível em: https://www.scielo.br/j/rbmet/a/rGqGprMLXW5F66b6R98D98j/?lang=pt. Acesso em: 9 mar. 2024.

THOM, H. C. S. A note on the gamma distribution. **Monthly weather review**, [*s. l.*], v. 86, n. 4, p. 117–122, 1958.

TU, X. *et al.* Multivariate design of socioeconomic drought and impact of water reservoirs. **Journal of Hydrology**, [*s. l.*], v. 566, p. 192–204, 2018. Disponível em: Acesso em: 25 mar. 2024.

USGS. **The distribution of water on, in, and above the Earth**. [*S. l.*], 2019. Disponível em: https://www.usgs.gov/media/images/distribution-water-and-above-earth. Acesso em: 19 abr. 2024.

VAN LOON, A. F. Hydrological drought explained. **Wiley Interdisciplinary Reviews: Water**, [*s. l.*], v. 2, n. 4, p. 359–392, 2015. Disponível em: https://onlinelibrary.wiley.com/doi/full/10.1002/wat2.1085. Acesso em: 25 mar. 2024.

VERDAN, I. da S.; JÚNIOR, A. C. da S. O.; SILVA, M. E. S. Variabilidade interanual da zona de convergência do Atlântico Sul e sua associação com o El Niño-Oscilação Sul entre 2000 e 2021. São Paulo, 2023. Disponível em: https://repositorio.usp.br/item/003152149. Acesso em: 9 mar. 2024.

VERSCHUREN, D.; LALRD, K. R.; CUMMING, B. F. Rainfall and drought in equatorial east Africa during the past 1,100 years. **Nature 2000 403:6768**, [*s. l.*], v. 403, n. 6768, p. 410–414, 2000. Disponível em: https://www.nature.com/articles/35000179. Acesso em: 20 fev. 2024

VICENTE-SERRANO, S. M. *et al.* A New Global 0.5° Gridded Dataset (1901–2006) of a Multiscalar Drought Index: Comparison with Current Drought Index Datasets Based on the Palmer Drought Severity Index. **Journal of Hydrometeorology**, [*s. l.*], v. 11, n. 4, p. 1033–1043, 2010. Disponível em: https://journals.ametsoc.org/view/journals/hydr/11/4/2010jhm1224_1.xml. Acesso em: 17 mar. 2024.

VICENTE-SERRANO, S. M.; BEGUERÍA, S.; LÓPEZ-MORENO, J. I. A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. **Journal of Climate**, [*s. l.*], v. 23, n. 7, p. 1696–1718, 2010. Disponível em: https://journals.ametsoc.org/view/journals/clim/23/7/2009jcli2909.1.xml. Acesso em: 17 mar. 2024.

WANG, S.-C. Artificial Neural Network. **Interdisciplinary Computing in Java Programming**, Boston, MA, p. 81–100, 2003. Disponível em: https://link.springer.com/chapter/10.1007/978-1-4615-0377-4_5. Acesso em: 28 mar. 2024.

WATSON, D. F.; PHILIP, G. M. A refinement of inverse distance weighted interpolation. **Geo-Processing**, [*s. l.*], v. 2, p. 315–327, 1985. Disponível em: https://cir.nii.ac.jp/crid/1573387450062569472. Acesso em: 10 out. 2023.

WEBSTER, M. D. *et al.* Uncertainty in emissions projections for climate models. **Atmospheric Environment**, [*s. l.*], v. 36, n. 22, p. 3659–3670, 2002. Disponível em: Acesso em: 9 jan. 2024.

WEERTS, H. J. P.; MUELLER, A. C.; VANSCHOREN, J. Importance of Tuning Hyperparameters of Machine Learning Algorithms. [*s. l.*], 2020. Disponível em: https://arxiv.org/abs/2007.07588v1. Acesso em: 5 dez. 2023.

WILHITE, D. A. Drought as a natural hazard. [*s. l.*], 2000.

WMO, G.; OMM, G. International meteorological vocabulary. [*s. l.*], 1966.

WMO; UNESCO. **International Glossary of Hydrology**. [*S. l.*]: World Meteorological Organization, United Nations Educational, Scientific and Cultural Organization, 2012-. ISSN 0177-9915. Disponível em:

http://www.wmo.int/pages/prog/hwrp/publications/international_glossary/385_IGH_2012.pdf. Acesso em: 25 mar. 2024.

WYTHOFF, B. J. Backpropagation neural networks: A tutorial. **Chemometrics and Intelligent Laboratory Systems**, [*s. l.*], v. 18, n. 2, p. 115–155, 1993. Disponível em: Acesso em: 28 mar. 2024.

YANG, L. *et al.* Google Earth Engine and Artificial Intelligence (AI): A Comprehensive Review. **Remote Sensing 2022, Vol. 14, Page 3253**, [*s. l.*], v. 14, n. 14, p. 3253, 2022. Disponível em: https://www.mdpi.com/2072-4292/14/14/3253/htm. Acesso em: 18 set. 2024.

YANTO *et al.* Landslide susceptible areas identification using IDW and Ordinary Kriging interpolation techniques from hard soil depth at middle western Central Java, Indonesia. **Natural Hazards**, [*s. l.*], v. 110, n. 2, p. 1405–1416, 2022. Disponível em: https://link.springer.com/article/10.1007/s11069-021-04982-5. Acesso em: 31 mar. 2024.

