



Serviço Público Federal
Ministério da Educação
Fundação Universidade Federal de Mato Grosso do Sul
Faculdade de Engenharias, Arquitetura e Urbanismo e Geografia - FAENG



LUIZ CLAUDIO GALVÃO DO VALLE JUNIOR



**ESTIMATIVA E PREVISÃO DA PROPAGAÇÃO DA SECA
NOS BIOMAS BRASILEIROS**

Campo Grande, MS.

2025

**UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE ENGENHARIAS E ARQUITETURA E URBANISMO E GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS AMBIENTAIS**

LUIZ CLAUDIO GALVÃO DO VALLE JUNIOR

**ESTIMATIVA E PREVISÃO DA PROPAGAÇÃO DA SECA
NOS BIOMAS BRASILEIROS**

Tese submetida ao Programa de Pós-graduação em Tecnologias Ambientais da Universidade Federal do Mato Grosso do Sul como requisito parcial a obtenção do título de Doutor em Tecnologias Ambientais, área de concentração: *Saneamento ambiental e Recursos Hídricos*.

Orientador: Prof. Dr. Thiago Rangel Rodrigues

Aprovada em: 25/02/2025

Banca Examinadora:

Prof. Dr. Thiago Rangel Rodrigues
Orientador PGTA- UFMS

Prof. Dr. Bergson Guedes Bezerra
Universidade Federal do Rio Grande do Norte – UFRN

Prof. Dr. Gabriel Brito Costa
Universidade Federal do Oeste do Pará – UFOPA

Prof. Dr. Jamil Alexandre Ayach Anache
Universidade de São Paulo - USP

Prof. Dr. Paulo Tarso Sanches de Oliveira
Universidade Federal de Mato Grosso do Sul - UFMS

Campo Grande, MS.

2025

DEDICATÓRIA

Dedico esse trabalho aos meus pais, Luiz Claudio (in memoriam) e Marileide, à minha irmã Jouse, e à minha esposa Amanda, que nunca deixaram de dar o suporte necessário para que eu chegasse até aqui.

EPÍGRAFE

*“A vitória está reservada para aqueles que
estão dispostos a pagar o preço.” (Sun Tzu)*

AGRADECIMENTOS

- Primeiramente, a Deus por me dar força, saúde, sabedoria e iluminar meu caminho durante esta parte da minha vida;
- Aos meus pais, Luiz Claudio (*in memoriam*) e Marileide, por todo amor, suporte e paciência, pois sem o incentivo da parte deles eu jamais teria chegado nesta etapa da minha vida;
- À minha esposa Amanda, que sempre me puxou pra cima nos momentos em que eu estava pra baixo e nunca deixou de acreditar em mim;
- Ao meu orientador, Prof. Dr. Thiago Rangel Rodrigues, que aceitou o desafio de trabalhar junto comigo há 7 anos e se mostrou não apenas um excelente profissional, mas também um grande amigo durante esta jornada;
- Ao meu amigo Pedro, não só pela amizade, mas por todo o apoio durante o meu Doutorado e auxílio na elaboração dos resultados deste estudo;
- Aos meus amigos Caio, Timpurim, Cafure, Andrey, Robson e Uglyaybe pelos momentos de alegria e descontração;
- À banca examinadora por aceitarem o convite para participar deste trabalho com as suas avaliações e contribuições;
- Ao Prof. Dr. Paulo Tarso Sanches de Oliveira, que me introduziu à pesquisa científica e trabalhos acadêmicos na época da minha graduação e foi de grande incentivo para meu ingresso na pós-graduação;
- Ao Laboratório de Ciências Atmosféricas (LCA) e ao Laboratório de Hidrologia, Erosão e Sedimentos (HEroS) pelo espaço disponibilizado para desenvolvimento e realização da minha pesquisa. Este agradecimento se estende aos colegas de laboratório pelo suporte e ideias;

- Aos colegas da Universidade Federal de Mato Grosso (UFMT) e do Programa de Pós-Graduação de Física Ambiental (PPGFA) por disponibilizarem dados durante minhas pesquisas na pós-graduação e pelas parcerias em outros estudos;
- Ao Programa de Pós-Graduação em Tecnologias Ambientais (PPGTA), da Faculdade de Engenharias, Arquitetura e Urbanismo (FAENG) da Fundação Universidade Federal de Mato Grosso do Sul (UFMS), pela estrutura, professores, colegas e corpo técnico;
- À Coordenação de Aperfeiçoamento Pessoal do Ensino Superior (CAPES) pelo auxílio financeiro concedido durante toda pesquisa e ao projeto. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (Capes) - Código de Financiamento 001

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS	xi
LISTA DE SÍMBOLOS	xiv
RESUMO	xv
ABSTRACT	xvii
1. INTRODUÇÃO.....	19
1.1. Introdução Geral	19
2. OBJETIVOS.....	24
2.1. Objetivo geral	24
2.2. Hipótese.....	24
2.3. Objetivos específicos.....	24
3. MATERIAL E MÉTODOS	25
3.1. Contexto regional e coleta de dados	25
3.2. Índices de seca padronizados.....	27
3.3. Análise de tendência.....	29
3.4. Análise de correlação cruzada	31
3.5. Métodos de <i>machine learning</i>	31
3.6. Avaliação de desempenho dos modelos	33
4. RESULTADOS.....	35
4.1. Análise de tendências das variáveis micrometeorológicas e vazão.....	35
4.2. Análise quantitativa dos eventos de seca nos biomas brasileiros.....	44
4.3. Análise de tendência de SPI, SPEI e SSI.....	63
4.4. Análise de correlação cruzada entre os índices de seca.....	71
4.5. Estimativas de SSI utilizando métodos de <i>machine learning</i>	76
5. DISCUSSÃO.....	96
5.1. Variação espaço-temporal das variáveis hidrometeorológicas.....	96
5.2. Distribuição e variação espaço-temporal dos eventos de seca	98
5.3. Avaliação dos métodos de <i>machine learning</i> na estimativa de SSI.....	102
6. CONCLUSÃO.....	106
7. SUGESTÕES PARA TRABALHOS FUTUROS.....	108
8. REFERÊNCIAS BIBLIOGRÁFICAS	109

LISTA DE FIGURAS

Figura 1. Mapa de localização das bacias hidrográficas do CABra e biomas brasileiros.	26
Figura 2. Tendência de precipitação (P) nas bacias hidrográficas em mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	36
Figura 3. Tendências de a) temperatura mínima (Tmin) e b) temperatura máxima (Tmax) nas bacias hidrográficas em °C/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	37
Figura 4. Tendências de a) umidade relativa do ar (UR) e b) velocidade do vento a 2 m de altura do nível do solo (u2) nas bacias hidrográficas em, respectivamente, %/ano e m/s/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	39
Figura 5. Tendências de a) radiação solar incidente (Rad) e b) evapotranspiração real (ET) nas bacias hidrográficas em, respectivamente, MJ/m ² /ano e mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	41
Figura 6. Tendência de evapotranspiração de referência (ET _o) nas bacias hidrográficas em mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	42
Figura 7. Tendências de vazão em a) volume e b) porcentagem da vazão média da bacia nas bacias hidrográficas em, respectivamente, m ³ /s/ano e %/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.	43
Figura 8. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 1 mês. O Brasil está dividido por biomas.	46
Figura 9. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 3 meses. O Brasil está dividido por biomas.	50
Figura 10. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 6 meses. O Brasil está dividido por biomas.	54

Figura 11. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 12 meses. O Brasil está dividido por biomas.	58
Figura 12. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 24 meses. O Brasil está dividido por biomas.	61
Figura 13. Tendência dos índices SPI, SPEI e SSI na escala de 1 mês. O Brasil está dividido por biomas.	64
Figura 14. Tendência dos índices SPI, SPEI e SSI na escala de 3 meses. O Brasil está dividido por biomas.	66
Figura 15. Tendência dos índices SPI, SPEI e SSI na escala de 6 meses. O Brasil está dividido por biomas.	67
Figura 16. Tendência dos índices SPI, SPEI e SSI na escala de 12 meses. O Brasil está dividido por biomas.	69
Figura 17. Tendência dos índices SPI, SPEI e SSI na escala de 24 meses. O Brasil está dividido por biomas.	70
Figura 18. Comparativo entre SPI24 e SPEI24 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEIxSSI da Tabela 8 para a bacia do rio Madeira, na Amazônia.	77
Figura 19. Estimativas de SSI1 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.	77
Figura 20. Estimativas de SSI3 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.	79
Figura 21. Estimativas de SSI6 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.	80

Figura 22. Estimativas de SSI12 a) sem atraso e b) com atraso de 4 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.	81
Figura 23. Estimativas de SSI24 a) sem atraso e b) com atraso de 4 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.	82
Figura 24. Comparativo entre SPI24 e SPEI24 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEIxSSI da Tabela 9 para a bacia do rio Formoso, no Cerrado.	83
Figura 25. Estimativas de SSI1 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.	84
Figura 26. Estimativas de SSI3 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.	85
Figura 27. Estimativas de SSI6 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.	86
Figura 28. Estimativas de SSI12 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.	87
Figura 29. Estimativas de SSI24 a) sem atraso e b) com atraso de 5 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.	88
Figura 30. Comparativo entre SPI12 e SPEI12 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEIxSSI da Tabela 10 para a bacia do rio Paraguai, no Pantanal.	89
Figura 31. Estimativas de SSI1 sem atraso utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.	90

Figura 32. Estimativas de SSI3 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.....	91
Figura 33. Estimativas de SSI6 a) sem atraso e b) com atraso de 3 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.....	92
Figura 34. Estimativas de SSI12 a) sem atraso e b) com atraso de 6 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.....	93
Figura 35. Estimativas de SSI24 a) sem atraso e b) com atraso de 12 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.....	95

LISTA DE TABELAS

Tabela 1. Tabela de classificação dos eventos de seca.	29
Tabela 2. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 1 mês e a média de eventos por bacia hidrográfica por bioma.	48
Tabela 3. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 3 meses e a média de eventos por bacia hidrográfica por bioma.	52
Tabela 4. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 6 meses e a média de eventos por bacia hidrográfica por bioma.	56
Tabela 5. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 12 meses e a média de eventos por bacia hidrográfica por bioma.	59
Tabela 6. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 24 meses e a média de eventos por bacia hidrográfica por bioma.	63
Tabela 7. Tendências, em ano ⁻¹ , para SPI, SPEI e SSI para as bacias hidrográficas selecionadas para avaliar propagação e previsão dos eventos de seca.	72
Tabela 8. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI, SPEIxSSI em todas as escalas para a bacia do rio Madeira, na Amazônia. Os valores acima de 0,700 foram destacados em negrito.	73
Tabela 9. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI, SPEIxSSI em todas as escalas para a bacia do rio Formoso, no Cerrado. Os valores acima de 0,700 foram destacados em negrito.	74
Tabela 10. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI,	

SPEIxSSI em todas as escalas para a bacia do rio Paraguai, no Pantanal. Os valores acima de 0,700 foram destacados em negrito. 75

Tabela 11. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia. 78

Tabela 12. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia. 78

Tabela 13. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia. 80

Tabela 14. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia. 81

Tabela 15. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia. 82

Tabela 16. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado. 84

Tabela 17. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado. 85

Tabela 18. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado. 86

Tabela 19. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.	87
Tabela 20. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.	88
Tabela 21. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.	90
Tabela 22. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.	91
Tabela 23. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.	92
Tabela 24. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.	94
Tabela 25. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.	95

LISTA DE SÍMBOLOS

SPI - Standardized precipitation index (índice de precipitação padronizado)
SPEI - Standardized precipitation evapotranspiration index (índice de precipitação-
evapotranspiração padronizado)
SSI - Standardized streamflow index (índice de escoamento padronizado)
CABra - Base de dados Catchments Attributes for Brazil (atributos de bacias
hidrográficas para o Brasil)
P - Precipitação
Q - Vazão
Eto - Evapotranspiração de referência
Rn - Saldo de radiação
G - Fluxo de calor do solo
Ta - Temperatura média do ar
u2 - Velocidade do vento a uma temperatura de 2 m acima do solo
es - Pressão de saturação de vapor
ea - Pressão real de vapor
 γ - Constante psicrométrica
 Δ - Inclinação da curva de pressão de vapor
D - Diferença entre precipitação e evapotranspiração de referência
ML - Machine learning
SVM - Support vector machine
GEP - Gene expression programming
ANN - Artificial neural networks
r - Coeficiente de correlação de Pearson
RMSE - Erro quadrático médio
RAE - Erro absoluto relativo
MAE - Erro absoluto médio
P90 - Percentil 90%

RESUMO

VALLE JUNIOR, L. C. G. (2025). Estimativa e previsão da propagação da seca nos biomas brasileiros. 2025. 118p. Tese - Programa de Pós Graduação em Tecnologias Ambientais. Universidade Federal de Mato Grosso do Sul, Brasil.

Por conta dos riscos que as secas trazem à segurança hídrica, alimentar e energética de uma determinada população, eventos extremos podem causar não só grandes prejuízos econômicos, mas também perda de vidas humanas e animais. Para países como o Brasil, onde a energia hidráulica é a principal matriz energética e o setor agrícola é a principal fonte de economia do país, secas mais severas podem causar infortúnios em diversas escalas, portanto, como forma de evitar grandes danos à qualidade de vida e a economia, entender o comportamento dos eventos de seca e conseguir prever futuros períodos de estiagem com acurácia se tornam estratégias valiosas. Uma das formas de contabilizar eventos de seca e suas respectivas intensidades é o uso de índices padronizados, que se utilizam de análise estatística de uma série temporal para gerar indicadores de períodos úmidos ou secos. O desafio está na obtenção de séries de dados de qualidade de variáveis meteorológicas e, principalmente no Brasil, hidrológicas, dificultando as estimativas de secas para gerar diagnósticos e prognósticos. Por conta da dificuldade da coleta de dados hidrológicos, o objetivo deste trabalho foi analisar as condições de seca nos biomas brasileiros através de dados hidrometeorológicos provenientes de uma série temporal entre 1980 e 2010 de dados medidos de 735 bacias distribuídas em todos os seis biomas brasileiros. Para caracterizar tais condições de seca, foram utilizados índices padronizados de seca meteorológica (SPI e SPEI) e hidrológica (SSI) considerando precipitação (P), evapotranspiração de referência (ET_o) e vazão (Q), respectivamente, em diferentes escalas de tempo, variando entre 1, 3, 6, 12 e 24 meses. Os eventos de seca ao decorrer da série foram contabilizados, assim como foi realizada a análise de tendência das variáveis hidrometeorológicas e dos índices de seca. Além disso, foram testados modelos utilizando *machine learning* (ML) para facilitar a previsão de índices de seca hidrológica através de precipitação e evapotranspiração de referência, considerando um atraso entre os índices meteorológicos e o índice hidrológico avaliado através de correlação cruzada. Os métodos de ML utilizados foram *support vector machine* (SVM), *gene expression. programming* (GEP) e *artificial neural networks* (ANN). A análise de tendência das variáveis micrometeorológicas, de vazão e dos índices de seca indicou variações que levam ao aumento dos eventos de estiagem hidrológica e meteorológica em quantidade e intensidade ao decorrer da série histórica em grande parte do país, especialmente no Pantanal, Cerrado e Amazônia. No total de eventos de seca, nota-se um número maior de eventos detectados com SPI e SPEI do que os observados com SSI, notavelmente no Pampa e na Caatinga. Foi possível observar que no Pantanal há um atraso bem definido entre a seca meteorológica e hidrológica, porém na Amazônia e Cerrado os resultados indicam que há outros fatores além de P e ET_o que influenciam nas estimativas de SSI. Dentre os modelos de ML utilizados, SVM e GEP apresentaram estimativas com menores erros do que os resultados gerados por ANN. De forma geral, os eventos de maior escala de tempo, como 12 e 24 meses, apresentaram estimativas com menores erros, todavia, no Pantanal, em todas as escalas de tempo os modelos de ML produziram resultados satisfatórios, desde que considerado o atraso ideal entre as

variáveis. Tais ferramentas possibilitam o melhor entendimento do comportamento da seca no Brasil e possibilidades de facilitar a previsão de eventos de seca hidrológica severa ou extrema, especialmente em locais que não possuem medições ou séries históricas consistentes de vazão dos corpos hídricos.

Palavras-chave: propagação de seca, previsão de seca, eventos extremos, mudanças climáticas, gestão de recursos hídricos, *machine learning*.

ABSTRACT

VALLE JUNIOR, L. C. G. (2025). Estimates and prediction of drought propagation in the Brazilian biomes. 2025. 118p. Thesis – Postgraduate Program in Environmental Technologies. Federal University of Mato Grosso do Sul, Brazil.

Due to the risks that drought brings to water, food, and energy security from a specific population, extreme drought can cause not only huge economic losses but also endanger human and animal lives. For countries like Brazil, where hydroelectricity is the primary energy source and agriculture is the leading contributor to the Brazilian economy, intense droughts can cause harm in several ways. Therefore, to mitigate further damage to life quality and economy, understanding drought events behavior and being able to predict future periods of aridity with accuracy can be valuable strategies. A manner of counting drought events and their intensity is the use of standardized indexes, which utilize statistical analysis of a time series to produce indicators of wet and dry periods. The challenge is in collecting high-quality meteorological and, especially in Brazil, hydrological data, making it difficult to obtain estimates regarding drought to generate diagnoses and forecasts. Considering the difficulties of collecting hydrological data, the goal of this work was to analyze drought conditions across Brazilian biomes through hydrometeorological data from a time series that spans from 1980 to 2010, utilizing information from 735 catchments distributed throughout the country. To characterize such drought conditions, it was used standardized indexes regarding meteorological (SPI and SPEI) and hydrological events (SSI), considering precipitation (P), reference evapotranspiration (ET_o), and discharge (Q), respectively, in different time scales, varying between 1, 3, 6, 12, and 24 months. Drought events were counted throughout the time series, and trend analysis was conducted on the hydrometeorological variables and the drought indexes. Additionally, models using machine learning (ML) were tested to aid in predicting hydrological drought indexes based on precipitation and reference evapotranspiration, considering a lag between the meteorological indexes and the hydrological one, which was evaluated through cross-correlation analysis. The ML methods employed were support vector machine (SVM), gene expression programming (GEP), and artificial neural networks (ANN). The trend analysis of the micrometeorological data, discharge, and drought indexes variables indicated variations that led to an increase in both hydrological and meteorological drought events during the time series across much of the country, especially in Pantanal, Cerrado, and Amazon rainforest. Considering the total number of drought events, it is noticed that a higher number of events were detected with SPI and SPEI than with SSI, notably in Pampa and Caatinga. It was possible to observe that in Pantanal there is a well-defined lag between meteorological and hydrological drought; however, in the Amazon rainforest and Cerrado, the obtained results indicate that factors beyond P and ET_o influence SSI estimates. Among the ML models tested, SVM and GEP provided the best estimates, producing smaller errors than the results generated by ANN. Generally, the events in longer time scales, such as 12 and 24 months, showed estimates with smaller errors, although, in Pantanal, ML models produced satisfactory results in all time scales as long as an ideal lag is considered between the variables. These tools can provide a better understanding of drought behavior in Brazil and the possibilities of promoting severe and

extreme hydrological drought events forecast, particularly in areas lacking measurements or consistent time series of discharge.

Keywords: drought propagation, drought forecast, extreme events, climate change, water resources management, machine learning.

1. INTRODUÇÃO

1.1. Introdução Geral

A seca é um evento meteorológico e hidrológico extremo que traz riscos tanto à segurança alimentar quanto à geração de energia, além de ser uma ameaça à sobrevivência de muitos e podendo levar a um aumento na migração de grandes populações de áreas rurais para regiões urbanizadas (DE OLIVEIRA-JÚNIOR *et al.*, 2018; HAO *et al.*, 2014; SHEFFIELD; WOOD; RODERICK, 2012; YERDELEN; ABDELKADER; ERIS, 2021). Este evento é causado por um prolongado déficit de precipitação, começando de forma lenta, mas terminando rapidamente após fortes eventos de chuva (DAI *et al.*, 2020; HUANG *et al.*, 2019; SOLH; VAN GINKEL, 2014). As secas severas e prolongadas impactaram tanto a economia, com um prejuízo anual em torno de 6 a 8 bilhões de dólares por conta de perdas na agricultura nos Estados Unidos (DAI *et al.*, 2020), quanto a qualidade de vida de diversas populações, como por exemplo centenas de milhares de mortes atribuídas diretamente à eventos de seca na região do Sahel, na África (GUHA-SAPIR; HARGITT; HOYOS, 2004; TOUMA *et al.*, 2015). Quando comparadas aos outros tipos de desastres naturais, as secas são uns dos eventos menos compreendidos e que acabam causando mais prejuízos (KAO; GOVINDARAJU, 2010; ZHANG *et al.*, 2015). Portanto, identificar e entender tais eventos e as alterações que os causam podem aperfeiçoar as estimativas e previsões de secas, gerando ferramentas de grande valia para mitigação de secas e gestão de recursos hídricos.

Recentemente, diversos estudos relacionados à eventos de seca têm sido desenvolvidos no Brasil (DA ROCHA JÚNIOR *et al.*, 2020; FILHO *et al.*, 2020; JULIANI; OKAWA, 2017; JUNQUEIRA *et al.*, 2020; THIELEN *et al.*, 2020), principalmente por conta do impacto da produção agrícola no PIB brasileiro e geração de energia de matriz hidrelétrica. As secas são geralmente recorrentes e difundidas na região

Nordeste do país (CUNHA *et al.*, 2019), que concentra a maior parte da população ocupada em agricultura familiar no Brasil, cerca de 47% dos agricultores familiares no país (IBGE, 2019), portanto a provisão de diversas famílias acabam sendo afetadas. Demais regiões agrícolas brasileiras, como a parte sul da Amazônia, uma parcela do Pantanal e todo o Cerrado, embora possuam períodos de naturais de estiagem (DE OLIVEIRA *et al.*, 2021; RODRIGUES *et al.*, 2014, 2016a) , também acabam tendo a produção afetada pelas mudanças climáticas e no ciclo hidrológico, causadas principalmente pela substituição da vegetação nativa por pastagens e monoculturas e queimadas (DE OLIVEIRA *et al.*, 2021; OLIVEIRA *et al.*, 2014; OLIVEIRA-JÚNIOR *et al.*, 2020; RODRIGUES *et al.*, 2016b; THIELEN *et al.*, 2020). Além do impacto causado pela agricultura local, há também o impacto do aumento da temperatura da superfície do mar e a influência de El Niño/La Niña nas variações climáticas naturais do Brasil, provocando períodos de estiagem incomuns (HASTENRATH, 2006; JIMÉNEZ-MUÑOZ *et al.*, 2016; SORRIBAS *et al.*, 2016).

Dentre as abordagens quali-quantitativas para analisar eventos de seca, as mais comuns são os índices padronizados de seca, que são importantes ferramentas para sistemas de monitoramento de seca (DE OLIVEIRA-JÚNIOR *et al.*, 2018; SHAMSHIRBAND *et al.*, 2020). Os índices de mais destaque na literatura são: *Palmer Drought Severity Index* (PDSI, índice de severidade de seca de Palmer) (PALMER, 1965), o *Standardized Precipitation Index* (SPI, índice de precipitação padronizado) (MCKEE; DOESKEN; KLEIST, 1993), o *Standardized Precipitation Evapotranspiration Index* (SPEI, índice de precipitação-evapotranspiração padronizado) (VICENTE-SERRANO; BEGUERÍA; LÓPEZ-MORENO, 2010) e o *Standardized Streamflow Index* (SSI, índice de escoamento padronizado) (SHUKLA; WOOD, 2008). Estes índices permitem analisar a propagação da seca, geralmente em escala mensal (FANG *et al.*, 2020; PEÑA-

GALLARDO *et al.*, 2019), além de apresentarem simplicidade na aplicação, geralmente usando apenas séries temporais de uma ou duas variáveis para a determinação dos resultados. Por se tratarem de índices padronizados e normalizados, a comparação entre diferentes climas e períodos se torna simplificada.

Para entender as peculiaridades de eventos extremos de seca, diversos estudos relacionados a índices de seca têm sido feitos em diferentes regiões do globo, abrangendo variados tipos de clima (BELAYNEH *et al.*, 2014; BOUAZIZ; MEDHIOUB; CSAPLOVISC, 2021; CUNHA *et al.*, 2019; FANG *et al.*, 2020; HUANG *et al.*, 2019; JEHANZAIB; KIM, 2020; KHOURY; COOMES, 2020; YERDELEN; ABDELKADER; ERIS, 2021). Por exemplo, Fang *et al.* (2020) analisou a resposta da propagação da seca meteorológica nos eventos de seca hidrológicos usando 50 anos de dados de precipitação de 22 estações na China. Yerdelen, Abdelkader e Eris, (2021) detectou ciclos de curto e longo prazo de secas na Turquia utilizando análise de wavelet. Huang *et al.* (2016) utilizou cenários futuros de mudanças climáticas para estimar índices de seca até o ano de 2100 na Malásia. Outra abordagem utilizada por outros estudos recentes é a implementação de machine learning na predição de índices de seca (BELAYNEH *et al.*, 2014; BOUAZIZ; MEDHIOUB; CSAPLOVISC, 2021; SHAMSHIRBAND *et al.*, 2020), a fim de desenvolver valiosas ferramentas para monitoramento e previsão de eventos extremos de seca.

Tais trabalhos com índices de seca também têm sido realizados pelos últimos anos no Brasil (CUNHA *et al.*, 2019; DA ROCHA JÚNIOR *et al.*, 2020; DA SILVA *et al.*, 2021; DE OLIVEIRA-JÚNIOR *et al.*, 2018; JESUS *et al.*, 2020; JUNQUEIRA *et al.*, 2020; THIELEN *et al.*, 2020), usando tanto dados observados em estações meteorológicas do Instituto Nacional de Meteorologia (INMET) quanto informações de sensoriamento remoto. Se tratando de apresentação de SPI em território nacional, tanto o

INMET quanto o Instituto Nacional de Pesquisas Espaciais (INPE) apresentam resultados para o Brasil todo, além do monitor de secas encabeçado pela Agência Nacional de Águas e Saneamento Básico (ANA), que apresenta de forma mensal regiões que estão passando por eventos de seca. Entretanto, poucos estudos realizados nos países utilizaram outros índices que não envolvem apenas precipitação, como SSI e SPEI, devido à dificuldade em obter longas séries temporais de outros dados meteorológicos e hidrológicos, principalmente dados de vazão e volume de água no solo. Os dados hidrológicos do Brasil são disponibilizados de forma aberta pela ANA, porém devido às limitações de medições, estudos no Brasil geralmente tratam de regiões específicas ou um número reduzido de bacias (CHAGAS *et al.*, 2020). Jesus *et al.* (2020) e Junqueira *et al.* (2020) realizaram estudos utilizando SSI no Brasil, porém entendendo a condição de apenas uma bacia em cada pesquisa. Recentemente foram desenvolvidas duas bases de dados hidrometeorológicos de livre acesso (ALMAGRO *et al.*, 2021; CHAGAS *et al.*, 2020), compilando informações de mais de 20 anos para todo território nacional, facilitando o desenvolvimento de estudos de propagação de seca numa escala nacional.

Considerando os efeitos de secas hidrológicas e meteorológicas tanto na situação ambiental quanto na questão socioeconômica, que envolvem conflitos de usos dos recursos hídricos e o aumento no custo dos serviços de distribuição de água e energia, e conseqüentemente a produção de alimentos, é de suma importância entender o comportamento dos eventos de estiagem e os possíveis cenários futuros para um melhor planejamento na gestão de recursos hídricos. Além disso, as dificuldades de obtenção de dados hidrológicos, como vazão, provocam a necessidade de formas mais simplificadas de estimativa de eventos de seca hidrológica. Portanto, o presente trabalho tem como alvo analisar a dinâmica das secas meteorológicas e hidrológicas nos biomas brasileiros, a fim

de testar ferramentas utilizando *machine learning* para estimar índices de seca hidrológica considerando como entrada variáveis com maior facilidade de coleta.

2. OBJETIVOS

2.1. Objetivo geral

O objetivo deste trabalho foi avaliar o comportamento de secas meteorológicas e hidrológicas nos biomas brasileiros e das variáveis que compõem tais eventos, promovendo a previsão de eventos de estiagem através de variáveis simplificadas.

2.2. Hipótese

- a) Espera-se que as variações espaço-temporais das variáveis micrometeorológicas impactem diretamente nas tendências dos valores de SPI, SPEI e SSI nas bacias;
- b) Pressupõe-se que haja correlação estatisticamente significativa entre os índices de seca meteorológica e o índice de seca hidrológica com um determinado atraso entre elas conforme as características de clima e uso e cobertura do solo;
- c) É considerada a possibilidade de estimar SSI com valores acumulados de precipitação e evapotranspiração de referência através de métodos de *machine learning*.

2.3. Objetivos específicos

- a) Avaliar, nas bacias hidrográficas brasileiras, a variação espaço-temporal das variáveis hidrometeorológicas que compõem os índices de seca utilizados;
- b) Caracterizar os eventos de seca meteorológica e hidrológica nos biomas brasileiros;
- c) Levantar através de parâmetros estatísticos o atraso entre os índices de seca
- d) Calibrar e testar modelos de estimativa de SSI através de *machine learning* utilizando os atrasos encontrados entre as secas meteorológicas e hidrológicas nos diferentes biomas.

3. MATERIAL E MÉTODOS

3.1. Contexto regional e coleta de dados

Para o estudo de estimativa de índices de seca, a área de estudo consiste em considerar todo o território brasileiro e seus biomas (Amazônia, Cerrado, Mata Atlântica, Pantanal, Caatinga e Pampa). Para tal pesquisa, os dados utilizados foram obtidos através da base de dados CABra (*Catchments Attributes for Brazil*, Atributos de Bacias Hidrográficas para o Brasil em tradução livre) publicada por Almagro et al. (2021), a qual consiste de dados sobre clima, vazão, águas subterrâneas, geologia, solo, topografia, cobertura do solo e distúrbios hidrológicos de 735 bacias hidrográficas distintas em uma série temporal de 30 anos (1980-2010) (Figura 1). A base de dados foi montada utilizando diversas fontes de dados (estações meteorológicas, sensoriamento remoto e dados geoespaciais). Todos os procedimentos realizados para gerar este banco de dados estão descritos em Almagro et al. (2021) e os dados estão disponíveis abertamente em <https://doi.org/10.5281/zenodo.4070146> e <https://thecabradataset.shinyapps.io/CABra/> (último acesso: 24/09/2024).

Para estimar os índices de seca serão necessários apenas dados de precipitação (P), vazão (Q) e evapotranspiração de referência (ET_o). Ambos dados de precipitação e vazão são valores medidos, porém os valores de evapotranspiração de referência são somente estimados. O próprio CABra disponibiliza os dados de ET_o já calculados para cada bacia utilizando três modelos distintos: FAO-56 Penman-Monteith (ALLEN *et al.*, 1998), Priestley-Taylor (PRIESTLEY; TAYLOR, 1972) e Hargreaves (HARGREAVES, 1975). Por se tratar do método padrão para estimativa de evapotranspiração de referência recomendado pela Organização das Nações Unidas para Agricultura e Alimentação (FAO) (ALLEN *et al.*, 1998), foi utilizado o método FAO-56 Penman-Monteith (Equação 1).

$$ET_o = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{(T_a + 273)} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34u_2)} \text{ (Eq. 1)}$$

onde ETo é a evapotranspiração de referência diária (mm.dia⁻¹), Rn é o saldo de radiação (MJ.m⁻².dia⁻¹), G é o fluxo de calor do solo (MJ.m⁻².dia⁻¹), Ta é a temperatura do ar diária média (°C), u2 é a velocidade do vento a uma altura de 2 m acima do solo (m.s⁻¹), es é a pressão de saturação de vapor, (kPa) ea é a pressão real de vapor (kPa), γ é a constante psicrométrica (kPa.°C⁻¹) e Δ é a inclinação da curva de pressão de vapor (kPa.°C⁻¹).

Além dos dados de P, Q e ETo, também foram coletados dados de temperatura máxima (Tmax), temperatura mínima (Tmin), umidade relativa do ar (UR), velocidade do vento a 2 metros de altura (u2), radiação solar incidente (Rad) e evapotranspiração real (ET). Todos os dados foram coletados por bacia para toda a base de dados.




Figura 1. Mapa de localização das bacias hidrográficas do CABra e biomas brasileiros.

3.2. Índices de seca padronizados

Neste estudo foram utilizados três índices de seca: *Standardized Precipitation Index* (SPI, índice de precipitação padronizado), *Standardized Precipitation Evapotranspiration Index* (SPEI, índice de precipitação-evapotranspiração padronizado) e *Standardized Streamflow Index* (SPI, índice de escoamento padronizado). Tanto o SPI quanto o SPEI são indicadores de seca meteorológica, porém o SSI indica eventos de seca hidrológica. Estes três indicadores dependem da probabilidade e distribuição das variáveis de entrada de cada índice. Estes índices têm sido utilizados por pesquisadores para monitoramento de seca, avaliações de impacto e análises de risco (BAZRAFSHAN; HEJABI; RAHIMI, 2014; DAI *et al.*, 2020; FANG *et al.*, 2020; MADADGAR *et al.*, 2017).

O SPI é um indicador recomendado pela Organização Mundial de Meteorologia (WMO) que depende apenas de dados de precipitação mensal para ser calculado. Foi proposto por McKee, Doesken e Kleist (1993) como uma ferramenta para identificar e estudar os diversos efeitos da escassez de precipitação nas águas subterrâneas, reservatórios superficiais, umidade do solo e vazão de rios. Para ser calculado, transforma-se a precipitação em uma variável padronizada, comumente chamada de escore Z ou apenas Z, para uma distribuição gama dos dados de precipitação mensal (P) em uma determinada escala de tempo, conforme apresentado na Equação 2.

$$SPI_{ij} = \frac{P_{ij} - \bar{P}_j}{\sigma_j} \text{ (Eq. 2)}$$

onde SPI_{ij} é o índice de precipitação padronizado no mês j do ano i, P_{ij} é a precipitação acumulada no mês j do ano i considerando a escala de tempo na acumulação da precipitação, $\bar{P}_j$ é média mensal de precipitação acumulada para o mês j com a precipitação acumulada na escala de tempo determinada, e σ_j é o desvio padrão para o mês j. Os valores de SPI são calculados em diferentes escalas de tempo, geralmente entre 1 e 48 meses. Em escalas curtas, SPI é mais relacionado a alterações na umidade do solo, enquanto em períodos mais longos, as anomalias na precipitação refletem mais os efeitos em águas subterrâneas, vazão e reservatórios superficiais (YERDELEN; ABDELKADER; ERIS, 2021). Para este estudo, as escalas de tempo utilizadas para calcular SPI foram 1, 3, 6, 12 e 24 meses.

O SPEI foi elaborado por Vicente-Serrano, Beguería e López-Moreno (2010) baseado no SPI, utilizando-se do mesmo princípio de distribuição e probabilidade, porém com a utilização de tanto dados de precipitação quanto de evapotranspiração de referência. Este índice padronizado considera o papel da temperatura e outros aspectos meteorológicos que estão intrínsecos ao processo de evapotranspiração na avaliação dos eventos de seca (SHAMSHIRBAND *et al.*, 2020; VICENTE-SERRANO; BEGUERÍA; LÓPEZ-MORENO, 2010). Diversos modelos de evapotranspiração de referência podem ser utilizados para a estimativa dos valores ETo, porém os resultados obtidos com a utilização do método de Penman-Monteith (Equação 1) são os mais adequados devido a abrangência de variáveis meteorológicas que o método considera (SHEFFIELD; WOOD; RODERICK, 2012), portanto este foi o modelo utilizado neste estudo. A variável utilizada para calcular SPEI foi a diferença entre precipitação e evapotranspiração de referência (Equação 3) e o índice foi estimado de forma análoga ao SPI, conforme a Equação 4.

$$D_{ij} = P_{ij} - ET_{oij} \text{ (Eq. 3)}$$

$$SPEI_{ij} = \frac{D_{ij} - \bar{D}_j}{\sigma_j} \text{ (Eq. 4)}$$

onde SPEI_{ij} é o índice de precipitação-evaporação padronizado no mês j do ano i, D_{ij} é a diferença entre precipitação e a evapotranspiração de referência acumuladas no mês j do ano i considerando a escala de tempo na acumulação da diferença, $\bar{D}_j$ é média mensal da diferença entre precipitação e a evapotranspiração de referência acumuladas para o mês j com a diferença acumulada na escala de tempo determinada, e σ_j é o desvio padrão. Semelhante ao SPI, as escalas de tempo utilizadas foram 1, 3, 6, 12 e 24 meses.

Embora apresente uma metodologia semelhante aos índices anteriormente descritos, o SSI incorpora processos hidrológicos na determinação e avaliação de eventos de seca, resumindo os efeitos da seca no comportamento da vazão dos rios, e, desta forma, complementando os outros índices com aspectos hidrológicos da seca (SHUKLA; WOOD, 2008). Para calcular o SSI é utilizado o mesmo procedimento que para estimar SPI, porém ao invés de usar precipitação, foram utilizados dados de vazão total mensal. Portanto, o cálculo de SSI é feito da seguinte maneira:

$$SSI_{ij} = \frac{Q_{ij} - \bar{Q}_j}{\sigma_j} \text{ (Eq. 5)}$$

onde SSI_{ij} é o índice de escoamento padronizado no mês j do ano i , Q_{ij} é a vazão mensal no mês j do ano i considerando a escala de tempo na acumulação da vazão, $\bar{Q}_j$ é a média da vazão mensal para o mês j com a vazão acumulada na escala de tempo determinada, e σ_j é o desvio padrão. Assim como nos demais índices, as escalas de tempo utilizadas no cálculo de SSI foram 1, 3, 6, 12 e 24 meses.

Conforme apresentado por McKee, Doesken e Kleist (1993) e pelo manual de SPI da WMO (WMO, 2012), a Tabela 1 demonstra um sistema de classificação de intensidade de eventos de seca para qualquer escala de tempo para os índices de seca apresentados anteriormente. O evento começa quando o índice se chega à intensidade de -1,0 ou menor e termina apenas quando o valor do índice se torna positivo. Por se tratarem de índices padronizados, os demais índices (SPEI e SSI) também podem utilizar a classificação da Tabela 1 como referência de análise qualitativa dos eventos de seca. Os índices foram calculados para todas as 735 bacias com os dados disponíveis no CABra. Desta forma, será possível caracterizar os eventos de seca de cada bacia e bioma.

Tabela 1. Tabela de classificação dos eventos de seca.

Valor do índice	Classificação
2,00 ou mais	Extremamente úmido
1,50 – 1,99	Muito úmido
1,00 – 1,49	Moderadamente úmido
-0,99 – 0,99	Condições normais
-1,00 – -1,49	Moderadamente seco
-1,50 – -1,99	Severamente seco
-2,00 ou menos	Extremamente seco

Fonte: (MCKEE; DOESKEN; KLEIST, 1993; WMO, 2012)

3.3. Análise de tendência

Para a análise de tendência dos dados obtidos, as variáveis hidrometeorológicas e os índices de seca foram submetidos ao teste de Mann-Kendall (KENDALL, 1975; MANN, 1945). Este teste é um método não-paramétrico utilizado para detectar tendências (crescentes ou decrescentes) estatisticamente significativas em séries temporais para dados independentes (ZHOU *et al.*, 2023).

O teste baseia-se em rejeitar ou não a hipótese nula (H_0), a qual indica que não há tendência. A estatística S (Equação 6) para uma série de n dados do teste de Mann-Kendall é calculada a partir da somatória dos sinais (*sinais*) da diferença, par a par, de todos valores da série (x_i) em relação aos valores que a eles são futuros (x_j) (Equação 7).

$$S = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sinais}(x_j - x_i) \quad (\text{Eq. 6})$$

$$\text{sinais}(x_j - x_i) = \begin{cases} +1; & \text{se } x_j > x_i \\ 0; & \text{se } x_j = x_i \\ -1; & \text{se } x_j < x_i \end{cases} \quad (\text{Eq. 7})$$

Caso $n \geq 10$, é possível comparar S com uma distribuição normal, logo a variância deste valor ($Var(S)$) pode ser calculada através da Equação 8.

$$Var(S) = \frac{n(n-1)(2n-5) - \sum_{m=1}^n t_m(m-1)(2m+5)}{18} \quad (\text{Eq. 8})$$

onde t_m é a quantidade de repetições de uma extensão m , como por exemplo, uma série histórica com quatro valores iguais entre si teria 1 repetição de extensão igual a 4, ou $t_m = 1$ e $m = 4$).

Por fim, é calculado o índice z de acordo com o sinal de S (Equação 9).

$$z = \begin{cases} \frac{S-1}{\sqrt{Var(S)}}; & \text{se } S > 0 \\ 0; & \text{se } S = 0 \\ \frac{S+1}{\sqrt{Var(S)}}; & \text{se } S < 0 \end{cases} \quad (\text{Eq. 9})$$

Por se tratar de um teste bicaudal, para rejeitar a H_0 é preciso que $|z| > z_{\alpha/2}$, onde α é o nível de significância. Para este estudo, o nível de significância considerado foi $\alpha = 5\%$, onde, segundo a tabela de distribuição normal padrão acumulada, $z_{0,05/2} = z_{0,025} = 1,96$, ou seja, séries onde $|z| \leq 1,96$ não possuem tendências significativas.

Para estimar a intensidade da variação em caso de tendência significativa detectada pelo teste de MK, a inclinação da curva de tendência linear é computada usando o método de Theil-Sen (SEN, 1968; THEIL, 1992), conforme a Equação 10.

$$b = \text{Mediana} \left(\frac{X_j - X_l}{j - l} \right) \forall l < j \quad (\text{Eq. 10})$$

onde b é a estimativa da inclinação da tendência, X_j é a j -ésima observação e X_l é a l -ésima observação.

3.4. Análise de correlação cruzada

A análise de correlação cruzada (CC) foi utilizada para verificar o atraso entre os índices de seca entre si, sendo realizadas 3 comparativos distintos, sendo eles: SPIa e SPEIb; SPIa e SSIb; e SPEIa e SSIb; de forma que a e b são as escalas de tempo utilizadas no cálculo dos índices, variando entre 1, 3, 6, 12 e 24. O cálculo da correlação cruzada entre as variáveis se dá conforme a Equação 11.

$$CC = \frac{\sum_{i=1}^n [(X_{i-\tau} - \bar{X})(Y_i - \bar{Y})]}{\sqrt{[\sum_{i=1}^n (X_{i-\tau} - \bar{X})^2][\sum_{i=1}^n (Y_i - \bar{Y})^2]}} \quad (\text{Eq. 11})$$

onde τ é o atraso aplicado no índice a ser atrasado (SPI ou SPEI), variando entre 0 e 24, $X_{i-\tau}$ é resultado do índice no mês equivalente a $i-\tau$, $\bar{X}$ é a média do índice atrasado no período analisado, Y_i é o índice base (SPEI ou SSI) no i -ésimo mês, $\bar{Y}$ é a média do índice base no período analisado, e n é número de meses no período analisado.