ZHAO, T. *et al.* Artificial intelligence for geoscience: Progress, challenges, and perspectives. **The Innovation**, [*s. l.*], v. 5, n. 5, p. 100691, 2024. Disponível em: http://www.cell.com/article/S2666675824001292/fulltext. Acesso em: 18 set. 2024.

ZHOU, J. *et al.* Choice of potential evapotranspiration formulas influences drought assessment: A case study in China. **Atmospheric research**, [*s. l.*], v. 242, p. 104979, 2020.

ANEXOS

Anexo A - Índices de secas

Índice	Parâmetros	Observações
Meteorologia		
Índice de Anomalia de Aridez (AAI)	P, T, PET, ET	Operacionalmente disponível para a Índia
Índice de Seca Keetch-Byram (KBDI)	P, T	Os cálculos baseiam-se no clima da zona de interesse
Índice de Precipitação Padronizado (SPI)	P	Destacado pela OMM como ponto de partida para a monitorização meteorológica da seca
Anomalia Ponderada Padronizada Precipitação (WASP)	P, T	Utiliza dados em quadrícula para monitorizar a seca nas regiões tropicais
Índice de Aridez (AI)	P, T	Altamente utilizado em classificações climáticas
Índice de Seca Efetivo (EDI)	P	Programa disponível através de contacto direto com a entidade de origem
Índice de Severidade de Seca de Palmer (PDSI)	P, T, AWC	Alta complexidade dos cálculos e à necessidade de dados completos em série
Índice de Anomalia de Chuva (RAI)	P	Necessidade de dados completos em série
Índice de Severidade de Seca de Palmer Autocalibrado (sc-PDSI)	P, T, AWC	Parâmetros do PDSI com metodologia que calcula as características de cada estação e regime climático
Índice de Anomalias Padronizado (SAI)	P	Dados pontuais utilizados para descrever as condições regionais
Índice Padronizado de Precipitação – Evapotranspiração (SPEI)	P, T	Dados serialmente completos necessários com saída semelhante à SPI, mas com um componente de temperatura
Umidade do solo		
Anomalia de Umidade do Solo (SMA)	P, T, AWC	Destinado a melhorar o balanço hídrico do PDSI
Índice de Déficit de Evapotranspiração (ETDI)	Mod	Cálculos complexos com várias entradas necessárias
Índice de Déficit de Umidade do Solo (SMDI)	Mod	Cálculos semanais em diferentes profundidades do solo, complicado de calcular
Hidrologia		
Índice Padronizado de Abastecimento de Reservatórios (SRSI)	RD	Cálculos semelhantes ao SPI usando dados do reservatório
Índice Padronizado de Fluxo de Água (SSFI)	SF	Usa o programa SPI junto com dados de fluxo de água
Índice de Nível de Água Padronizado (SWI)	GW	Cálculos semelhantes ao SPI, mas usando dados de águas subterrâneas ou de nível de poço em vez de precipitação
Índice de Seca de Fluxo de Água (SDI)	SF	Cálculos semelhantes aos do SPI, mas usando dados de fluxo de água em vez de precipitação
Índice de Abastecimento de Água de Superfície (SWSI)	P, RD, SF, S	Muitas metodologias e produtos derivados disponíveis, mas as comparações entre bacias estão sujeitas ao método escolhido
Sensoriamento Remoto		
Índice de Estresse Evaporativo (ESI)	Sat, PET	Não tem um longo histórico como um produto operacional
Índice de Vegetação por Diferença Normalizada (NDVI)	Sat	Calculado para a maioria dos locais

Índice de Resposta da Vegetação à Seca (VegDRI)	Sat, P, T, AWC, LC, ER	Leva em conta muitas variáveis para separar o estresse da seca de outros estresses da vegetação
Índice de satisfação de necessidade de água (WRSI)	Sat, Mod, CC	Operacional para muitos locais
Composto ou modelado		
Indice Combinado de Seca (CDI)	Mod, P, Sat	Usa dados de superfície e de sensoriamento remoto
Sistema Global Integrado de Monitoramento e Previsão da Seca (GIDMaPS)	Multiple, Mod	Integra três índices: Índice de umidade do solo padronizado, SPI e Índice de seca padronizado multivariado
Sistema Global de Assimilação de Dados Terrestres (GLDAS)	Multiple, Mod, Sat	Útil em regiões com poucos dados devido à extensão global
Índice de Seca Padronizado Multivariado (MSDI)	Multiple, Mod	Disponível, mas é necessária interpretação

Fonte: Svoboda e Fuchs (2017)

Anexo B – Códigos de programação e repositórios GitHub

Os códigos de programação e scripts utilizados no desenvolvimento da presente pesquisa, estão disponibilizados de forma aberta e livre no GitHub oficial do autor. Da mesma forma, o autor concede aos leitores as permissões para a replicação parcial ou total dos códigos-fonte:

GitHub oficial do autor

https://github.com/CarlosMendez1997Col

Repositório índices SPI e SPEI.

https://github.com/CarlosMendez1997Col/Evaluate-hydrological-and-meteorological-droughts-using-C-and-R.git

Repositório prognostico rede NNAR

https://github.com/CarlosMendez1997Col/Model-and-forecasts-hidrological-and-energetic-resources-using-ArcGIS-API-for-Python-and-R.git

Repositório de geoprocessamento de dados

https://github.com/CarlosMendez1997Col/Monitoring-water-resources-using-Google-Earth-Engine-and-Javascript.git