3.5. Métodos de *machine learning*

Os resultados obtidos através da análise de correlação cruzada foram utilizados para avaliar através de métodos de *machine learning* (ML) a possibilidade de estimar SSI nas diversas escalas de tempo utilizando como entradas apenas os valores de precipitação (P) e evapotranspiração de referência (ET_o) acumulados. A maioria dos estudos utilizando ML na previsão de eventos de seca utilizaram métodos de treinamento supervisionado (PRODHAN *et al.*, 2022), que consistem utilizar um conjunto de treinamento, que se refere aos dados de entrada e saída utilizados para treinar o algoritmo utilizando, propondo uma solução otimizadas para este conjunto, e um conjunto de teste, no qual o modelo gerado com o conjunto de treinamento é aplicado com novos dados, contidos neste último conjunto, gerando, então, as estimativas de saída para as entradas utilizadas no conjunto de teste. Para todos os métodos, foi utilizado 80% dos dados como conjunto

de treinamento e o restante como conjunto de teste, sendo ambos os conjuntos construídos de forma aleatória. Foram escolhidos 3 métodos supervisionados para estimar o índice de seca hidrológica, sendo eles *support vector machine* (SVM), *gene expression programming* (GEP) e *artificial neural networks*.

- *Support vector machine* (SVM)

O método *Support Vector Machine* foi proposto por Boser, Guyon e Vapnik (1992) baseado na teoria da aprendizagem estatística, e, futuramente, após estudos aprimorando a técnica, foi desenvolvido SVM baseado em regressão por Vapnik (2000). De forma geral, o SVM divide-se em modelo de classificação, ou linear, e de regressão, ou não-linear. Quando se envolve previsão, recomenda-se o método de regressão, ou *support vector regression* (SHAMSHIRBAND *et al.*, 2020). A regressão gera um hiperplano, o que é usado como base, de forma que a distância de um ponto específico até este hiperplano é considerada como o erro da estimativa. Os procedimentos de cálculo do método são descritos em Vapnik (2000) e Basak, Pal e Patranabis (2007).

- *Gene expression programming* (GEP)

O *gene expression programming* (GEP) é um algoritmo genético que utiliza uma população de indivíduos calculados e os escolhe conforme o desempenho, então evolui o cálculo através de alterações genéticas nos operadores utilizados (FERREIRA, 2001). Na primeira etapa, o algoritmo cria uma população de soluções através de um processo acidental, seja utilizando informações inseridas ou não. A seguir, um genoma ou cromossomo, que consiste em uma cadeia destas soluções é alterado para achar novos resultados através de iterações, gerando um novo cromossomo. Caso o resultado do novo cromossomo apresente um melhor desempenho, este é mantido como solução e alterado

para aprimorá-lo. Caso contrário, o genoma anterior é mantido como melhor opção. Este processo de iterações se repete até que a solução seja satisfatória ou chegue a um determinado número de gerações. Os detalhes de processamento do GEP são apresentados minuciosamente por Ferreira (2001). Para este estudo, foi determinado que o número máximo de gerações foi de 20, ou seja, gerados 20 genomas e a solução escolhida foi a que apresentou melhor desempenho dentro destas iterações.

- *Artificial neural networks* (ANN)

Artificial neural networks é um sistema robusto de processamento de informação que possui algumas características que se assemelham às redes neurais biológicas do cérebro humano (ASCE, 2000). ANN é o método de ML mais utilizado para estimativa e previsão de eventos de seca (PRODHAN *et al.*, 2022). De forma geral, estas redes neurais são compostas por uma camada de entrada, uma ou mais camadas ocultas, chamadas de neurônios, onde os processos de otimização ocorrem, e, por fim, a camada de saída, o qual apresenta os resultados. No presente estudo, o número de camadas ocultas foi apenas 1, devido à simplicidade das variáveis de entrada. O número de iterações (épocas) utilizada foi 500. Para mais detalhes de computação, o processamento está descrito por ASCE (2000).

3.6. Avaliação de desempenho dos modelos

Os parâmetros estatísticos utilizados para avaliar as estimativas de SSI obtidas utilizando *machine learning* foram coeficiente de correlação de Pearson (r) (Equação 12), erro quadrático médio (RMSE) (Equação 13), erro absoluto relativo (RAE) (Equação 14) e erro absoluto médio (MAE) (Equação 15), conforme representados a seguir:

$$r = \frac{\sum_{i=1}^n [(P_i - \bar{P})(O_i - \bar{O})]}{\sqrt{[\sum_{i=1}^n (P_i - \bar{P})^2][\sum_{i=1}^n (O_i - \bar{O})^2]}} \quad (\text{Eq. 12})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \text{ (Eq. 13)}$$

$$RAE = \frac{\sum_{i=1}^n |P_i - O_i|}{\sum_{i=1}^n |O_i - \bar{O}|} \text{ (Eq. 14)}$$

$$MAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \text{ (Eq. 15)}$$

onde P_i é o valor estimado de SSI para o i -ésimo mês, O_i é o valor observado de SSI no i -ésimo mês, $\bar{P}$ é a média dos valores preditos, $\bar{O}$ é a média dos valores observados, e n é o número de valores observados. Os valores de r variam entre -1,0 e 1,0, onde valores positivos significam correlação direta e os negativos indicam correlação inversa. Os valores de erro (RMSE, RAE e MAE) são sempre positivos, de forma que os menores valores representam uma maior proximidade entre os valores estimados e observados.

4. RESULTADOS

4.1. Análise de tendências das variáveis micrometeorológicas e vazão

A variação espaço-temporal das variáveis de precipitação (P), temperatura mínima (Tmin), temperatura máxima (Tmax), umidade relativa (UR), velocidade do vento à 2m do solo (u_2), radiação solar incidente (Rad), evapotranspiração real (ET), evapotranspiração potencial (ETo) e vazão (Q) foram avaliadas de forma anual ao longo da série temporal. Os valores de tendência mensal apresentados são apenas aqueles que apresentaram significância de 95% ($p\text{-value} \leq 0,05$). A tendência anual de volume de chuva (Figura 2) foi observada em apenas 14 bacias, sendo o menor valor foi de -15,11 mm/ano, na bacia do Rio Amazonas, localizado na Amazônia, o que totaliza uma queda de em média 453 mm de chuva ao longo da série. Considerando a média de precipitação anual desta bacia de 2340,97 mm, essa tendência de volume chuva representa aproximadamente 0,67% da precipitação média anual. Seis bacias da Amazônia apresentaram tendência negativa de precipitação, sendo o bioma com mais bacias apresentando tendências negativas, seguido do Cerrado com cinco, sendo todas localizadas na bacia do Rio Tocantins, e do Pantanal, que contém apenas uma bacia para o todo bioma. A bacia localizada no Pantanal apresentou a segunda menor tendência da série, com o valor de -8,82 mm/ano, que contabiliza cerca de 0,66% da média de precipitação anual observada na série para a mesma bacia, sendo uma tendência proporcionalmente bem semelhante à bacia de menor decréscimo de chuva detectado. O bioma Amazônia também apresentou as únicas bacias com tendências positivas da série, localizadas na bacia do Rio Amazonas, sendo o aumento de chuva na base de 12,42 (0,59% da média anual) e 13,03 mm/ano (0,61% da média anual) respectivamente.




Figura 2. Tendência de precipitação (P) nas bacias hidrográficas em mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

Foram observadas tendências significativas de temperatura mínima (Figura 3a) em 339 bacias, sendo 10 delas negativas, localizadas em sua maioria no Cerrado (7 bacias). Todavia, o menor valor de tendência foi encontrado para uma bacia localizada na Caatinga, com o valor de $-0,038\text{ }^{\circ}\text{C/ano}$, que representa um decréscimo de $1,16\text{ }^{\circ}\text{C}$ na temperatura mínima média entre o início e fim da série histórica. As demais tendências negativas variaram entre $-0,017$ e $-0,030\text{ }^{\circ}\text{C/ano}$. Dentre as 329 bacias com tendências negativas, os biomas que mais apresentaram bacias com aumento da temperatura mínima significativo foram Mata Atlântica (146 bacias), Cerrado (121 bacias) e Amazônia (50 bacias), além da bacia localizada no Pantanal. As tendências positivas detectadas variaram entre $0,009$ a $0,068\text{ }^{\circ}\text{C/ano}$, sendo que a bacia com maior aumento da temperatura mínima detectada localiza-se na região hidrográfica Atlântico Sudeste, contemplando a bacia do Rio Paraíba do Sul. Tal valor observado foi de $0,068\text{ }^{\circ}\text{C/ano}$, totalizando um aumento médio de $2,03\text{ }^{\circ}\text{C}$ ao longo da série.




Figura 3. Tendências de a) temperatura mínima (Tmin) e b) temperatura máxima (Tmax) nas bacias hidrográficas em °C/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

Para os valores de temperatura máxima, na Figura 3b, apenas em 3 bacias foram detectadas tendências negativas significativas, sendo duas delas na Mata Atlântica e uma na Caatinga, de forma que esta última também apresentou tendência negativa para temperatura mínima. A menor tendência detectada está localizada na bacia do rio Pelotas, no bioma Mata Atlântica, com um decréscimo médio de $-0,046$ °C/ano, totalizando uma queda média de $1,37$ °C da temperatura máxima ao longo da série. Em termos de tendência positiva, foram observados valores significativos em 322 bacias, sendo 129 delas localizadas na Mata Atlântica e 124 no Cerrado. A bacia localizada no Pantanal, assim como na tendência de temperatura mínima, também apresentou uma taxa significativa de aumento de temperatura máxima ao longo da série histórica. A maior tendência encontra-se na mesma bacia com a maior tendência de temperatura negativa, por com um valor ligeiramente mais alto, sendo uma taxa de $0,070$ °C/ano ao longo da série, de forma que resulta em um aumento médio de $2,10$ °C ao longo dos 30 anos

analisados. As demais tendências positivas variaram entre 0,012 a 0,069 °C/ano. Das 322 tendências positivas de temperatura máxima, em 206 delas também foram detectadas tendências significativas de temperatura mínima.

A Figura 4a apresenta a análise da umidade relativa ao longo da série, que apresentou 279 bacias com tendências significativas, sendo 261 negativas e 18 positivas. Dentre as tendências negativas, a maior parte delas (147 bacias) se encontra no Cerrado, porém não foi detectada nenhuma tendência na região do Pampa. O menor valor foi de -0,240 %/ano em uma bacia contendo o Rio das Velhas, o maior afluente em extensão da bacia do Rio São Francisco, localizado na Mata Atlântica, resultando em uma redução de 7,2% em média da umidade relativa desta bacia entre o início e fim da série histórica. As demais variações negativas de umidade relativa estão entre -0,056 e -0,238 %/ano. Já em relação às tendências positivas, a Caatinga e a Mata Atlântica foram os únicos biomas com detecção de aumento de umidade relativa ao longo dos anos, sendo 7 na Mata Atlântica e 11 na Caatinga. Os valores variaram de 0,115 até 0,213 %/ano, sendo o maior deles localizado na Mata Atlântica, na região hidrográfica Atlântico Leste.

Se tratando de tendência significativa de velocidade do vento à 2 m do nível do solo (Figura 4b), foram detectadas 251 bacias com variação de u_2 ao longo da série, sendo 156 negativas e 95 positivas. De forma diferente das variáveis de temperatura e umidade relativa, a velocidade do vento variou negativamente em uma proporção semelhante à distribuição total de bacias por bioma, sem destaque para nenhuma região específica. A menor tendência observada foi de 0,0129 m/s/ano, na bacia do rio Coruripe em Alagoas, localizada na Região Hidrográfica do Atlântico Nordeste Oriental, e tal valor representa cerca de 0,55% da média anual de u_2 na bacia. Os demais decréscimos variaram entre -0,0017 e -0,0128 m/s/ano. Entre as tendências positivas, os valores encontrados apresentaram intensidades ligeiramente superiores às tendências negativas, variando de

0,0026 a 0,0128 m/s/ano. Outro detalhe observado é a concentração de bacias no Cerrado que apresentaram aumento da velocidade do vento, sendo detectadas tendências positivas em 61 bacias somente neste bioma, inclusive os maiores valores, sendo 12 das 15 bacias com maior variação positiva localizadas no Cerrado. O maior aumento de velocidade do vento foi detectado na bacia do rio Parnaíba, afluente do rio Paraná. Todavia, distinto do que foi encontrado para a maior tendência negativa, esse aumento de u_2 nesta bacia representa aproximadamente 1,29% da média anual.




Figura 4. Tendências de a) umidade relativa do ar (UR) e b) velocidade do vento a 2 m de altura do nível do solo (u_2) nas bacias hidrográficas em, respectivamente, %/ano e m/s/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

As variações de radiação incidente ao longo dos anos, apresentadas na Figura 5a, se mostraram díspar em relação ao número de bacias com tendências positivas e negativas. Das 243 bacias com tendências significativas, apenas 10 apresentaram decréscimo de radiação incidente ao longo do tempo, sendo elas localizadas na mesma região hidrográfica e estado, bacias do Atlântico Leste e Bahia, respectivamente, sendo 4

localizadas na Mata Atlântica e 6 na Caatinga. A variação de Rad apresentou valores entre -0,031 e -0,044 MJ/m²/ano. A bacia com variação negativa mais intensa apresentou uma tendência que indica cerca de 0,24% da média anual de radiação incidente na bacia e um decréscimo de aproximadamente 1,33 MJ/m² entre o início e o fim da série. Em relação às tendências positivas, os valores encontrados apresentaram uma amplitude maior do que a variação negativa de Rad, estando entre 0,017 e 0,060 MJ/m²/ano. Assim como nas tendências positivas de u₂, as bacias do Cerrado foram as que mais apresentaram aumento de radiação incidente ao longo do tempo, com tendências detectadas em 135 bacias, de forma que 44 delas estão entre as 50 com maiores taxas de aumento de Rad durante a série histórica. Entretanto, o maior valor foi encontrado em uma bacia de um afluente do rio Amazonas, na Amazônia, representando um aumento total em 1,79 MJ/m² ao longo de 30 anos. A bacia em questão apresentou uma média anual de Rad de 15,67 MJ/m², portanto, tal acréscimo de radiação incidente numa proporção de cerca de 11,4% desta média.

As tendências significativas de evapotranspiração real (Figura 5b) foram detectadas com valores positivos em 60 bacias e negativos em 45. Dentre as tendências positivas, 73% delas são localizadas em bacias da Mata Atlântica, porém as maiores variações ao longo do tempo estão localizadas em 2 bacias na Caatinga, porém em rios de bacias distintas da região hidrográfica do Atlântico Nordeste Ocidental. A maior variação de ET localiza-se na bacia do rio Paraíba, apresentando uma tendência de 7,94 mm/ano, o que representa 1,89% da média de ET acumulada anualmente nesta bacia. A segunda maior tendência está na bacia do rio Apodi, no estado do Rio Grande do Norte, com um valor de 7,39 mm/ano, indicando um aumento de evapotranspiração anual acumulada em torno de 222 mm entre o início e o fim da série histórica. As outras tendências positivas detectadas apresentam valores entre 1,11 e 5,97 mm/ano. As variações negativas de ET

variam de -1,11 a -5,57 mm/ano, sendo a maior parcela das bacias com decréscimo de evapotranspiração localizada na Amazônia. A menor tendência localiza-se em parte da bacia do rio Madeira, um dos principais afluentes do rio Amazonas, de forma que tal decréscimo representa 0,42% da evapotranspiração acumulada na bacia.




Figura 5. Tendências de a) radiação solar incidente (Rad) e b) evapotranspiração real (ET) nas bacias hidrográficas em, respectivamente, MJ/m²/ano e mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

A análise de tendência da evapotranspiração de referência nas bacias (Figura 6) apresentou apenas valores significativos positivos, variando entre 1,40 e 5,96 mm/ano, presente em 250 bacias, a maioria delas (55,6%) em pontos do Cerrado. Dentre as 100 maiores tendências, 65 delas estão presentes no Cerrado. Todavia, o maior aumento de ETo ao longo da série foi detectado na Mata Atlântica, no estado de Mato Grosso do Sul, em uma sub-bacia do rio Ivinhema, afluente do rio Paraná, representando um acréscimo de aproximadamente 0,34% da média da ETo acumulada anualmente na bacia, o que se reflete em um aumento de cerca de 10% da evapotranspiração de referência entre o

primeiro e o último ano da série histórica. Em apenas 5 bacias houve tendência significativa de ETo sem detecção das demais variáveis meteorológicas, sendo 4 delas na Caatinga e 1 na Mata Atlântica.




Figura 6. Tendência de evapotranspiração de referência (ETo) nas bacias hidrográficas em mm/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

Diferente das variáveis meteorológicas, as tendências de vazão dos rios localizados nas bacias analisadas (Figura 7) apresentam uma discrepância muito elevada entre os valores absolutos encontrados, de forma que a tendência de menor intensidade está em escala inferior a $0,002 \text{ m}^3/\text{s}/\text{ano}$, enquanto a de maior intensidade ultrapassa a faixa de $140 \text{ m}^3/\text{s}/\text{ano}$ de variação. Para termos de comparação, dentre as 100 tendências negativas detectadas, 57 variaram entre $-0,0017$ e $-0,9816 \text{ m}^3/\text{s}/\text{ano}$, 33 diminuíram na taxa de $-1,0200$ a $-8,1703 \text{ m}^3/\text{s}/\text{ano}$, e 10 bacias entre $-27,383$ e $-141,357$. Portanto, as tendências

de vazão também estão representadas em porcentagem em função da média obtida durante a série histórica, a fim de representar um valor mais próximo de algo normalizado, visando entender a dinâmica da variação de uma das variáveis hidrológicas nas bacias. É possível observar que as bacias com o maior e o menor valor de tendência respectivamente, embora em valor absoluto apresentem uma variação acima de 100 m³/s/ano, não representam mais do que 1,19% de suas respectivas médias de vazão durante a série histórica.




Figura 7. Tendências de vazão em a) volume e b) porcentagem da vazão média da bacia nas bacias hidrográficas em, respectivamente, m³/s/ano e %/ano entre os anos de 1980 e 2010. O Brasil está dividido por biomas. As tendências negativas estão identificadas com a cor azul e as positivas com a cor vermelha.

Dentre as tendências negativas, a bacia com menor tendência em função da vazão média localiza-se em uma sub-bacia do Rio Paraná, com uma vazão média de 15,54 m³/s e uma tendência de -0,52 m³/s/ano (3,35% da vazão média). A distribuição das tendências negativas de Q se concentra no Cerrado (57 bacias) e na Mata Atlântica (34 bacias). Quanto às tendências positivas, as 2 bacias de maior variação de volume estão localizadas

na Amazônia, sendo ambas localizadas na bacia do rio Negro, um dos principais afluentes do rio Amazonas, e com as variações de 44,93 e 104,21 m³/s/ano, porém tais declínios representam menos do que 0,60% da média da vazão destas bacias, também sendo as 2 variações positivas de menor proporção em relação à vazão das bacias com tendências significativas detectadas. A maior tendência proporcional encontra-se também na Amazônia, porém na região hidrográfica Atlântico Nordeste Ocidental, com um aumento médio de 0,87 m³/s/ano, representando cerca de 4,21% da vazão média observada durante a série.

4.2. Análise quantitativa dos eventos de seca nos biomas brasileiros

A quantidade de eventos identificados com os índices de seca em escala de 1 mês está apresentada na Figura 8, enquanto a análise por bioma está presente na Tabela 2. As bacias apresentaram ao total 24.130 eventos de seca moderada, 10.878 eventos de seca severa e 6.734 eventos de seca extrema considerando SPI1. Nesta escala, o maior número de eventos de secas severas detectados com SPI foi 28, em uma bacia localizada na Mata Atlântica, e o número máximo de eventos extremos foi 20, detectados em 2 bacias da Mata Atlântica também. O número de bacias com secas severas detectadas com SPI1 acima do percentil 90% (P90), que foi de 20 eventos, é de 51 bacias, sendo elas localizadas, em sua maioria na Mata Atlântica (35) e no Cerrado (9), porém a Caatinga e o Pantanal não apresentaram nenhuma bacia com número de secas nesta categoria. Quanto às secas extremas, o P90 foi de 13 eventos, de forma que 66 bacias apresentaram eventos extremos acima desta quantidade. Assim como nas secas severas, os biomas com maior número de bacias foi a Mata Atlântica (42 bacias) e o Cerrado (14), completando a classificação com 10 bacias na Amazônia. A Caatinga, o Cerrado e o Pantanal não apresentaram bacias com eventos de seca extrema acima do percentil 90%. Considerando

a média de eventos por bacia em cada bioma, o bioma com maior média de eventos de seca severa usando SPI1 foi o Pampa, seguido da Amazônia. Já para a distribuição de seca extremas por cada bioma utilizando SPI1, o Cerrado apresentou a maior média de eventos por bacia. Tanto em eventos de seca severa quanto extrema, a Caatinga apresentou uma média abaixo dos outros biomas quando comparados entre si.




Figura 8. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 1 mês. O Brasil está dividido por biomas.

Para a seca meteorológica considerando também a evapotranspiração potencial (SPEI), os resultados obtidos na escala de 1 mês indicaram um total de 22.269 eventos

moderados, 11.184 eventos severos e 7.817 eventos extremos. Para SPEI1, o maior número de eventos severos foi detectado em 2 bacias do bioma amazônico, sendo 25 secas severas em cada. Já o maior número de secas extremas foi 17, observado em 4 bacias, sendo todas localizadas na Mata Atlântica, em sub-bacias do rio Paraná. O P90 para eventos de seca severa foi num total de 20, totalizando 50 bacias com número de secas severas detectadas acima deste valor. Tal distribuição se dá com 30% delas na Amazônia, 50% na Mata Atlântica, 14% no Cerrado e 3% no Pampa. A Caatinga e o Pantanal não apresentaram bacias com número de eventos severos acima de 20. Para o número de eventos extremos, o percentil 90% foi igual a 13, que totaliza 53 bacias com secas extremas detectadas acima do P90. Nesta distribuição acima do percentil 90%, apenas o Pampa não apresentou bacias que se encaixem na categoria, sendo o bioma com mais bacias acima de 13 eventos de seca extrema detectados a Mata Atlântica, com 20 bacias. Em relação à média de eventos por bacia em cada bioma utilizando SPEI1, o maior número médio de eventos está presente na Amazônia. Para eventos extremos, a maior média por bacia se localiza no Pantanal, que conta apenas com 1 bacia, seguido da Amazônia. Quando comparado com SPI1, percebe-se que há um aumento de quase 100% entre a quantidade de secas extremas detectadas na Caatinga, porém nos demais biomas se notam valores próximos entre os índices.

Se tratando de seca hidrológica, o total de eventos de seca utilizando SSI1 resultou em 23.663 secas moderadas, 7.340 secas severas e 2.425 secas extremas. Em relação aos eventos extremos, nota-se, de forma geral, uma diminuição em relação ao que foi detectado com SPI1 e SPEI1, indicando que na escala de 1 mês a seca hidrológica ocorreu em frequência abaixo da metade do que a seca meteorológica. Os resultados apresentaram 2 bacias que não apresentaram nenhum evento de seca hidrológica durante a série, ambas localizadas na Caatinga. A bacia com maior número de secas severas detectadas com

Tabela 2. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 1 mês e a média de eventos por bacia hidrográfica por bioma.

SPI1						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.478	31,77	1.235	15,83	739	9,47
Mata Atlântica	12.410	33,45	5.720	15,42	3.355	9,04
Caatinga	1.617	32,34	578	11,56	278	5,56
Cerrado	7.073	32,30	3.066	14,00	2.206	10,07
Pampa	511	31,94	265	16,56	146	9,13
Pantanal	41	41,00	14	14,00	10	10,00

SPEI1						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.427	31,12	1.272	16,31	896	11,49
Mata Atlântica	11.141	30,03	5.828	15,71	3.963	10,68
Caatinga	1.366	27,32	626	12,52	533	10,66
Cerrado	6.798	31,04	3.183	14,53	2.252	10,28
Pampa	508	31,75	260	16,25	159	9,94
Pantanal	29	29,00	15	15,00	14	14,00

SSI1						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.465	31,60	1.106	14,18	667	8,55
Mata Atlântica	12.200	32,88	3.536	9,53	838	2,26
Caatinga	951	19,02	320	6,40	126	2,52
Cerrado	7.571	34,57	2.187	9,99	742	3,39
Pampa	449	28,06	174	10,88	51	3,19
Pantanal	27	27,00	17	17,00	1	1,00

SPI1 localiza-se no Cerrado, na bacia do rio Paraná, apresentando 35 secas hidrológicas severas ao longo da série histórica. O P90 dos valores de SPI1 dentro da faixa de seca severa é de 16, o que totaliza 62 bacias com eventos acima desse valor. Nesta distribuição. A maioria se localiza na Amazônia (24 bacias), seguido de 17 tanto no Cerrado quanto na Mata Atlântica, 2 na Caatinga e 1 em cada bioma restante. No que se refere à eventos extremos, o percentil 90% é 8, o que caracteriza 50 bacias com contagem de secas extremas acima deste valor, porém há de se destacar que 70% delas se localizam na Amazônia, inclusive a com maior número de eventos (28 secas extremas). Tal efeito da seca hidrológica na escala de 1 mês na Amazônia pode ser observado quando se compara a média de eventos extremos por bacia nos biomas, que apresentam uma considerável diferença entre o bioma amazônico e os demais. Também se nota a baixa média de

eventos de seca hidrológica de forma geral na Caatinga, apresentando, proporcionalmente, um número que chega a representar menos do que 1/3 de outros biomas em secas severas e extremas.

Abaixo segue o total de eventos de seca na escala 3 (Figura 9) e o quantitativo por biomas (Tabela 3). Na escala de 3 meses, o número de eventos detectados com SPI foi de 25.344 secas moderadas, 11.880 secas severas e 4.797 secas extremas. É possível observar uma menor contagem de eventos extremos quando comparado com SPI1. O maior número de eventos de seca severa foi de 26, observado em 5 bacias, sendo 3 delas localizadas no Cerrado, 1 na Mata Atlântica e a outra na Amazônia. O P90 para o número de eventos severos utilizando SPI3 é 21, portanto o número de bacias com contagem de secas severas acima deste valor é de 54, sendo metade delas localizadas somente no Cerrado, 15 na Mata Atlântica, 8 na Caatinga e 4 na Amazônia. Quanto às secas extremas, a bacia com maior número de eventos (18), encontra-se na Amazônia. O percentil 90% para o número de eventos extremos detectados com SPI3 é 10, o que leva a um número de 49 bacias com a contagem de secas extremas acima deste valor. Destas 49 bacias, a distribuição é parelha entre a Amazônia (19 bacias), Mata Atlântica (16 bacias) e Cerrado (14 bacias). A distribuição de eventos por bacia em cada bioma indica médias e comportamentos semelhantes aos valores encontrados com SPI1, porém, para a Caatinga, a média por bacia de secas severas aumentou, apresentando o segundo maior valor dentre os biomas, e o número de eventos extremos diminuiu em cerca de 35%.

Para os valores SPEI3, o total de eventos detectados foi de 22.866 eventos moderados, 12.129 eventos severos e 7.895 eventos extremos. A bacia com maior número de evento severos localiza-se na Amazônia, apresentando 30 eventos. As bacias com número de secas severas superior ao percentil 90% (23 eventos) se distribuem da seguinte forma: 16 bacias na Amazônia, 15 bacias no Cerrado, 14 bacias na Mata Atlântica e




Figura 9. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 3 meses. O Brasil está dividido por biomas.

Caatinga (3). Em relação às secas extremas, 4 bacias apresentaram o maior número de eventos (16), sendo 2 delas localizadas na Amazônia, uma no Cerrado e outra na Mata atlântica. O P90 de eventos extremos foi de 13, resultando em 71 bacias com número de secas extremas detectadas acima deste. Tais bacias se concentrando na Mata Atlântica, com 48% delas, e Cerrado (27%). Diferente do que foi apresentado na escala de 1 mês, o Pantanal apresentou apenas 6 eventos de secas extremas durante a série histórica utilizando SPEI3. As demais médias de eventos por bacia observados com SPEI3 nos outros biomas apresentou valores semelhantes ao mesmo índice na escala de 1 mês.

No que se refere à seca hidrológica na escala de 3 meses, a totalidade de eventos se resume em 24.145 secas moderadas, 8.172 secas severas e 3.005 secas extremas, apresentando um leve aumento em relação a contagem de eventos utilizando SS1, porém ainda abaixo quando comparado com os índices de seca meteorológica. Apenas 1 bacia não apresentou eventos de seca hidrológica durante a série histórica, localizada na Mata Atlântica, na bacia do rio Barigui, contido na região hidrográfica do rio Paraná, divergindo do que foi observado na escala de 1 mês. O maior número de eventos severos em uma bacia foi 31, observado no Ribeirão do Lobo, uma sub-bacia do rio Tietê, um dos principais afluentes do rio Paraná, no Cerrado. 56 bacias apresentaram a contagem de secas severas acima do percentil 90% (18 eventos), distribuído, em sua grande maioria, entre 20 bacias na Mata Atlântica e 15 bacias tanto na Amazônia quanto no Cerrado. Já em relação aos eventos extremos, a Amazônia abrange a bacia com o maior número de secas extremas (28 eventos), assim como a maioria das bacias com maior contagem de tais eventos acima do P90 (9 eventos), em que a distribuição foi a seguinte: 38 bacias na Amazônia, 17 no Cerrado e 15 na Mata Atlântica. De forma análoga à escala de 1 mês, a quantidade de eventos extremos detectados com SSI3 distribuídos por bioma indica a Amazônia como a região com mais secas hidrológicas extremas, proporcionalmente,

quando comparados com os outros biomas. Ademais, nota-se também um aumento em torno de 73% do número de eventos extremos no Pampa em relação à escala de 1 mês e a ausência de tais eventos na bacia do rio Paraguai, no Pantanal.

Tabela 3. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 3 meses e a média de eventos por bacia hidrográfica por bioma.

SPI3						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.705	34,68	1.289	16,53	706	9,05
Mata Atlântica	12.665	34,14	5.787	15,60	2.260	6,09
Caatinga	1.769	35,38	811	16,22	182	3,64
Cerrado	7.614	34,77	3.749	17,12	1.528	6,98
Pampa	552	34,50	229	14,31	113	7,06
Pantanal	39	39,00	15	15,00	8	8,00

SPEI3						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.586	33,15	1.488	19,08	841	10,78
Mata Atlântica	11.077	29,86	5.820	15,69	4.050	10,92
Caatinga	1.506	30,12	828	16,56	547	10,94
Cerrado	7.163	32,71	3.744	17,10	2.262	10,33
Pampa	496	31,00	227	14,19	189	11,81
Pantanal	38	38,00	22	22,00	6	6,00

SSI3						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.404	30,82	1.141	14,63	728	9,33
Mata Atlântica	12.565	33,87	4.147	11,18	1.207	3,25
Caatinga	1.003	20,06	355	7,10	130	2,60
Cerrado	7.593	34,67	2.328	10,63	852	3,89
Pampa	556	34,75	183	11,44	88	5,50
Pantanal	24	24,00	18	18,00	0	0,00

O somatório de eventos de seca na escala de 6 meses nas bacias analisadas estão presentes na Figura 10, assim como os eventos por bioma estão na Tabela 4. Os eventos de seca detectados utilizando SPI6 totalizaram 25.185 secas moderadas, 11.237 secas severas e 4.393 secas extremas. De forma semelhante a SPI3, quando comparado com SPI1, o número de secas extremas observados com SPI6 apresenta uma redução de mais de 2000 eventos. 8 bacias não apresentaram eventos de seca extrema utilizando SPI, sendo elas localizadas em sua maioria na Mata Atlântica (6 bacias) e 2 localizadas no Pampa. A

bacia com maior número de secas severas apresentou 28 eventos, sendo localizada em uma sub-bacia do rio Amazonas, na Amazônia. O percentil 90% para o número de eventos severos é de 21, o que sucede em 53 bacias com quantidade de secas severas acima deste valor, de forma que a Mata Atlântica possui 17 bacias e o Cerrado 16 dentro desta classificação. Se tratando de eventos extremos, a bacia com maior número de secas extremas ao longo da série histórica se encontra na Amazônia, com 23 eventos. A quantidade de bacias com eventos extremos acima do P90 (10) é de 51, sendo a maioria delas localizada na Amazônia (47%) e na Mata Atlântica (39%). Na média de eventos detectados com SPI6 por bacia, nota-se uma diminuição de eventos extremos no Pampa de mais de 50% quando comparado com SPI3 e cerca de 1/3 da totalidade de secas extremas observadas através de SPI1.

Quanto à SPEI6, o número de secas observadas foi de 21.632 eventos moderados, 11.195 eventos severos e 8.209 eventos extremos. O maior número de eventos severos em uma bacia foi 30, localizado na Amazônia. O P90 do número de eventos severos é 21, o que resulta em 62 bacias com secas acima deste valor. Tal classificação está distribuída entre os biomas da seguinte forma: 27 bacias na Mata Atlântica, 18 bacias na Amazônia, 13 no Cerrado, 2 na Caatinga e 2 no Pampa. No que se refere a secas extremas, a bacia com maior quantidade de eventos extremos localiza-se na Caatinga, em uma sub-bacia do rio Paraguaçu, na região hidrográfica Atlântico Leste. O percentil 90% da contagem de seca extrema foi de 14 eventos. 38 bacias apresentaram quantidade de eventos extremos acima deste valor, apresentando uma distribuição parelha entre os biomas, sendo 37% na Mata Atlântica, 24% no Cerrado, 21% na Amazônia e 18% na Caatinga. A média de eventos severos por bacia indicou valores próximos ao encontrados com SPEI3, porém, se tratando de secas extremas, a Caatinga apresentou o maior valor detectado com SPEI6 dentre os biomas.




Figura 10. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 6 meses. O Brasil está dividido por biomas.

Os eventos de seca hidrológica na escala de 6 meses somam 23.723 secas moderadas, 8.784 secas severas e 3.149 secas extremas. De forma idêntica ao que foi

encontrado na escala de 3 meses, apenas a bacia do rio Barigui não apresentou eventos de seca durante a série histórica. O maior número de eventos de seca severa em uma bacia é de 30, observado em uma sub-bacia do rio Amazonas. O percentil 90% do número de eventos hidrológicos severos foi de 19, o que resultou em 71 bacias com secas severas detectadas acima desse valor, sendo 35 delas na Mata Atlântica, 22 no Cerrado, 13 na Amazônia e 1 no Pampa. Para secas extremas, o maior número de eventos detectados foi 28, localizado na mesma bacia que apresentou o maior número de secas severas para SSI3, indicando um aumento da intensidade da seca hidrológica nessa bacia com o aumento da escala de tempo. O P90 para o número de eventos extremos observados foi de 10. Assim como para eventos severos, o número de bacias com secas extremas acima do P90 foi 71, porém com uma distribuição diferente proporcionalmente, com a maioria destas bacias localizadas na Amazônia (50,7%), seguido da Mata Atlântica (26,8%) e Cerrado (19,7%), com o resto localizado no Pampa. Quando comparados os eventos por bioma, a Caatinga apresentou redução de eventos severos e extremos em relação à SSI3, assim como no Cerrado nas secas extremas, porém de forma mais sutil do que na Caatinga. Nota-se um aumento gradual do número de secas hidrológicas extremas entre as escalas de 1, 3 e 6 meses na Amazônia, Mata Atlântica e Pampa. O Pantanal manteve-se sem eventos extremos.

Na escala de 12 meses (Figura 11 e Tabela 5), o total de secas meteorológicas detectadas com SPI foi de 26.395 eventos moderados, 10.329 eventos severos e 3.334 eventos extremos. Nota-se um aumento do número de eventos moderados e uma diminuição dos eventos extremos com a progressão de escala de SPI. O número de bacias sem detecção de eventos extremos aumento em 10 vezes quando comparado com os resultados obtidos com SPI6, sendo a maioria delas, cerca de 73%, localizada na Mata Atlântica. O maior número de eventos severos em uma bacia foi de 31, localizado em

Tabela 4. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 6 meses e a média de eventos por bacia hidrográfica por bioma.

SPI6						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.627	33,68	1.323	16,96	731	9,37
Mata Atlântica	12.428	33,50	5.376	14,49	2.101	5,66
Caatinga	1.652	33,04	816	16,32	240	4,80
Cerrado	7.848	35,84	3.492	15,95	1.265	5,78
Pampa	594	37,13	214	13,38	48	3,00
Pantanal	36	36,00	16	16,00	8	8,00

SPEI6						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.503	32,09	1.445	18,53	834	10,69
Mata Atlântica	10.158	27,38	5.360	14,45	4.099	11,05
Caatinga	1.427	28,54	753	15,06	614	12,28
Cerrado	7.084	32,35	3.375	15,41	2.483	11,34
Pampa	426	26,63	243	15,19	169	10,56
Pantanal	34	34,00	19	19,00	10	10,00

SSI6						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.271	29,12	1.174	15,05	800	10,26
Mata Atlântica	12.279	33,10	4.530	12,21	1.313	3,54
Caatinga	1.055	21,10	345	6,90	98	1,96
Cerrado	7.559	34,52	2.523	11,52	834	3,81
Pampa	535	33,44	195	12,19	104	6,50
Pantanal	24	24,00	17	17,00	0	0,00

uma sub-bacia do rio Amazonas, na Amazônia. O P90 dos eventos severos é de 21, o que leva a 50 bacias com quantidade de secas severas acima desse valor. A distribuição destas bacias se dá da seguinte forma: 18 na Mata Atlântica, 15 no Cerrado, 12 na Amazônia, 4 na Caatinga e a bacia localizada no Pantanal. Para os eventos extremos, foi observado que a maior quantidade durante a série histórica está localizada em uma bacia na região hidrográfica Atlântico Nordeste Oriental, na Mata Atlântica. O percentil 90% para a contagem de secas extremas utilizando SPI12 foi de 10 eventos e a quantidade de bacias com tais eventos detectados acima do P90 foi 71, com uma distribuição semelhante ao que foi encontrado com SPI6, sendo a maioria delas localizadas na Amazônia (48%) e as demais distribuídas entre Cerrado (21%), Mata Atlântica (20%) e Caatinga (11%). No total de eventos por bioma, é possível observar uma redução de quase 40% de eventos

extremos na Mata Atlântica, além de uma redução de cerca de 22% no número de secas no Cerrado quando comparado com os resultados obtidos com SPI6.

Para a seca meteorológica considerando SPEI, a quantidade de eventos de seca observada durante a série histórica na escala de 12 meses foram as seguintes: 21.274 secas moderadas, 10.313 secas severas e 8.222 secas extremas. A bacia com maior número de eventos severos (35) se localiza em uma sub-bacia do rio Amazonas, no Cerrado. O percentil 90% do número de secas severas com SPEI12 foi 21, o que resulta em 63 bacias acima deste valor. Estas bacias se localizam de forma distribuída no Cerrado (23 bacias), na Mata Atlântica (21 bacias), na Amazônia (17 bacias), além de 1 na Caatinga e 1 no Pampa. Para os eventos extremos, a bacia do rio Uma, localizado na região hidrográfica Atlântico Nordeste Oriental, na Mata Atlântica, apresentou o maior número de secas durante o período de análise, no total de 24. O P90 do número de eventos extremos é 14, o que leva a 50 bacias acima deste valor. Dentre estas bacias, a maioria delas se localiza na Mata Atlântica (42%) e o resto na Amazônia, Cerrado e Caatinga. Quanto ao número de eventos por bioma, é possível observar uma diminuição dos eventos severos em todos os biomas quando comparado com o que foi observado na escala de 6 meses, exceto no Pantanal, que apresentou um aumento secas severas na mesma quantidade que diminuiu o total de secas extremas neste bioma.

O total de eventos detectados com SSI12 foi de 23.104 secas moderadas, 8.926 secas severas e 3.227 secas extremas. Assim como nas escalas de 3 e 6 meses, a bacia do rio Barigui não apresentou nenhum evento de seca hidrológica na série histórica, porém outras 6 bacias, todas na Caatinga, também não apresentaram eventos detectados. A bacia com maior número de eventos de seca severa (36 eventos) localiza-se em uma sub-bacia do rio Paranaíba, um dos principais afluentes do rio Paraná, no bioma Cerrado. O P90 da contagem de secas hidrológicas severas foi de 21. Foram observadas 68 bacias com




Figura 11. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 12 meses. O Brasil está dividido por biomas.

eventos severos acima deste valor, de forma que a maioria se encontra na Mata Atlântica (31 bacias), seguido do Cerrado (29 bacias) e o resto na Amazônia. A mesma sub-bacia

com maior quantidade de eventos extremos de seca hidrológica na escala de 6 meses também apresentou a maior contagem de secas extremas detectadas com SSI12, porém com 29 eventos observados. O percentil 90% para os eventos extremos foi de 12, o que resultou em 71 bacias acima desse valor, com uma distribuição equilibrada entre Amazônia (40,8%) e 29,6% delas tanto para Mata Atlântica quanto para o Cerrado. No total de eventos por bioma, a quantidade de secas hidrológicas no Pantanal aumentou no geral, porém diminuiu a quantidade de secas severas. A média de eventos extremos por bacia aumentou levemente na Amazônia e no Cerrado.

Tabela 5. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 12 meses e a média de eventos por bacia hidrográfica por bioma.

SPI12						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.626	33,67	1.248	16,00	730	9,36
Mata Atlântica	13.656	36,81	4.972	13,40	1.270	3,42
Caatinga	1.648	32,96	735	14,70	283	5,66
Cerrado	7.847	35,83	3.158	14,42	991	4,53
Pampa	584	36,50	193	12,06	56	3,50
Pantanal	34	34,00	23	23,00	4	4,00

SPEI12						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.443	31,32	1.345	17,24	864	11,08
Mata Atlântica	10.331	27,85	4.986	13,44	4.150	11,19
Caatinga	1.541	30,82	666	13,32	603	12,06
Cerrado	6.476	29,57	3.073	14,03	2.416	11,03
Pampa	454	28,38	221	13,81	183	11,44
Pantanal	29	29,00	22	22,00	6	6,00

SSI12						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.192	28,10	1.091	13,99	875	11,22
Mata Atlântica	11.826	31,88	4.597	12,39	1.292	3,48
Caatinga	1.074	21,48	330	6,60	63	1,26
Cerrado	7.396	33,77	2.703	12,34	900	4,11
Pampa	570	35,63	197	12,31	97	6,06
Pantanal	46	46,00	8	8,00	0	0,00

Por fim, a Figura 12 apresenta o total de eventos nas bacias hidrográficas e a Tabela 6 apresenta os resultados obtidos por biomas para os índices de seca na escala de 24

meses. O total da contagem de secas detectadas com SPI24 foi de 27.696 eventos moderados, 9.882 eventos severos e 2.078 eventos extremos. Nota-se um aumento de secas moderadas e uma diminuição dos demais eventos de seca quando comparado com os resultados observados na escala de 12 meses. O número de bacias sem eventos extremos é de 346, cerca de 47% do total de bacias, e em uma delas, localizada na bacia do rio São Francisco, no Cerrado, também não foram detectados eventos de seca severa. A bacia de maior número de eventos severo (37) localiza-se no Cerrado, na região hidrográfica do São Francisco. O P90 de total de secas severas é de 22 eventos. As bacias com quantidade de eventos severos acima deste valor é de 69, distribuído entre todos os biomas, exceto o Pantanal, de forma que 24 se encontram na Mata Atlântica, 19 no Cerrado, 14 na Amazônia, 9 na Caatinga e 3 no Pampa. Para as secas extremas, uma sub-bacia localizada na região hidrográfica Tocantins-Araguaia apresentou o valor máximo de eventos encontrados com SPI24, resultando em 29. O percentil 90% foi de 9 eventos, sucedendo em 69 bacias nas quais, assim como nos eventos severos, foram distribuídas nos mesmos 5 biomas, porém o Cerrado (27 bacias) e a Amazônia (25 bacias) foram as regiões que apresentaram a maior quantidade de bacias. A média total de eventos extremos por bacia nos biomas diminuiu em relação às secas detectadas com SPI12, principalmente na Mata Atlântica, com uma redução maior do que 50%, porém no Pampa houve um aumento em torno de 14% nestes eventos.

Em relação aos eventos de seca observados com SPEI na escala de 24 meses, o somatório foi o seguinte: 20.711 secas moderadas, 11.396 secas severas e 7.950 secas extremas. Nesta escala, apenas uma bacia localizada na região hidrográfica Atlântico Leste, na Caatinga, não apresentou eventos de seca extrema durante a série histórica. Duas bacias apresentaram o maior número de secas severas utilizando SPEI24 (38 eventos), sendo uma localizada na Mata Atlântica e outra no Cerrado. O P90 do número de eventos




Figura 12. Número de eventos de seca detectados com os índices SPI, SPEI e SSI na escala de 24 meses. O Brasil está dividido por biomas.

severos é 24, o que levou a 69 bacias com quantidade de secas acima desse valor. Dentre estas bacias, 32 localizam-se na Mata Atlântica, 16 no Cerrado, 12 na Amazônia, 6 na

Caatinga e 3 no Pampa. Quanto aos eventos extremos, a quantidade de secas em uma única bacia foi 20, localizada na Caatinga, em uma sub-bacia do rio Parnaíba. O percentil 90% para secas extremas é de 14 eventos. 65 bacias apresentaram o número de eventos extremos acima do P90, de forma que estão distribuídas entre Mata Atlântica (49,2%), Cerrado (32,3%), Amazônia (15,4%) e Caatinga (3,1%). Considerando a distribuição dos eventos de seca observados com SPEI24 por bioma, nota-se um aumento de mais de 10% entre o total de secas severas entre os resultados obtidos entre SPEI12 e SPEI24. Além disso, é possível notar um aumento no número de eventos extremos no Cerrado, enquanto nos outros biomas há um decréscimo entre as escalas de 12 e 24 meses.

Para os eventos de seca hidrológica com o acumulado de 24 meses, o total de eventos foi de 23.555 secas moderadas, 8.050 secas severas e 2.675 secas extremas. Não foram detectados eventos de secas em 5 bacias nesta escala, sendo elas localizadas na Caatinga (3 bacias) e Mata Atlântica (2 bacias). Uma sub-bacia do rio Tietê, localizada na Mata Atlântica apresentou 41 eventos severos durante a série histórica, o maior número detectado para secas desta intensidade. O percentil 90% para os eventos severos foi de 22, o que resultou em 63 bacias com quantidade de secas severas detectadas acima deste valor. Estas bacias se encontram em sua maioria na Mata Atlântica (29 bacias), sendo o restante localizado no Cerrado (20 bacias), Amazônia (11 bacias) e Pampa (3). Em relação às secas extremas, diferentemente das escalas de 6 e 12 meses, a bacia com maior número de eventos detectados com SSI24 se localiza na Mata Atlântica, na região hidrográfica Atlântico Sul, com 35 eventos. O P90 para secas extremas observadas com SSI24 foi de 12 eventos. O número de bacias com eventos extremos detectados acima do percentil 90% foi 67, distribuído da seguinte forma: 22 bacias na Amazônia, 20 na Mata Atlântica, 20 no Cerrado e 5 na Caatinga. Na média de eventos por bioma, o Pantanal manteve-se sem eventos extremos e apenas com 1 evento severo detectado. A Caatinga apresentou

aumento na quantidade de secas extremas detectadas quando comparada com os resultados de SSI12, com um acréscimo em 100 eventos. Assim como nas demais escalas de tempo, a média de eventos extremos por bacia na Amazônia foi a maior dentre os biomas.

Tabela 6. Total de eventos de seca detectados em cada bioma com SPI, SPEI e SSI na escala de 24 meses e a média de eventos por bacia hidrográfica por bioma.

SPI24						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.504	32,10	1.245	15,96	553	7,09
Mata Atlântica	14.823	39,95	4.702	12,67	538	1,45
Caatinga	1.733	34,66	868	17,36	181	3,62
Cerrado	8.040	36,71	2.780	12,69	739	3,37
Pampa	554	34,63	265	16,56	65	4,06
Pantanal	42	42,00	22	22,00	2	2,00

SPEI24						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.273	29,14	1.351	17,32	826	10,59
Mata Atlântica	10.621	28,63	5.888	15,87	3.972	10,71
Caatinga	1.632	32,64	792	15,84	477	9,54
Cerrado	5.680	25,94	3.019	13,79	2.535	11,58
Pampa	463	28,94	323	20,19	137	8,56
Pantanal	42	42,00	23	23,00	3	3,00

SSI24						
Bioma	Seca moderada		Seca severa		Seca extrema	
	Total	Média por bacia	Total	Média por bacia	Total	Média por bacia
Amazônia	2.316	29,69	1.179	15,12	660	8,46
Mata Atlântica	12.085	32,57	4.136	11,15	932	2,51
Caatinga	1.319	26,38	276	5,52	163	3,26
Cerrado	7.128	32,55	2.237	10,21	867	3,96
Pampa	642	40,13	221	13,81	53	3,31
Pantanal	65	65,00	1	1,00	0	0,00

4.3. Análise de tendência de SPI, SPEI e SSI

A análise de tendência de SPI na escala de 1 mês (Figura 13) apresentou 146 bacias com tendências negativas e 13 bacias com tendências positivas. A maior parte das bacias com tendências negativas localizam-se no Cerrado (51%). A bacia com menor tendência, com diminuição anual de SPI1 em cerca de 0,0024, é localizada no Cerrado, seguido da bacia do rio Paraguai, localizada no Pantanal. Para SPEI1, o número de bacias com

tendências negativas é mais do que o dobro (323 bacias no total) do que quando comparado com as tendências de SPI1, porém o número de bacias com aumento de SPEI foi apenas 4, porém com valores abaixo de 0,0016 ao ano. Cerca de 88% das bacias do Cerrado apresentaram diminuição significativa de SPEI na escala de 1 mês ao longo da série histórica. Dentre as 5 bacias com menores tendências (abaixo de -0,0030), 3 localizam-se no Cerrado, 1 na Amazônia e a bacia localizada no Pantanal. Para SSI1, 382 bacias apresentaram declínios significativos e 65 bacias com aumento do índice ao longo do tempo, das quais 35 localizam-se na Amazônia. Dentre as tendências negativas do índice de seca hidrológica na escala de 1 mês, 13 das 15 bacias com valores mais baixos, inclusive a de menor tendência (-0,0069/ano), localizam-se na bacia do São Francisco, no Cerrado.




Figura 13. Tendência dos índices SPI, SPEI e SSI na escala de 1 mês. O Brasil está dividido por biomas.

Na escala de 3 meses, com os resultados apresentados na Figura 14, o número de bacias com tendências negativas de SPI é de 364, um aumento de quase 150% em relação

à SPI1, porém o número de bacias com tendências positivas dobrou. A bacia com menor tendência de SPI3 é a do rio Paraguai, no Pantanal, com o valor de -0,0039/ano. Dentre as bacias com tendência positiva, a Amazônia apresentou 54% delas, porém a de maior aumento localiza-se na Caatinga, no valor de 0,0028/ano, na bacia do rio Paraíba, na região hidrográfica Atlântico Nordeste Oriental. Para as tendências de SPEI3, 471 bacias apresentaram tendências significativas, sendo 453 delas negativas, cerca de 62% das bacias do banco de dados. A tendência negativa mais intensa de SPEI3 localiza-se no Pantanal com um declínio ao longo do tempo no valor de -0,0047. O número de bacias com tendência positiva também aumentou para SPEI3 em função da escala de 1 mês, com 18 bacias nesta condição, distribuídas igualmente na Amazônia, Caatinga e Mata Atlântica. Para SSI3, 400 bacias apresentaram tendências negativas e 81 positivas. Assim como nos resultados obtidos com SSI1, a bacia do São Francisco apresentou as tendências negativas de maior intensidade para SSI3, sendo 73% das 30 menores tendências localizadas em sub-bacias nesta região hidrográfica, incluindo a de menor valor (-0,0073/ano), localizada na bacia do Rio Formoso. Quanto às tendências positivas, o maior aumento de SSI3, no valor de 0,0073/ano, localiza-se em uma sub-bacia do rio Mearim, na região hidrográfica Atlântico Nordeste Ocidental, na Amazônia.

A Figura 15 apresenta os resultados da análise de tendências para os índices de seca na escala de 6 meses. A quantidade de bacias com tendências negativas de SPI6 é 354, sendo a bacia com diminuição mais intensa, assim como para SPI3, localizada no Pantanal, com a tendência de -0,0047/ano. Foram detectadas 34 bacias com tendências positivas de SPI na escala de 6 meses, sendo elas distribuídas da seguinte forma: 15 na Amazônia, 12 na Mata Atlântica e 7 na Caatinga. A maior tendência de SPI6 foi de 0,0030/ano, na mesma bacia com maior tendência de SPI3. Se tratando de SPEI na escala de 6 meses, a menor tendência, da mesma forma que SPEI3, localiza-se na bacia do rio




Figura 14. Tendência dos índices SPI, SPEI e SSI na escala de 3 meses. O Brasil está dividido por biomas.

Paraguai, no Pantanal, que apresentou uma variação $-0,0056/\text{ano}$. Outras 442 bacias também apresentaram tendências negativas, sendo 207 delas localizadas no Cerrado. 31 bacias apresentaram tendências positivas significativas, com 5 bacias na Caatinga, 12 na Mata Atlântica e 14 na Amazônia, onde está a maior tendência ($0,0029/\text{ano}$). As tendências significativas para seca hidrológica na escala de 6 meses foram detectadas de forma negativa em 402 bacias e 101 bacias com aumento de SSI. Assim como para SSI1 e SSI3, a bacia do São Francisco apresentou as sub-bacias com as reduções mais acentuadas de SSI6 durante a série histórica, com a de menor valor sendo $-0,0077/\text{ano}$. A maior tendência de SSI na escala de 6 meses localiza-se na mesma bacia que a de incremento mais intenso de SSI3, porém com um valor ligeiramente abaixo ($0,0070/\text{ano}$).

A Figura 15 apresenta os resultados da análise de tendências para os índices de seca na escala de 6 meses. A quantidade de bacias com tendências negativas de SPI6 é 354, sendo a bacia com diminuição mais intensa, assim como para SPI3, localizada no Pantanal, com a tendência de $-0,0047/\text{ano}$. Foram detectadas 34 bacias com tendências

positivas de SPI na escala de 6 meses, sendo elas distribuídas da seguinte forma: 15 na Amazônia, 12 na Mata Atlântica e 7 na Caatinga. A maior tendência de SPI6 foi de 0,0030/ano, na mesma bacia com maior tendência de SPI3. Se tratando de SPEI na escala de 6 meses, a menor tendência, da mesma forma que SPEI3, localiza-se na bacia do rio Paraguai, no Pantanal, que apresentou uma variação -0,0056/ano. Outras 442 bacias também apresentaram tendências negativas, sendo 207 delas localizadas no Cerrado. 31 bacias apresentaram tendências positivas significativas, com 5 bacias na Caatinga, 12 na Mata Atlântica e 14 na Amazônia, onde está a maior tendência (0,0029/ano). As tendências significativas para seca hidrológica na escala de 6 meses foram detectadas de forma negativa em 402 bacias e 101 bacias com aumento de SSI. Assim como para SSI1 e SSI3, a bacia do São Francisco apresentou as sub-bacias com as reduções mais acentuadas de SSI6 durante a série histórica, com a de menor valor sendo -0,0077/ano. A maior tendência de SSI na escala de 6 meses localiza-se na mesma bacia que a de incremento mais intenso de SSI3, porém com um valor ligeiramente abaixo (0,0070/ano).




Figura 15. Tendência dos índices SPI, SPEI e SSI na escala de 6 meses. O Brasil está dividido por biomas.

No que se refere à escala de 12 meses (Figura 16), o número de bacias com tendências significativas para SPI aumentou quando comparado com a escala de 6 meses, apresentando um total de 375 bacias com tendências negativas e 56 positivas. Dentre as bacias com diminuição de SPI, a bacia do rio Paraguai também apresenta a menor tendência (-0,0057/ano). Os demais biomas apresentam a seguinte distribuição: 162 na Mata Atlântica, 157 no Cerrado, 39 na Amazônia, 10 na Caatinga e 6 no Pampa. Cerca de 72% das bacias localizadas no Cerrado apresentam tendências negativas de SPI₁₂. Para as tendências positivas, a maioria se localiza na Mata Atlântica (48%) e na Amazônia (30%), bioma em que localizam as 3 maiores tendências, entre 0,0034 e 0,0037/ano. Para SPEI na escala de 12 meses, 464 bacias apresentaram diminuição do índice ao longo da série histórica e 39 apresentaram aumento. Dentre as bacias de tendência negativa, a maioria localiza-se na Mata Atlântica (211 bacias), seguida do Cerrado (189 bacias). A tendência negativa de maior intensidade é na mesma bacia que para SPEI₆, localizada no Pantanal, porém com uma diminuição mais acentuada, no valor de -0,0066/ano. As bacias com tendência positiva localizam-se em apenas 3 biomas, sendo eles a Mata Atlântica, com 17 bacias, a Amazônia, com 15 bacias e onde está presente o maior valor (0,0037), e a Caatinga, com 7 bacias. Em relação ao índice de seca hidrológica na escala de 12 meses, 402 bacias apresentaram tendências de diminuição e 111 bacias com aumento de SSI ao longo do tempo. Assim como nas demais escalas de SSI, as tendências negativas de maior intensidade se localizam em sub-bacias do rio São Francisco, sendo que 19 das 20 menores tendências, entre -0,0066 a -0,0083/ano, se localizam nesta região hidrográfica, e a que, dentre estas, não se localiza nesta região é a bacia do rio Tietê, localizado na Mata Atlântica, na bacia do rio Paraná. Quanto às tendências positivas, todos os biomas, exceto o Pantanal, apresentam bacias com aumento de SSI₁₂ ao longo

do tempo, de forma que a maior tendência, no valor de 0,0069/ano, se localiza também na bacia do rio Mearim, na Amazônia.




Figura 16. Tendência dos índices SPI, SPEI e SSI na escala de 12 meses. O Brasil está dividido por biomas.

Abaixo, a Figura 17 apresenta as tendências para SPI24, SPEI24 e SSI24. Para SPI na escala de 24 meses, o número de bacias com tendência negativa significativas aumentou em cerca de 25% em relação aos resultados de SPI12, apresentando um total de 470 bacias com diminuição de SPI24, todavia, o número de bacias com tendência de aumento do índice foi superior proporcionalmente, tendo um acréscimo de 32% no total quando comparada à escala de 12 meses, totalizando 74 bacias. Proporcionalmente, em relação ao total de bacias por bioma, a Caatinga foi a região a apresentar o menor número de bacias com tendências negativas de SPI24, presente em apenas 26% de suas bacias. Nos demais biomas, a detecção de tendências negativas passou de 50% das bacias em cada um deles. A bacia com decréscimo de SPI24 mais intenso, assim como em outras escalas de tempo, é a do rio Paraguai, no Pantanal, apresentando a tendência de




Figura 17. Tendência dos índices SPI, SPEI e SSI na escala de 24 meses. O Brasil está dividido por biomas.

-0,0074/ano. Já as tendências positivas de SPI na escala de 24 meses se concentram na Mata Atlântica (28 bacias) e Amazônia (24 bacias), bioma no qual se localiza a bacia de maior tendência (0,0053/ano), na região hidrográfica do rio Amazonas. No que se refere à SPEI24, 533 bacias apresentaram tendências negativas, o que representa quase 3/4 do total de bacias do banco de dados e também um aumento de aproximadamente 15% do número de bacias com tendências negativas em relação à escala de 12 meses do mesmo índice. A bacia localizada no Pantanal apresentou a tendência mais intensa dentre os resultados de SPEI, com uma tendência detectada de -0,0082/ano. Já em relação às tendências de aumento, houve pouca variação quando comparado a SPEI12, resultando em 41 bacias com tendências positivas detectadas, de forma que a distribuição delas é: 17 na Mata Atlântica, 16 na Amazônia e 8 na Caatinga. A maior tendência de aumento foi encontrada na mesma bacia que para SPEI, na Amazônia, no valor de 0,0052/ano. Quanto à seca hidrológica na escala de 24 meses, o número de bacias com tendências significativas totalizou 581, sendo 470 negativas e 111 positivas. Assim como para SSI12,

as menores tendências se localizam na bacia do rio São Francisco, porém ao invés de 19 entre as 20 bacias de declínio mais intenso, são 18 na escala de 24 meses. Estas 20 tendências negativas mais acentuadas variam entre -0,0078 e -0,0090. A bacia do rio Tietê apresenta também nesta escala tendência de SSI entre as 20 menores, porém a bacia localizada no Pantanal aparece dentre elas nesta escala. A bacia de menor tendência é a do rio Formoso, que em todas as escalas de SSI esteve entre as 2 menores tendências durante a série histórica. Para as tendências positivas de SSI24, a maior tendência manteve-se na mesma bacia que para a escala de 12 meses, no rio Mearim, na Amazônia.

4.4. Análise de correlação cruzada entre os índices de seca

A fim de avaliar a propagação da seca e possibilidade de previsão de eventos de seca hidrológica, foram escolhidas 3 bacias com base nos resultados obtidos através da análise de tendência dos índices de seca. As bacias escolhidas foram a bacia do rio Madeira, localizada na Amazônia, região hidrográfica do rio Amazonas (código ANA: 15700000), a bacia do rio Formoso, localizada no Cerrado, na região hidrográfica do São Francisco (código ANA: 45880000), e a bacia do rio Paraguai, sendo a única bacia localizada no Pantanal dentro da base de dados utilizada (ANA: 67100000). Tal escolha foi feita baseada na observação de constância destas bacias entre as menores tendências detectadas para todas as escalas de tempo, de forma que a bacia do rio Paraguai apresentou decréscimos intensos nos 3 índices, a bacia da Amazônia apresentou decréscimo intenso de SPI e SPEI e a bacia localizada na região do rio São Francisco indicou um declínio agudo do índice de seca hidrológica. A Tabela 7 apresenta um resumo dos resultados obtidos pela análise de tendência nas 3 bacias.

Tabela 7. Tendências, em ano⁻¹, para SPI, SPEI e SSI para as bacias hidrográficas selecionadas para avaliar propagação e previsão dos eventos de seca.

Índice	Escala (meses)	Bacia		
		Rio Madeira (Amazônia)	Rio Formoso (Cerrado)	Rio Paraguai (Pantanal)
SPI	1	-0,0020	Sem tendência	-0,0024
	3	-0,0035	-0,0014	-0,0039
	6	-0,0041	-0,0017	-0,0047
	12	-0,0048	-0,0024	-0,0057
	24	-0,0058	-0,0039	-0,0074
SPEI	1	-0,0025	-0,0019	-0,0030
	3	-0,0041	-0,0029	-0,0047
	6	-0,0048	-0,0029	-0,0056
	12	-0,0059	-0,0040	-0,0066
	24	-0,0068	-0,0057	-0,0082
SSI	1	-0,0033	-0,0069	-0,0050
	3	-0,0036	-0,0073	-0,0052
	6	-0,0037	-0,0076	-0,0057
	12	-0,0039	-0,0083	-0,0066
	24	-0,0056	-0,0090	-0,0081

A Tabela 8 apresenta o maior coeficiente de correlação encontrado na análise correlação cruzada entre os índices para a bacia do rio Madeira, na Amazônia. Nota-se que há uma correlação próxima de 1,0 quando comparados SPI e SPEI de mesma escala de tempo e sem atraso entre eles, indicando que, mesmo utilizando uma variável a mais para estimar SPEI, é possível verificar comportamentos semelhantes entre os índices de mesma escala no mesmo período de análise. Todavia, se tratando da comparação entre SPI e SSI, observa-se que a maior correlação entre os índices em diferentes escalas de tempo foi com ambos no acumulado de 24 meses, apresentando um coeficiente de correlação de 0,687 para o atraso de 5 meses entre os índices. Tal comportamento entre as variáveis indicam comportamentos discrepantes entre elas, de forma que a reação de SSI não aparenta ter tanta influência apenas da variação da chuva. Para a análise entre SPEI e SSI na bacia, os resultados apresentaram maiores coeficientes de correlação quando comparados com as correlações entre SPI e o índice de seca hidrológica. O coeficiente de correlação entre SPEI24 e SSI24 foi o maior encontrado nas comparações com SSI, apontando um valor de 0,721 para o um atraso de 4 meses entre as variáveis. É

possível observar também as semelhanças entre as comparações SPIxSSI e SPEIxSSI se tratando do atraso com maior coeficiente para cada escala de tempo, apresentando atraso idênticos na maioria deles, exceto para SSI6, 12 e 24 com os índices de seca meteorológica na escala de 24 meses.

Tabela 8. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI, SPEIxSSI em todas as escalas para a bacia do rio Madeira, na Amazônia. Os valores acima de 0,700 foram destacados em negrito.

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SPEI1	0,988 (0)	0,674 (0)	0,480 (0)	0,333 (0)	0,307 (0)
SPEI3	0,655 (2)	0,986 (0)	0,765 (0)	0,528 (0)	0,479 (0)
SPEI6	0,535 (3)	0,794 (2)	0,987 (0)	0,733 (0)	0,614 (0)
SPEI12	0,379 (6)	0,571 (4)	0,753 (3)	0,985 (0)	0,800 (0)
SPEI24	0,281 (0)	0,425 (0)	0,539 (0)	0,754 (12)	0,941 (0)

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SSI1	0,383 (1)	0,546 (1)	0,512 (1)	0,440 (0)	0,461 (1)
SSI3	0,383 (3)	0,549 (3)	0,595 (2)	0,483 (1)	0,499 (1)
SSI6	0,365 (6)	0,531 (5)	0,610 (3)	0,555 (1)	0,546 (2)
SSI12	0,282 (10)	0,432 (9)	0,559 (7)	0,635 (4)	0,626 (5)
SSI24	0,210 (8)	0,320 (7)	0,394 (5)	0,518 (12)	0,687 (5)

Índice	SPEI1	SPEI3	SPEI6	SPEI12	SPEI24
SSI1	0,414 (1)	0,574 (1)	0,601 (1)	0,486 (0)	0,445 (1)
SSI3	0,419 (3)	0,572 (3)	0,631 (2)	0,535 (1)	0,478 (1)
SSI6	0,387 (6)	0,582 (5)	0,658 (3)	0,608 (1)	0,532 (1)
SSI12	0,311 (10)	0,474 (9)	0,616 (7)	0,701 (4)	0,626 (4)
SSI24	0,230 (8)	0,349 (7)	0,442 (5)	0,587 (12)	0,721 (4)

Quanto à análise de correlação cruzada dentre os índices de seca na bacia do rio Formoso, na bacia do São Francisco, no Cerrado (Tabela 9), a principal diferença quando comparado aos resultados da bacia da Amazônia é a falta de correlação de SPI1 e SPI3 com SPEI nas diferentes escalas de tempo. Enquanto a correlação de SPI nas escalas de 6, 12 e 24 se assemelha ao que foi encontrado para a bacia do rio Madeira, a baixa correlação das escalas de tempo menores indica um impacto diferente quando considerada a evapotranspiração de referência na estimativa de eventos de seca nas escalas de 1, principalmente, e 3 meses para bacias com características semelhantes. Quando comparado SPI com o índice de seca hidrológica, notam-se baixas correlações

Tabela 9. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI, SPEIxSSI em todas as escalas para a bacia do rio Formoso, no Cerrado. Os valores acima de 0,700 foram destacados em negrito.

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SPEI1	0,462 (0)	0,275 (0)	0,164 (0)	0,136 (0)	0,078 (0)
SPEI3	0,329 (0)	0,469 (0)	0,300 (0)	0,251 (0)	0,185 (0)
SPEI6	0,400 (5)	0,644 (3)	0,959 (0)	0,634 (0)	0,436 (0)
SPEI12	0,264 (1)	0,436 (8)	0,618 (6)	0,962 (0)	0,657 (0)
SPEI24	0,194 (11)	0,303 (11)	0,366 (11)	0,611 (12)	0,963 (0)

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SSI1	0,409 (0)	0,478 (0)	0,483 (0)	0,567 (0)	0,608 (0)
SSI3	0,307 (2)	0,461 (1)	0,501 (0)	0,595 (0)	0,658 (0)
SSI6	0,268 (5)	0,380 (3)	0,501 (1)	0,597 (0)	0,670 (0)
SSI12	0,169 (11)	0,280 (9)	0,386 (6)	0,553 (1)	0,670 (1)
SSI24	0,113 (12)	0,155 (12)	0,193 (12)	0,377 (12)	0,618 (11)

Índice	SPEI1	SPEI3	SPEI6	SPEI12	SPEI24
SSI1	0,262 (0)	0,346 (0)	0,560 (0)	0,665 (0)	0,689 (0)
SSI3	0,195 (2)	0,332 (1)	0,586 (0)	0,697 (0)	0,748 (0)
SSI6	0,169 (5)	0,290 (4)	0,586 (1)	0,701 (0)	0,769 (0)
SSI12	0,131 (11)	0,246 (10)	0,486 (6)	0,669 (1)	0,784 (0)
SSI24	0,093 (12)	0,206 (12)	0,310 (12)	0,527 (12)	0,750 (5)

entre eles em todas as escalas de tempo, da mesma forma que para a bacia da Amazônia. A comparação de SPI24 com todas as escalas de SSI apresentaram correlações acima de 0,6, sendo a escala de SPI que apresentou as maiores correlações em relação à SSI. A maior correlação considerando SPIxSSI foi 0,670, porém para 2 comparações distintas, sendo elas SPI24xSSI6, sem atraso, e SPI24xSSI12, com atraso de 1 mês. Comparando SPEI e SSI, as correlações com SPEI12 e SPEI24 apresentaram valores acima do que as comparações SPIxSSI, notando-se, assim como na bacia da Amazônia, uma influência maior das demais variáveis meteorológicas no comportamento da seca hidrológica. As maiores correlações quando comparando SPEI e SSI foram detectadas com o índice de seca meteorológica na escala de 24 meses, sendo a relação com SSI12 a de valor mais intenso, porém apenas na comparação SPEI24xSSI24 a maior correlação apresentou atraso, sendo este de 5 meses.

Tabela 10. Coeficientes de correlação cruzada, com o atraso correspondente em parênteses entre os índices de seca, apresentando as comparações SPIxSPEI, SPIxSSI, SPEIxSSI em todas as escalas para a bacia do rio Paraguai, no Pantanal. Os valores acima de 0,700 foram destacados em negrito.

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SPEI1	0,959 (0)	0,631 (0)	0,497 (0)	0,368 (0)	0,360 (0)
SPEI3	0,624 (1)	0,980 (0)	0,763 (0)	0,563 (0)	0,557 (0)
SPEI6	0,468 (4)	0,751 (3)	0,984 (0)	0,767 (0)	0,699 (0)
SPEI12	0,363 (7)	0,571 (5)	0,738 (2)	0,948 (0)	0,817 (0)
SPEI24	0,317 (2)	0,499 (0)	0,642 (0)	0,817 (12)	0,986 (0)

Índice	SPI1	SPI3	SPI6	SPI12	SPI24
SSI1	0,311 (3)	0,513 (3)	0,688 (1)	0,759 (0)	0,628 (0)
SSI3	0,333 (5)	0,538 (4)	0,722 (3)	0,795 (1)	0,665 (1)
SSI6	0,337 (6)	0,536 (6)	0,714 (5)	0,815 (3)	0,699 (2)
SSI12	0,306 (11)	0,491 (10)	0,664 (9)	0,809 (6)	0,759 (3)
SSI24	0,229 (10)	0,378 (9)	0,522 (10)	0,736 (12)	0,870 (6)

Índice	SPEI1	SPEI3	SPEI6	SPEI12	SPEI24
SSI1	0,345 (3)	0,543 (3)	0,707 (1)	0,733 (0)	0,630 (0)
SSI3	0,367 (4)	0,574 (3)	0,736 (3)	0,767 (1)	0,667 (1)
SSI6	0,374 (6)	0,576 (5)	0,737 (5)	0,786 (3)	0,704 (2)
SSI12	0,349 (11)	0,542 (9)	0,701 (9)	0,790 (6)	0,772 (2)
SSI24	0,279 (10)	0,435 (9)	0,580 (8)	0,742 (12)	0,890 (5)

As correlações cruzadas entre os índices de seca na bacia do Pantanal (Tabela 10) apresentaram, especialmente nas comparações com SSI, valores acima dos que foram encontrados nas outras bacias analisadas, demonstrando um efeito maior da seca meteorológica na seca hidrológica. Valores próximos a 1,0 foram encontrados nas comparações SPIxSPEI em todas as escalas de tempo, com os maiores valores sem atraso entre as variáveis, refletindo, assim como na bacia do rio Madeira, comportamentos semelhantes entre SPI e SPEI. Quando comparado SPI e SSI na bacia do rio Paraguai, nota-se os maiores valores de correlação para SPI6, SPI12 e SPI24, principalmente na escala de 12 meses da seca meteorológica, que apresentou correlação acima 0,73 com todas as escalas de SSI. Todavia, a maior correlação entre estes índices é com ambos na escala de 24 meses, que apresentou o valor de 0,870 para um atraso de 6 meses entre SPI e SSI. Para SPEI e SSI, a análise de correlação cruzada apresentou resultados semelhantes à comparação SPIxSSI, inclusive quando comparado ambos índices de seca

meteorológica na escala de 12 meses com SSI, de forma que as maiores correlações foram encontradas para o mesmo atraso em cada escala de tempo do índice de seca hidrológica. A bacia localizada no Pantanal também apresentou a maior correlação entre um índice de seca meteorológica com SSI dentre as 3 bacias analisadas, na comparação SPEI24 com SSI24, apresentando 0,890 para um atraso de 5 meses.

4.5. Estimativas de SSI utilizando métodos de *machine learning*

- Rio Madeira (Amazônia)

Conforme o resultado obtido pela análise de correlação cruzada entre os índices de seca na bacia do rio Madeira, notou-se que os índices de seca meteorológica na escala de 24 meses apresentaram maior correlação com SSI nas diferentes escalas de tempo, portanto decidiu-se utilizar a escala de 24 meses para o acumulado de chuva e evapotranspiração de referência usados como entrada para gerar os modelos utilizando *machine learning*. A Figura 18 apresenta o comparativo entre os índices de seca meteorológica na escala de 24 meses e os índices hidrológicos, tanto sem atraso quanto com o atraso ideal conforme a Tabela 8 considerando a maior correlação com SPEI24.

É possível observar que para a escala de 1 mês (Figura 19) os modelos não apresentaram estimativas de SSI que indicassem valores que se aproximassem dos índices observados. Embora o atraso ideal seja de apenas 1 mês entre as variáveis P e ETo e o índice de seca hidrológica, os parâmetros estatísticos (Tabela 11) indicaram resultados mais favoráveis para os modelos calculados sem atraso. Dentre os métodos de *machine learning* utilizados, o SVM sem atraso foi o que apresentou os melhores resultados de forma geral, apresentando os menores valores de erro e maior correlação.




Figura 18. Comparativo entre SPI24 e SPEI24 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEI $\times$ SSI da Tabela 8 para a bacia do rio Madeira, na Amazônia.




Figura 19. Estimativas de SSI1 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 11. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia.

Sem atraso			
	SVM	GEP	ANN
r	0,578	0,526	0,522
RMSE	0,758	0,796	0,795
RAE	0,811	0,873	0,870
MAE	0,604	0,650	0,648

Com atraso (1 mês)			
	SVM	GEP	ANN
r	0,444	0,376	0,859
RMSE	0,798	0,901	0,918
RAE	0,875	0,901	0,918
MAE	0,608	0,626	0,638

Para a escala de 3 meses (Figura 20 e Tabela 12), os resultados obtidos foram semelhantes ao de 1 mês para a bacia do rio Madeira, inclusive considerando a comparação dos modelos com ou sem atraso ideal. Os modelos não apresentaram resultados similares ao SSI3 observado. O modelo de melhores resultados, assim como para 1 mês, foi o SVM sem atraso, porém com valores menos favoráveis em relação à erros e r.

Tabela 12. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia.

Sem atraso			
	SVM	GEP	ANN
r	0,564	0,499	0,464
RMSE	0,783	0,835	0,852
RAE	0,865	0,934	0,952
MAE	0,635	0,685	0,698

Com atraso (1 mês)			
	SVM	GEP	ANN
r	0,555	0,485	0,425
RMSE	0,796	0,833	0,895
RAE	0,861	0,904	0,937
MAE	0,646	0,678	0,703




Figura 20. Estimativas de SSI3 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.

Assim como nas escalas de 1 e 3 meses, as estimativas de SSI6 utilizando *machine learning* (Figura 21) não apresentaram valores condizentes com os índices observados. O modelo que apresentou os melhores parâmetros estatísticos, expostos na Tabela 13, foi o SVM, assim como nas escalas de tempo menores, porém com o atraso de 1 mês entre as variáveis de entrada e SSI. Todavia, quando comparado com os resultados de escala 1 e 3 meses, os resultados dos modelos para SSI6 apresentaram performances estatísticas piores, mesmo a comparação SPEI24xSSI6 apresentando resultados de correlação cruzada ligeiramente acima do que as comparações de SPEI24 com SSI1 e SSI3.

Os resultados de estimativa de SSI12 com chuva e ETo acumulados em 24 meses (Figura 22) apresentaram parâmetros estatísticos (Tabela 14) com melhor performance do que quando comparado com os valores estimados de SSI em escalas menores, porém é possível observar que os erros calculados ainda indiquem que os valores estimados não se aproximam tanto dos observados. Embora o atraso de maior correlação na comparação SPEI24xSSI12 seja de 4 meses, o modelo utilizando *machine learning* com maior




Figura 21. Estimativas de SSI6 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 13. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia.

	Sem atraso		
	SVM	GEP	ANN
r	0,516	0,476	0,443
RMSE	0,886	0,979	0,994
RAE	0,948	0,979	1,062
MAE	0,716	0,739	0,802

	Com atraso (1 mês)		
	SVM	GEP	ANN
r	0,554	0,521	0,451
RMSE	0,855	0,873	0,895
RAE	0,920	0,948	0,948
MAE	0,715	0,737	0,737

correlação foi o SVM sem atraso. Entretanto, o modelo com os menores erros encontrados é o SVM com o atraso de 4 meses.




Figura 22. Estimativas de SSI12 a) sem atraso e b) com atraso de 4 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 14. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia.

	Sem atraso		
	SVM	GEP	ANN
r	0,633	0,565	0,553
RMSE	0,755	0,789	0,817
RAE	0,831	0,867	0,916
MAE	0,618	0,645	0,681
	Com atraso (4 meses)		
	SVM	GEP	ANN
r	0,618	0,577	0,552
RMSE	0,733	0,754	0,811
RAE	0,822	0,845	0,919
MAE	0,614	0,632	0,687

Os resultados obtidos para o SSI na escala de 24 meses, apresentados na Figura 23, foram os melhores apresentados para os dados da bacia do rio Madeira. A diferença entre as estimativas utilizando um atraso de 4 meses entre as variáveis de entrada e SSI24 e sem levar em consideração uma diferença de tempo é mais notável do que nas outras escalas de tempo. O modelo de melhor resultado (Tabela 15), de forma geral para estimar

SSI na bacia, foi o SVM com atraso de 4 meses, que apresentou tanto o maior coeficiente de correlação quanto os menores erros quando comparados os valores estimados e observados do índice.




Figura 23. Estimativas de SSI24 a) sem atraso e b) com atraso de 4 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Madeira, na Amazônia, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 15. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Madeira, na Amazônia.

Sem atraso			
	SVM	GEP	ANN
r	0,722	0,636	0,631
RMSE	0,633	0,729	0,722
RAE	0,767	0,895	0,896
MAE	0,511	0,596	0,596
Com atraso (4 meses)			
	SVM	GEP	ANN
r	0,759	0,692	0,669
RMSE	0,605	0,698	0,834
RAE	0,708	0,850	0,994
MAE	0,477	0,572	0,669

- Rio Formoso (Cerrado)

Para a bacia do rio Formoso, na região hidrográfica do São Francisco, no bioma Cerrado, os resultados obtidos com os valores de correlação cruzada indicaram maiores correlações de SSI em diversas escalas com os índices de seca meteorológica na escala de 24 meses. Portanto, assim como foi utilizado para treinar e validar os modelos da bacia do rio Madeira, utilizou-se como entradas P e ETo acumulados por um período de 2 anos. A figura abaixo (Figura 24) apresenta a distribuição de SPI e SPEI na escala de 24 meses e de SSI em todas as escalas de tempo analisadas, tanto com quanto sem o atraso de maior correlação encontrado com SPEI24 (Tabela 9). Por haver apenas uma escala de tempo do índice de seca hidrológica que apresentou o maior coeficiente de correlação com atraso, todos os índices SSI, exceto para 24 meses, foram testados sem atraso.




Figura 24. Comparativo entre SPI24 e SPEI24 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEI $\times$ SSI da Tabela 9 para a bacia do rio Formoso, no Cerrado.

Para SSI1 (Figura 25), nota-se graficamente a diferença entre os resultados obtidos na bacia do rio Madeira (Figura 19) e a bacia do Cerrado. Os parâmetros estatísticos encontrados, apresentados na Tabela 16, indicam que o método *gene expression programming* apresentou o maior coeficiente de correlação, porém os menores erros foram detectados com o método *support vector machine*. Os coeficientes de correlação em todos os modelos estão mais próximos de 0,5 do que 1,0, porém é possível observar os valores residuais mais próximos da linha 1:1 para esta bacia do que para a bacia da Amazônia na mesma escala de SSI.




Figura 25. Estimativas de SSI1 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 16. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.

	SVM	GEP	ANN
r	0,640	0,650	0,529
RMSE	0,643	0,636	0,728
RAE	0,491	0,773	0,879
MAE	0,491	0,506	0,567

Os modelos gerados utilizando SSI3 (Figura 26) apresentaram parâmetros estatísticos indicando melhor desempenho do que os resultados encontrados para SSI1 na bacia do rio Formoso. Os modelos treinados com SVM e GEP apresentaram os melhores resultados (Tabela 17) para esta escala de tempo, sendo que as estimativas geradas com

support vector machine apresentaram menores erros e maior correlação nas estimativas de SSI3 quando comparadas com os valores observados. É possível notar uma dispersão maior dos valores estimados no modelo gerado por ANN do que nos demais.




Figura 26. Estimativas de SSI3 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 17. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.

	SVM	GEP	ANN
r	0,744	0,713	0,644
RMSE	0,555	0,582	0,649
RAE	0,649	0,700	0,756
MAE	0,439	0,474	0,516

Para a escala de 6 meses, apresentados na Figura 27 e Tabela 18, os resultados obtidos por SVM superaram a performance do mesmo método na estimativa de SSI3, de forma que os erros foram menores e o coeficiente de correlação apresentou valor superior, mais próximo de 1,0 do que 0,5 nesta escala. É possível notar que o modelo treinado com GEP apresentou estimativas de SSI6 negativo próximas dos valores observados, porém, houve uma subestimativa dos índices mais elevados. Já o modelo gerado com *artificial neural networks* não apresentou resultados de mesmo desempenho que os demais modelos na bacia do Cerrado, assim como nas escalas de tempo menores.




Figura 27. Estimativas de SSI6 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 18. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.

	SVM	GEP	ANN
r	0,780	0,738	0,692
RMSE	0,525	0,594	0,637
RAE	0,616	0,726	0,700
MAE	0,417	0,491	0,518

Considerando a escala do índice de seca hidrológica com 12 meses (Figura 28 e Tabela 19), os parâmetros estatísticos calculados indicaram um melhor desempenho do uso de SVM para estimar SSI. Observa-se graficamente que a comparação de valores observados e estimados com SVM apresentou uma menor dispersão do que nos resultados dos outros modelos, especialmente quando comparado com o que foi gerado com ANN. Levando em conta a correlação entre SPEI24 e SSI12 (Tabela 9), tais resultados corroboram com o impacto da precipitação e evapotranspiração de referência na seca hidrológica, especialmente para os valores mais baixos de SSI, visto que a dispersão aumenta conforme o acréscimo dos valores.




Figura 28. Estimativas de SSI12 sem atraso utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 19. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.

	SVM	GEP	ANN
r	0,843	0,760	0,693
RMSE	0,461	0,559	0,651
RAE	0,537	0,638	0,654
MAE	0,378	0,449	0,505

Para as estimativas de SSI24, expressos na Figura 29 e na Tabela 20, um dos resultados obtidos apresentaram os melhores parâmetros estatísticos obtidos usando os dados da bacia do rio Formoso e também dentre todos os modelos testados nas bacias destacadas. Tal resultado foi obtido utilizando *support vector machine* para estimar SSI, porém sem o atraso de maior correlação cruzada. Embora a análise de correlação cruzada (Tabela 9Tabela 19) tenha indicado que a maior correlação na comparação SPEI24xSSI24 tenha um atraso de 5 meses, a correlação sem atraso apresentou um valor próximo (0,732). Os resultados obtidos com SVM, especialmente sem atraso, apresentaram erros bem baixos, quando comparados com os demais modelos e até mesmo com os resultados em escalas de tempo menores. A correlação do modelo treinado com SVM sem atraso foi superior a 0,9, indicando um impacto considerável das variáveis de entrada nos eventos de seca na escala de 2 anos.




Figura 29. Estimativas de SSI24 a) sem atraso e b) com atraso de 5 meses utilizando acumulado de 24 meses de P e ETo como entradas para a bacia do rio Formoso, no Cerrado, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 20. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Formoso, no Cerrado.

	Sem atraso		
	SVM	GEP	ANN
r	0,906	0,747	0,632
RMSE	0,436	0,662	0,758
RAE	0,385	0,569	0,639
MAE	0,336	0,498	0,559

	Com atraso (5 meses)		
	SVM	GEP	ANN
r	0,875	0,715	0,607
RMSE	0,481	0,661	0,809
RAE	0,473	0,648	0,834
MAE	0,384	0,527	0,678

- Rio Paraguai (Pantanal)

Diferente do que foi encontrado nas outras 2 bacias, a bacia do rio Paraguai, localizada no Pantanal, apresentou os melhores resultados de correlação cruzada (Tabela 10) com os índices de seca na escala de 12 meses ao invés de 24, portanto, foi utilizado como entrada os valores de precipitação e evapotranspiração de referência acumulados

por um período de 12 meses. Exceto para SSI1, as demais escalas de tempo de SSI indicaram maior correlação com atrasos. A Figura 30 apresenta a distribuição dos índices ao longo do tempo, tanto com quanto sem o atraso de maior coeficiente de correlação.




Figura 30. Comparativo entre SPI12 e SPEI12 com SSI em diversas escalas a) sem atraso e b) com atraso conforme a comparação SPEIxSSI da Tabela 10 para a bacia do rio Paraguai, no Pantanal.

Na escala de 1 mês (Figura 31), já é possível observar maior correlação entre os valores estimados e observados quando comparado com os valores calculados de SSI1 nas outras bacias analisadas. O modelo de melhor resultado (Tabela 21), tanto com maior coeficiente de correlação quanto menores erros, foi treinado utilizando *gene expression programming*, porém os demais modelos apresentaram resultados próximos. É possível notar que os valores acima de zero tendem a ser subestimados, porém já se observa o impacto de P e ETo na detecção de secas hidrológicas na escala mensal no Pantanal.




Figura 31. Estimativas de SSI1 sem atraso utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 21. Parâmetros estatísticos entre as estimativas de SSI1 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.

	SVM	GEP	ANN
r	0,774	0,801	0,778
RMSE	0,621	0,595	0,632
RAE	0,610	0,600	0,628
MAE	0,483	0,475	0,497

Para estimativas de SSI3 (Figura 32 e Tabela 22), o atraso, mesmo que de 1 mês, apresentou diferença na performance dos modelos, sendo o de melhor desempenho, assim como para SSI1, o modelo treinado por GEP. Nota-se um aumento do coeficiente de correlação em todos os modelos quando se considera o atraso, porém não necessariamente uma diminuição nos erros, como observado no comparativo das estimativas obtidas com ANN. Todavia, é possível observar graficamente, especialmente com os modelos treinados por SVM e GEP, um achatamento dos resultados em torno da linha 1:1 quando comparados com as estimativas sem atraso.




Figura 32. Estimativas de SSI3 a) sem atraso e b) com atraso de 1 mês utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 22. Parâmetros estatísticos entre as estimativas de SSI3 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.

	Sem atraso		
	SVM	GEP	ANN
r	0.784	0.786	0.778
RMSE	0.625	0.646	0.646
RAE	0.587	0.620	0.632
MAE	0.471	0.497	0.507

	Com atraso (1 mês)		
	SVM	GEP	ANN
r	0,795	0,823	0,794
RMSE	0,600	0,557	0,666
RAE	0,594	0,551	0,652
MAE	0,470	0,436	0,516

Para a escala de 6 meses, com os resultados apresentados na Figura 33, os coeficientes de correlação encontrados nos modelos treinados sem atraso apresentaram valores levemente acima do que os computados com atraso, porém, nota-se a diferença na dispersão das estimativas de SSI6. A Tabela 23 apresenta os parâmetros estatísticos das comparações entre SSI6 observado e estimado. Os modelos sem atraso superestimam

os menores valores de SSI e acabam subestimando mais os valores positivos do que quando comparados aos modelos treinados com atraso. O modelo de melhor performance, considerando apenas coeficiente de correlação, foi utilizando SVM sem atraso, porém, considerando os menores erros e a proximidade com a linha 1:1, o modelo usando GEP com atraso de 3 meses apresentou parâmetros estatísticos de melhor desempenho.




Figura 33. Estimativas de SSI6 a) sem atraso e b) com atraso de 3 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 23. Parâmetros estatísticos entre as estimativas de SSI6 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.

	Sem atraso		
	SVM	GEP	ANN
r	0.842	0.836	0.812
RMSE	0.585	0.602	0.598
RAE	0.562	0.558	0.598
MAE	0.469	0.466	0.499
	Com atraso (3 meses)		
	SVM	GEP	ANN
r	0,813	0,836	0,811
RMSE	0,573	0,539	0,580
RAE	0,561	0,530	0,592
MAE	0,453	0,428	0,478

No que se refere à escala de 12 meses, com os resultados expressos na Figura 34 e Tabela 24, é notável a diferença entre os modelos treinados com e sem atraso, especialmente no que se refere aos erros e valores mais extremos. Os modelos com atraso apresentaram maiores coeficientes de correlação do que as estimativas sem atraso. Os métodos *support vector machine* e *gene expression programming* com atraso de 6 meses apresentaram os parâmetros estatísticos de melhor desempenho, porém, é possível notar que o modelo treinado com GEP apresenta resultados com valores mais extremos de forma mais satisfatória, próximo da linha 1:1.




Figura 34. Estimativas de SSI12 a) sem atraso e b) com atraso de 6 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.

Para SSI24 (Figura 35), as estimativas, tanto para o modelo com atraso quanto sem, apresentaram uma dispersão maior do que para os valores computados de SSI6 e SSI12 na bacia do rio Paraguai. O coeficiente de correlação (Tabela 25) de SPI12 com SSI24 sem atraso é de 0,593, e o de SPEI12 com SSI24 é no valor de 0,630, o que pode justificar a

Tabela 24. Parâmetros estatísticos entre as estimativas de SSI12 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.

Sem atraso			
	SVM	GEP	ANN
r	0.785	0.727	0.725
RMSE	0.664	0.788	0.760
RAE	0.652	0.750	0.729
MAE	0.553	0.637	0.619

Com atraso (6 meses)			
	SVM	GEP	ANN
r	0,847	0,851	0,822
RMSE	0,521	0,517	0,574
RAE	0,516	0,526	0,580
MAE	0,427	0,435	0,479

dispersão dos valores das estimativas de SSI24. O melhor resultado foi obtido com o modelo utilizando SVM com atraso de 12 mesmo, porém mesmo assim é notável que os valores residuais indiquem que há necessidade de correção do modelo para estimativa de seca hidrológica na escala de 24 meses utilizando as entradas na acumulação de 12 meses.

Para SSI24 (Figura 35), as estimativas, tanto para o modelo com atraso quanto sem, apresentaram uma dispersão maior do que para os valores computados de SSI6 e SSI12 na bacia do rio Paraguai. O coeficiente de correlação (Tabela 25) de SPI12 com SSI24 sem atraso é de 0,593, e o de SPEI12 com SSI24 é no valor de 0,630, o que pode justificar a dispersão dos valores das estimativas de SSI24. O melhor resultado foi obtido com o modelo utilizando SVM com atraso de 12 mesmo, porém mesmo assim é notável que os valores residuais indiquem que há necessidade de correção do modelo para estimativa de seca hidrológica na escala de 24 meses utilizando as entradas na acumulação de 12 meses.




Figura 35. Estimativas de SSI24 a) sem atraso e b) com atraso de 12 meses utilizando acumulado de 12 meses de P e ETo como entradas para a bacia do rio Paraguai, no Pantanal, usando os métodos SVM, GEP e ANN respectivamente.

Tabela 25. Parâmetros estatísticos entre as estimativas de SSI24 obtidas utilizando, respectivamente, SVM, GEP e ANN e os valores observados para a bacia do rio Paraguai, no Pantanal.

	Sem atraso		
	SVM	GEP	ANN
r	0.747	0.684	0.670
RMSE	0.626	0.698	0.708
RAE	0.627	0.707	0.705
MAE	0.498	0.562	0.560

	Com atraso (12 meses)		
	SVM	GEP	ANN
r	0,815	0,788	0,765
RMSE	0,563	0,605	0,686
RAE	0,566	0,608	0,677
MAE	0,457	0,492	0,547

5. DISCUSSÃO

5.1. Variação espaço-temporal das variáveis hidrometeorológicas

Dentre as variáveis hidrometeorológicas que menos variaram anualmente nas bacias analisadas, a precipitação (P) apresentou a menor quantidade de bacias com tendência significativa, em contraste com a temperatura máxima (Tmax), que apresentou variação no maior número de bacias com variações significantes (339 bacias). De forma semelhante aos resultados obtidos, Penereiro et al. (2018) avaliou 243 estações meteorológicas localizadas em municípios espalhados pelos biomas brasileiros e encontrou mais tendências significativas de temperatura média do que de precipitação. (PORTO DE CARVALHO *et al.*, 2014) observou tendências positivas de precipitação máxima diária para as regiões Sul, Sudeste e Centro-Oeste do Brasil.

Comparando as variáveis de temperatura máxima e mínima (Tmin), nota-se que comparado aos outros biomas, a Caatinga foi o que menos apresentou bacias com tendências significativas. Os resultados obtidos corroboram com o que foi encontrado em outros estudos na Caatinga (CAMPOS; DE ANDRADE, 2021; TORRES; LAPOLA; GAMARRA, 2018). No Cerrado e na Mata Atlântica, onde a maioria das bacias com tendência positiva de Tmin se encontram, têm a agricultura como o principal causador da mudança de uso e cobertura do solo ao longo das últimas décadas (ANACHE *et al.*, 2018; CABALLERO *et al.*, 2023). O aumento da temperatura mínima e da temperatura noturna afetam todos os estados de crescimento da plantação, diminuindo a produção e aumentando os custos de tratamento e irrigação (NOETZOLD *et al.*, 2014; PENG *et al.*, 2004; SHI *et al.*, 2017).

A mudança de temperatura impacta diretamente na umidade relativa (UR), devido à alteração no déficit de vapor de pressão, portanto, o aumento da temperatura média ao longo tende a ocasionar a diminuição de UR (ALLEN *et al.*, 1998; PEREIRA;

ANGELOCCI; SENTELHAS, 2002), o que corrobora com os resultados obtidos de tendências negativas de UR na Amazônia, Mata Atlântica e Cerrado. No Cerrado, onde se encontram a maior parte das bacias com tendência negativa de umidade relativa, também foi onde foram observadas as maiores tendências de temperatura. Segundo Hofmann et al. (2021), o aumento da temperatura no Cerrado que ocorre nas últimas décadas permite a atmosfera local reter mais vapor do que o que a evapotranspiração na região consegue ceder. A diminuição da umidade relativa média e aumento da temperatura no Cerrado e região central do Brasil nos leva a projetar um aumento da sequeidão no ar.

Os resultados de tendências de velocidade do vento indicam um aumento dos valores médios de u_2 de forma mais presente no Pantanal e no Cerrado, e diminuição nas regiões mais próximas da costa brasileira. Estes resultados divergem dos encontrados por Gilliland e Keim (2018). Lima et al. (2024), entretanto, encontrou tendências de u_2 nos biomas brasileiros que variaram entre positivas e negativas em períodos de 30 anos, mostrando uma alta variabilidade de comportamento da velocidade do vento no país. Todavia, as tendências positivas de u_2 , assim como de radiação solar incidente, apresentam um impacto direto nas tendências de ETo , visto que 75% das bacias com tendências positivas de velocidade do vento e 81% das estações com aumento de Rad apresentaram também tendências significativas de evapotranspiração de referência. O Pantanal, o Cerrado, sul da Amazônia e a região da bacia do rio São Francisco na Caatinga apresentaram as maiores tendências de ETo , indicando o aumento mais agudo da demanda atmosférica ao longo do tempo nestes locais. Estudos indicaram a radiação como um dos fatores mais importantes na estimativa de ETo em nestas regiões (DE OLIVEIRA *et al.*, 2021; VALLE JÚNIOR *et al.*, 2021), corroborando com os resultados encontrados neste estudo. A evapotranspiração real apresentou, em sua maioria, variações

negativas na Amazônia, especialmente na região que se aproxima à fronteira agrícola amazônica. Tais resultados são possivelmente causados pela diminuição de extração da água subsuperficial devido à mudança do uso do solo na região (SILVA; PEREIRA; DA ROCHA, 2016). Resultados semelhantes de ET foram obtidos por (BAKER *et al.*, 2021).

As tendências de vazão dos rios indicaram o Pantanal e a transição entre Cerrado e Caatinga, especialmente na bacia do rio São Francisco como pontos de maior atenção às condições hidrológicas futuras. Marengo, Tomasella e Uvo (1998) encontraram resultados que indicaram tendências negativas na vazão do rio São Francisco causados possivelmente por consequência do manejo inadequado dos recursos hídricos da região. Projeções futuras apontam que tanto a evapotranspiração quanto o escoamento superficial tendem a diminuir na Caatinga (TORRES; LAPOLA; GAMARRA, 2018). Para a bacia do rio Paraguai e sudoeste da Amazônia, além da detecção de tendências negativas de precipitação na série histórica do CABra, incêndios causados por atividades antrópicas a fim de alterar a cobertura do solo para agropecuária de forma mais célere (MARENGO *et al.*, 2021).

5.2. Distribuição e variação espaço-temporal dos eventos de seca

Os resultados obtidos em relação ao número de eventos de seca detectados mostraram que, para SPI, o aumento da escala do tempo diminui de forma geral o total de eventos detectados, porém os eventos moderados do índice de chuva acabaram apresentando um aumento com a progressão do acúmulo de precipitação. Todavia, Da Silva *et al.* (2023) identificou que no Nordeste brasileiro, independentemente das condições climáticas, a intensidade de SPI aumentou conforme o tempo de acumulação analisado, porém SPI nas escalas de 1, 3 e 6 meses não apresentaram variação significativa na Caatinga. Tal resultado pode ser atribuído pela padronização dos dados

de chuva de forma que não é possível identificar chuvas rápidas ou esparsas ao longo da série. Para SPEI, os eventos moderados diminuíram em função da escala do tempo, enquanto os eventos severos e extremos se mantiveram na mesma faixa nas alterações de acúmulo da diferença entre P e ETo. Tal resultado indica que no país, como um todo, a demanda atmosférica é determinante na detecção de eventos de seca meteorológica mais intensos. Em relação à SSI, nota-se uma diferença entre o número de eventos detectados com os índices de seca meteorológica no total, em secas severas e, principalmente, eventos extremos.

Comparando a quantidade de eventos de seca extrema quantificados entre SPI e SSI, o índice de seca hidrológica na escala de 24 meses ultrapassa o de seca meteorológica, porém, na comparação SPEIxSSI é possível observar que o total de eventos hidrológicos extremos é menor do que, pelo menos, 40% do total de eventos detectados com SPEI. Essa diferença de números na seca hidrológica extrema pode dever-se à influência de outras variáveis não contabilizadas no estudo, como níveis de reservatório, volume de água subsuperficial ou subterrânea, mudança do uso do solo, dentre outros fatores que afetam direta e indiretamente a vazão dos rios, acarretando em efeitos que mitigam os eventos extremos. Em escalas sazonais, as atividades humanas exercem um impacto supressor nas secas severas e extremas, mitigando o impacto das mudanças climáticas (ZHAO *et al.*, 2024). Em bacias da Irlanda, os resultados de Meresa, Murphy e Donegan (2023) apresentaram mais secas hidrológicas do que eventos detectados com SPI e SPEI, de forma inversa com os resultados obtidos no Brasil. Shiau (2023) avaliou não somente o impacto entre SPI e SSI, mas também do índice de seca de reservatório, porém a relação SPIxSSI tem maior influência do que SPI na detecção de seca hidrológica em uma bacia chinesa. Da Silva *et al.* (2024) apresentou resultados que

indicam que secas meteorológicas são mais comuns, porém menos severas do que as secas hidrológicas na região hidrográfica Atlântico Nordeste Oriental.

Dentre as tendências dos índices de seca, notou-se em grande parte das bacias que a intensidade das variações, sejam elas positivas ou negativas, foram se intensificando com o aumento da escala de tempo utilizada nos índices. Além disso, é possível observar que as tendências negativas mais intensas de SPI e SPEI se concentram na Amazônia, Cerrado e Pantanal. O Pantanal e o Cerrado, especialmente na região do Alto São Francisco, também foram locais constantes declínio dos valores de SSI em todas as escalas de tempo, porém na Amazônia, diferente dos resultados de variação temporal dos índices de seca meteorológica, as tendências do índice hidrológico foram positivas em grande parte do bioma.

Comparando o comportamento dos índices de seca com as tendências das variáveis hidrometeorológicas, embora a precipitação anual não apresentou muitas bacias com variações significativas, SPI apresentou tendências significativas em todas as escalas de tempo em todos os biomas, possivelmente pela consideração de sazonalidade que o índice utiliza. Diferentemente da variação temporal de SPEI, que considera de forma intrínseca diversas variáveis meteorológicas, como a temperatura e radiação solar. A diferença entre as tendências de SSI e dos índices de seca meteorológica instigam uma fraca relação entre o efeito de outras variáveis além das presentes no cálculo de SPI e SPEI e a seca hidrológica, de forma que seja necessário entender a dinâmica de cada localidade e os eventos anormais que podem ter ocorrido durante o período de análise. Wu et al. (2024) identificou que a resposta de SPI para SSI é mais sensível quando as variáveis micrometeorológicas estão diminuindo ao longo do tempo, porém de forma não-linear. Anomalias climáticas, como El Niño e La Niña, precisam ser levadas em consideração para avaliar o impacto das variáveis meteorológicas nos eventos de seca (SUHANA *et*

al., 2023). Costa et al. (2021) identificou que os eventos de El Niño coincidem com eventos de seca mais prolongados em bacias do Nordeste Brasileiro. Segundo Zou et al. (2023), o aumento da temperatura e diminuição de precipitação, escoamento superficial e coeficiente de escoamento foram os principais motores para condições de estiagem em uma região semiárida na China.

Os resultados obtidos neste estudo mostram que a seca meteorológica na bacia do rio Paraguai tem grande impacto da seca meteorológica na região. Assim como os resultados obtidos pelo CABra, Silva et al. (2024) identificou que precipitação insuficiente na escala de 12 meses é o principal fator a causar secas no Pantanal. Calim Costa et al. (2024) identificou que os efeitos de secas meteorológicas aparentam ser mais significantes em escalas maiores do que 3 meses no Pantanal. No caso de secas extremas, altas temperaturas também podem ser um dos motores de tais eventos no Pantanal (SILVA *et al.*, 2024). A resposta de SPI e SPEI em SSI no Pantanal apresentou resultados promissores para corroborar com a relação direta entre vazão, precipitação e demanda atmosférica, com atrasos bem definidos entre seca meteorológica e hidrológica. Todavia, na região amazônica essa mesma relação não se refletiu, em que mesmo o declínio de SPEI ao longo do tempo não indicou o aumento de secas hidrológicas em grande parte da região. Li et al. (2024) observou que o tempo de propagação da seca meteorológica em seca hidrológica é mais curto em estações com taxas de evaporação maiores, o que condiz com as correlações mais altas entre os índices de seca meteorológica e SSI apresentarem atrasos menores do que quando comparado com o Pantanal.

A sazonalidade menos destacada na Amazônia também pode ser um reflexo desta menor conversão de SPI e SPEI em seca hidrológica, visto que a propagação de seca meteorológica em hidrológica depende que a seca meteorológica passe um certo limite que sofre influência da mudança de estações ou períodos climáticos (WU *et al.*, 2024;

ZHANG *et al.*, 2023). Sattar e Kim (2018) identificou que a probabilidade de atrasos mais curtos entre a seca meteorológica e hidrológica aumenta conforme o aumento da intensidade dos índices meteorológicos. Já na região do São Francisco, a baixa correlação entre os índices de seca possivelmente se deve à atividade antrópica na região. Devido especialmente à agricultura local, o bombeamento de águas subterrâneas pode ser um dos principais fatores para diminuição da vazão na região do São Francisco (LUCAS *et al.*, 2021). Suhana *et al.* (2023) indicou que a resposta de SPI em SSI pode ser afetada em localidades onde as águas subterrâneas são a fonte de água potável, devido à recarga de aquíferos e lençóis freáticos com precipitação. O aumento da propagação da seca meteorológica em hidrológica ocorre quando a reservação de água subterrânea é limitada (MERESA; MURPHY; DONEGAN, 2023). Todavia, pela proximidade com a costa brasileira, a influência da temperatura do oceano pode causar impactos diferentes na bacia do rio São Francisco quando comparada com a região do Pantanal e Amazônia. Freitas *et al.* (2022) apontou que o aumento da temperatura da superfície do mar na região Nordeste possivelmente afeta a formação de nuvens e, conseqüentemente, diminui a precipitação na região do Alto São Francisco, causando impactos no volume de água escoado superficialmente na bacia.

5.3. Avaliação dos métodos de *machine learning* na estimativa de SSI

Dentre os resultados obtidos com *machine learning*, nota-se que as estimativas no rio Madeira apresentaram parâmetros estatísticos piores do que nas outras duas bacias. Na bacia da Amazônia, o atraso apresentou melhores resultados em algumas escalas, porém na escala de 12 meses as estimativas sem atraso indicaram maior correlação e menor erro em todos os métodos. Estes resultados possivelmente indicam que precipitação e ETo com atraso não são suficientes para estimar SSI na Amazônia. Outros

fatores, como água subterrânea e cobertura do solo podem ser necessários para previsão de seca hidrológica na região. Pelo menos 34% da bacia do rio Amazonas é sustentada pela água subterrânea durante o período de estiagem (BAGHERI *et al.*, 2024). Além disso, o rio Madeira pode sofrer efeito de reservatórios de usinas hidrelétricas e regulação de vazão (MIGUEZ-MACHO; FAN, 2012), indicando a necessidade de avaliar o efeito da ação antrópica na região. So, Lee e Bae (2020) obteve resultados de previsão de seca hidrológica utilizando como entrada acumulados de 3 meses de precipitação, vazão e nível de reservatórios na Coreia do Sul, pontuando a importância de dados de reservatórios em locais com barragens. De forma geral, o SVM foi o método com melhores resultados na bacia da região amazônica.

Da mesma forma, a bacia analisada localizada no Cerrado também teve SVM como o melhor método para estimativa de SSI, principalmente na escala de 24 meses, de forma que os valores positivos também apresentaram estimativas próximas dos valores observados. Todavia, assim como na bacia do rio Madeira, a bacia do rio São Francisco possui muita influência das águas subterrâneas. A região do Alto São Francisco tem crescido nas últimas décadas como uma fronteira agrícola, na região chamada de MATOPIBA, que é composto pela parcela do Cerrado nos estados do Maranhão, Tocantins, Piauí e Bahia (MARTINS *et al.*, 2024), e consequentemente tendo seu balanço hídrico afetado pelo aumento de demanda de irrigação. Durante os períodos de seca mais intensa, há um acréscimo de abstração de água subterrâneas para irrigação na região do São Francisco (PAREDES-TREJO *et al.*, 2021). Logo, é possível concluir que para escalas de tempo abaixo de 12 meses sejam necessárias mais entradas intrínsecas à reservação de água na bacia e produção agrícola, porém, para períodos de acumulação mais prolongados, os valores de precipitação e evaporação de referência podem ser considerados como principais variáveis na previsão de secas hidrológicas.

Para a bacia localizada no Pantanal, entretanto, os resultados apresentaram comportamento diferente das demais bacias analisadas. Por conta da análise de correlação cruzada, eram esperados desempenhos melhores dos modelos de *machine learning* para a bacia do rio Paraguai. Entretanto, as estimativas considerando o atraso de maior coeficiente de correlação apresentaram parâmetros estatísticos de melhor desempenho, porém, independentemente de atraso, os valores positivos de SSI, especialmente os mais elevados, indicaram estimativas que subestimam os valores observados. Possivelmente as condições de SSI positivo não apresentaram estimativas aceitáveis devido à dinâmica hidrológica do Pantanal, pois o rio Paraguai e seus afluentes são regulados por pulsos de inundação e drenagem lenta durante a época de cheia da região, devido à sua topografia plana e pouco acidentada (PAZ *et al.*, 2010). Para as condições de seca, todavia, os modelos indicaram a influência de P e ETo como importantes motores da estiagem na região. Portanto, para as condições do Pantanal, é importante considerar não somente o atraso entre a seca meteorológica e seca hidrológica, mas também como o comportamento hidrológico da bacia do rio Paraguai se diferencia entre os períodos de cheia e estiagem. Conforme estudo apresentado por Wu *et al.* (2024), análises não-estacionárias apresentaram maior número de acertos de alertas de estiagem quando correlacionados índices de seca meteorológica com seca hidrológica.

Um dos grandes desafios de utilizar *machine learning* na previsão de eventos de seca hidrológica é apresentar de forma otimizada as entradas necessárias para obtenção de melhores resultados. A própria natureza dos métodos, que são treinados com um grupo de dados específicos, pode também gerar incertezas quando necessário apresentar resultados fora que se localizam fora do espaço de treino. Modelos utilizando *machine learning* e métodos híbridos apresentaram maior desempenho na previsão de secas quando comparados com métodos probabilísticos, estatísticos e metodologias utilizando

séries temporais (PRODHAN *et al.*, 2022). Diversos estudos apresentaram métodos de caracterização e previsão de eventos hidrológicos ao redor do mundo (AGANA; HOMAIFAR, 2017; ARABZADEH; KHOLOOSI; BAZRAFSHAN, 2016; CHIANG; TSAI, 2012; CUTORE; MAURO; CANCELLIERE, 2009; ESFAHANIAN *et al.*, 2017; NABIPOUR *et al.*, 2020; OCHOA-RIVERA, 2008; PRASAD *et al.*, 2017; SEO; LEE, 2019), porém as peculiaridades de cada localidade dificultam a padronização de metodologias e entradas utilizadas. Segundo Prodhhan *et al.* (2022), ANN é um dos métodos mais utilizados na previsão de índices de seca por conta das propriedades não-lineares que os modelos usam para identificar as possíveis interações. Parajuli *et al.* (2024) identificou alta precisão utilizando os modelos *Random Forest* e *Support Vector Machine* para estimar SSI1 e SSI3 utilizando como entradas as variáveis de precipitação, vazão, com atraso de até 5 meses e mudança de uso do solo, com os resultados na escala de 3 meses com maior precisão do que para 1 mês. Sundararajan *et al.* (2021) indicou que uma das desvantagens do uso de *machine learning* é o uso de uma grande quantidade de dados históricos, de forma que a precisão da modelagem é prejudicada devido à falta de disponibilidade de dados. Os resultados obtidos neste estudo apresentaram o desempenho de modelos com diferentes métodos usando entradas simplificadas e um atraso obtido através de correlação cruzada, porém é necessário entender a dinâmica hidrológica de cada bacia e os efeitos da ação antrópica para aplicar ferramentas que ajudam na previsão e prevenção de eventos extremos.

6. CONCLUSÃO

O estudo apresentado nesta tese teve como objetivo diagnosticar os eventos de seca nos biomas brasileiros, avaliando comportamento dos eventos de seca e propondo métodos de previsão da seca hidrológica quando há falta de dados de vazão. Este trabalho apresentou um panorama espaço-temporal dos eventos de seca meteorológica e hidrológica, além das variações dos índices SPI, SPEI, SSI e variáveis hidrometeorológicas entre os anos 1980-2010 em bacias espalhadas em todos os biomas brasileiros. Com tais informações, foi possível avaliar a correlação de atraso entre a seca meteorológica e hidrológica em biomas com tendências negativas mais intensas detectadas na base de dados utilizada. Por fim, foram avaliadas estimativas de SSI utilizando três métodos de *machine learning* e precipitação e evapotranspiração de referência como variáveis de entrada, a fim de apresentar ferramentas mais simplificadas na previsão de eventos de seca hidrológica.

Embora a precipitação e vazão não tenham apresentado tendências significativas em grande parte das bacias hidrográficas, é notável a diminuição dos índices de seca em parte considerável do Brasil. As demais variáveis micrometeorológicas corroboram com as tendências negativas de SPI, SPEI e SSI no território brasileiro, especialmente as que compõem a estimativa de ETo através do método de Penman-Monteith. A quantidade de eventos de seca hidrológica durante a série histórica é bem menor do que o total de secas quantificadas com SPI e SPEI, especialmente na Caatinga e no Pampa. Amazônia, Cerrado e, principalmente, Pantanal foram os biomas com tendências negativa mais intensas nos índices, indicando uma piora mais acentuada das secas meteorológica e hidrológica nestas regiões, além de uma diminuição do tempo de retorno de secas severas e extremas com o passar do tempo.

A análise de correlação cruzada dos índices de seca em bacias da Amazônia, Cerrado e Pantanal apresentaram comportamentos diferentes dos atrasos de maior correlação entre os biomas. Na Amazônia e no Cerrado notou-se uma conversão menor de eventos de seca meteorológica em hidrológica, possivelmente por conta da ação antrópica na região, como represamento de água com barragens para geração de energia elétrica, e também por conta do fluxo de água subterrânea nas bacias analisadas, que, diferentemente do Pantanal, indicam a necessidade de avaliação de outras variáveis além de precipitação e evapotranspiração de referência no impacto dos eventos detectados com SSI. Já no Pantanal, SPI e SPEI nas escalas de 12 e 24 meses apresentaram alta correlação com SSI, com atrasos bem definidos, expressando a possibilidade de P e ETo serem as principais variáveis a refletirem na diminuição da vazão e, conseqüentemente, na aparição de eventos de seca hidrológica no bioma.

As estimativas de SSI através de métodos de *machine learning* usando P e ETo como entradas corroboram com os resultados obtidos pela análise de correlação cruzada de forma que é possível prever valores de SSI no Pantanal em escalas de tempo de 1 a 24 meses, assim como na Amazônia, para SSI₂₄, e no Cerrado para escalas de SSI acima de 6 meses. Os métodos *support vector machine* e *gene expression programming* apresentaram resultados de melhor performance do que os obtidos com *artificial neural networks*. Todavia, é necessário entender a dinâmica de cada bacia para identificar o atraso ideal entre os índices de seca meteorológica e hidrológica, visto que em algumas bacias, como a do rio Paraguai, entender tal comportamento melhorou a performance dos modelos utilizados. Estas ferramentas podem permitir tomadas de decisão mais ágeis por parte dos gestores de recursos hídricos a fim de mitigar os impactos da seca meteorológica na seca hidrológica severas e extremas com tempo hábil para agir de forma preventiva

7. SUGESTÕES PARA TRABALHOS FUTUROS

A primeira sugestão se refere ao estudo sobre os limites da propagação da seca meteorológica para hidrológica, considerando condições climáticas, hidrológicas e de uso do solo que permeiam as bacias hidrográficas, além de intensidade e duração das secas observadas. Assim como o estudo de demais fatores, como nível de reservatório, reservação de água subterrânea, extração para irrigação, mudança de uso e cobertura do solo, queimadas e outros aspectos intrínsecos à atividade humana na composição de indicadores que influenciam diretamente na seca hidrológica. A sazonalidade também é um dos fatores a serem considerados, principalmente em regiões áridas como a Caatinga, portanto recomenda-se estudos mais detalhados em considerando diferentes estações do ano.

Outra sugestão é a avaliação de outros métodos de *machine learning* e aplicação em outras bacias hidrográficas, com entradas diferentes, conforme o que for avaliado para a localidade, para estimativa e previsão de seca hidrológica. Da mesma forma, aplicar os modelos com performances adequadas na previsão de condições futuras, usando diferentes cenários de mudanças climáticas.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- AGANA, N. A.; HOMAIFAR, A. A deep learning based approach for long-term drought prediction. Em: SoutheastCon 2017, 2017, [...]. 2017. p. 1–8.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Rome, Italy: FAO Irrigation and Drainage Paper no. 56, 1998.
- ALMAGRO, A.; OLIVEIRA, P. T. S.; MEIRA NETO, A. A.; ROY, T.; TROCH, P. CABra: a novel large-sample dataset for Brazilian catchments. **Hydrology and Earth System Sciences**, v. 25, n. 6, p. 3105–3135, 2021. Disponível em: <<https://hess.copernicus.org/articles/25/3105/2021/>>.
- ANACHE, J. A. A.; FLANAGAN, D. C.; SRIVASTAVA, A.; WENDLAND, E. C. Land use and climate change impacts on runoff and soil erosion at the hillslope scale in the Brazilian Cerrado. **Science of The Total Environment**, v. 622–623, p. 140–151, 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0048969717333156>>.
- ARABZADEH, R.; KHOLOOSI, M. M.; BAZRAFSHAN, J. Regional Hydrological Drought Monitoring Using Principal Components Analysis. **Journal of Irrigation and Drainage Engineering**, v. 142, n. 1, p. 4015029, 2016. Disponível em: <<https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29IR.1943-4774.0000925>>.
- ASCE. Artificial Neural Networks in Hydrology. I: Preliminary Concepts. **Journal of Hydrologic Engineering**, v. 5, n. 2, p. 115–123, 1 abr. 2000. Disponível em: <[https://doi.org/10.1061/\(ASCE\)1084-0699\(2000\)5:2\(115\)](https://doi.org/10.1061/(ASCE)1084-0699(2000)5:2(115))>.
- BAGHERI, O.; POKHREL, Y.; MOORE, N.; PHANIKUMAR, M. S. Groundwater dominates terrestrial hydrological processes in the Amazon at the basin and subbasin scales. **Journal of Hydrology**, v. 628, p. 130312, 2024. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0022169423012544>>.
- BAKER, J. C. A.; GARCIA-CARRERAS, L.; GLOOR, M.; MARSHAM, J. H.; BUERMANN, W.; DA ROCHA, H. R.; NOBRE, A. D.; DE ARAUJO, A. C.; SPRACKLEN, D. V. Evapotranspiration in the Amazon: spatial patterns, seasonality, and recent trends in observations, reanalysis, and climate models. **Hydrology and Earth System Sciences**, v. 25, n. 4, p. 2279–2300, 2021. Disponível em: <<https://hess.copernicus.org/articles/25/2279/2021/>>.
- BASAK, D.; PAL, S.; PATRANABIS, D. C. **Support Vector Regression Neural Information Processing-Letters and Reviews**. [s.l: s.n.].
- BAZRAFSHAN, J.; HEJABI, S.; RAHIMI, J. Drought Monitoring Using the Multivariate Standardized Precipitation Index (MSPI). **Water Resources Management**, v. 28, n. 4, p. 1045–1060, 2014. Disponível em: <<https://doi.org/10.1007/s11269-014-0533-2>>.
- BELAYNEH, A.; ADAMOWSKI, J.; KHALIL, B.; OZGA-ZIELINSKI, B. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural

network and wavelet support vector regression models. **Journal of Hydrology**, v. 508, p. 418–429, jan. 2014.

BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. Em: Proceedings of the Fifth Annual Workshop on Computational Learning Theory, 1992, New York, NY, USA. [...]. New York, NY, USA: Association for Computing Machinery, 1992. p. 144–152.

BOUAZIZ, M.; MEDHIOUB, E.; CSAPLOVISC, E. A machine learning model for drought tracking and forecasting using remote precipitation data and a standardized precipitation index from arid regions. **Journal of Arid Environments**, v. 189, n. December 2020, p. 104478, 2021.

CABALLERO, C. B.; BIGGS, T. W.; VERGOPOLAN, N.; WEST, T. A. P.; RUHOFF, A. Transformation of Brazil's biomes: The dynamics and fate of agriculture and pasture expansion into native vegetation. **Science of The Total Environment**, v. 896, p. 166323, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0048969723049483>>.

CALIM COSTA, M.; MARENGO, J. A.; ALVES, L. M.; CUNHA, A. P. Multiscale analysis of drought, heatwaves, and compound events in the Brazilian Pantanal in 2019–2021. **Theoretical and Applied Climatology**, v. 155, n. 1, p. 661–677, 1 jan. 2024.

CAMPOS, D. A.; DE ANDRADE, E. M. Seasonal trend of climate variables in an area of the Caatinga phytogeographic domain. **REVISTA AGRO@MBIENTE ON-LINE**, v. 15, 25 fev. 2021.

CHAGAS, V. B. P.; CHAFFE, P. L. B.; ADDOR, N.; FAN, F. M.; FLEISCHMANN, A. S.; PAIVA, R. C. D.; SIQUEIRA, V. A. CAMELS-BR: hydrometeorological time series and landscape attributes for 897 catchments in Brazil. **Earth System Science Data**, v. 12, n. 3, p. 2075–2096, 8 set. 2020.

CHIANG, J. L.; TSAI, Y. S. Reservoir Drought Prediction Using Support Vector Machines. Em: Innovation in Materials Science and Emerging Technology, 2012, [...]. Trans Tech Publications Ltd, 2012. v. 145, p. 455–459.

COSTA, M. da S.; OLIVEIRA-JÚNIOR, J. F. de; SANTOS, P. J. dos; CORREIA FILHO, W. L. F.; GOIS, G. de; BLANCO, C. J. C.; TEODORO, P. E.; SILVA JUNIOR, C. A. da; SANTIAGO, D. de B.; SOUZA, E. de O.; JARDIM, A. M. da R. F. Rainfall extremes and drought in Northeast Brazil and its relationship with El Niño–Southern Oscillation. **International Journal of Climatology**, v. 41, n. S1, p. E2111–E2135, 1 jan. 2021.

CUNHA, A. P. M. A.; ZERI, M.; DEUSDARÁ LEAL, K.; COSTA, L.; CUARTAS, L. A.; MARENGO, J. A.; TOMASELLA, J.; VIEIRA, R. M.; BARBOSA, A. A.; CUNNINGHAM, C.; CAL GARCIA, J. V.; BROEDEL, E.; ALVALÁ, R.; RIBEIRO-NETO, G. Extreme Drought Events over Brazil from 2011 to 2019. **Atmosphere**, v. 10, n. 11, p. 642, 24 out. 2019.

CUTORE, P.; MAURO, G. Di; CANCELLIERE, A. Forecasting Palmer Index Using Neural Networks and Climatic Indexes. **Journal of Hydrologic Engineering**, v. 14, n. 6,

p. 588–595, 2009. Disponível em:
<<https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29HE.1943-5584.0000028>>.

DA ROCHA JÚNIOR, R. L.; DOS SANTOS SILVA, F. D.; COSTA, R. L.; GOMES, H. B.; PINTO, D. D. C.; HERDIES, D. L. Bivariate Assessment of Drought Return Periods and Frequency in Brazilian Northeast Using Joint Distribution by Copula Method. **Geosciences**, v. 10, n. 4, p. 135, 10 abr. 2020.

DA SILVA, A. S. A.; MENEZES, R. S. C.; TELESCA, L.; STOSIC, B.; STOSIC, T. Fisher Shannon analysis of drought/wetness episodes along a rainfall gradient in Northeast Brazil. **International Journal of Climatology**, v. 41, n. S1, p. E2097–E2110, 2021.

DA SILVA, A. S. A.; STOSIC, T.; ARSENIĆ, I.; MENEZES, R. S. C.; STOSIC, B. Multifractal analysis of standardized precipitation index in Northeast Brazil. **Chaos, Solitons and Fractals**, v. 172, 1 jul. 2023.

DA SILVA, G. J. F.; SILVA, R. M. da; BRASIL NETO, R. M.; SILVA, J. F. C. B. C.; DANTAS, A. P. X.; SANTOS, C. A. G. Multi-datasets to monitor and assess meteorological and hydrological droughts in a typical basin of the Brazilian semiarid region. **Environmental Monitoring and Assessment**, v. 196, n. 4, 1 abr. 2024.

DAI, M.; HUANG, S.; HUANG, Q.; LENG, G.; GUO, Y.; WANG, L.; FANG, W.; LI, P.; ZHENG, X. Assessing agricultural drought risk and its dynamic evolution characteristics. **Agricultural Water Management**, v. 231, p. 106003, 2020. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0378377419316531>>.

DE OLIVEIRA, R. G.; VALLE JÚNIOR, L. C. G.; DA SILVA, J. B.; ESPÍNDOLA, D. A. L. F.; LOPES, R. D.; NOGUEIRA, J. S.; CURADO, L. F. A.; RODRIGUES, T. R. Temporal trend changes in reference evapotranspiration contrasting different land uses in southern Amazon basin. **Agricultural Water Management**, v. 250, p. 106815, 2021. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0378377421000809>>.

DE OLIVEIRA-JÚNIOR, J. F.; DE GOIS, G.; DE BODAS TERASSI, P. M.; DA SILVA JUNIOR, C. A.; BLANCO, C. J. C.; SOBRAL, B. S.; GASPARINI, K. A. C. Drought severity based on the SPI index and its relation to the ENSO and PDO climatic variability modes in the regions North and Northwest of the State of Rio de Janeiro - Brazil. **Atmospheric Research**, v. 212, n. 2017, p. 91–105, 2018.

ESFAHANIAN, E.; NEJADHASHEMI, A. P.; ABOUALI, M.; ADHIKARI, U.; ZHANG, Z.; DANESHVAR, F.; HERMAN, M. R. Development and evaluation of a comprehensive drought index. **Journal of Environmental Management**, v. 185, p. 31–43, 2017. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0301479716308404>>.

FANG, W.; HUANG, S.; HUANG, Q.; HUANG, G.; WANG, H.; LENG, G.; WANG, L. Identifying drought propagation by simultaneously considering linear and nonlinear dependence in the Wei River basin of the Loess Plateau, China. **Journal of Hydrology**, v. 591, p. 125287, 2020. Disponível em:
<<https://www.sciencedirect.com/science/article/pii/S0022169420307472>>.

- FERREIRA, C. Gene Expression Programming: a New Adaptive Algorithm for Solving Problems. 25 fev. 2001. Disponível em: <<http://arxiv.org/abs/cs/0102027>>.
- FILHO, J. D. P.; SOUZA FILHO, F. A.; MARTINS, E. S. P. R.; STUDART, T. Copula-Based Multivariate Frequency Analysis of the. **water Article**, v. 12, p. 1–22, 2020.
- FREITAS, A. A.; DRUMOND, A.; CARVALHO, V. S. B.; REBOITA, M. S.; SILVA, B. C.; UVO, C. B. Drought Assessment in São Francisco River Basin, Brazil: Characterization through SPI and Associated Anomalous Climate Patterns. **Atmosphere**, v. 13, n. 1, 1 jan. 2022.
- GILLILAND, J. M.; KEIM, B. D. Surface wind speed: trend and climatology of Brazil from 1980–2014. **International Journal of Climatology**, v. 38, n. 2, p. 1060–1073, 2018. Disponível em: <<https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/joc.5237>>.
- GUHA-SAPIR, D.; HARGITT, D.; HOYOS, P. **Thirty Years of Natural Disasters 1974–2003: The Numbers**. Louvain-la-Neuve, Belgium: Presses universitaires de Louvain, 2004.
- HAO, Z.; AGHAKOUCHAK, A.; NAKHJIRI, N.; FARAHMAND, A. Global integrated drought monitoring and prediction system. **Scientific Data**, v. 1, n. 1, p. 140001, 11 dez. 2014.
- HARGREAVES, G. H. Moisture Availability and Crop Production. **Transactions of the ASAE**, v. 18, n. 5, p. 0980–0984, 1975. Disponível em: <<http://elibrary.asabe.org/abstract.asp??JID=3&AID=36722&CID=t1975&v=18&i=5&T=1>>.
- HASTENRATH, S. Circulation and teleconnection mechanisms of Northeast Brazil droughts. **Progress in Oceanography**, v. 70, n. 2–4, p. 407–415, ago. 2006.
- HOFMANN, G. S.; CARDOSO, M. F.; ALVES, R. J. V.; WEBER, E. J.; BARBOSA, A. A.; DE TOLEDO, P. M.; PONTUAL, F. B.; SALLES, L. de O.; HASENACK, H.; CORDEIRO, J. L. P.; AQUINO, F. E.; DE OLIVEIRA, L. F. B. The Brazilian Cerrado is becoming hotter and drier. **Global Change Biology**, v. 27, n. 17, p. 4060–4073, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/gcb.15712>>.
- HUANG, S.; WANG, L.; WANG, H.; HUANG, Q.; LENG, G.; FANG, W.; ZHANG, Y. Spatio-temporal characteristics of drought structure across China using an integrated drought index. **Agricultural Water Management**, v. 218, n. June 2018, p. 182–192, jun. 2019.
- HUANG, Y. F.; ANG, J. T.; TIONG, Y. J.; MIRZAEI, M.; AMIN, M. Z. M. Drought Forecasting using SPI and EDI under RCP-8.5 Climate Change Scenarios for Langat River Basin, Malaysia. **Procedia Engineering**, v. 154, p. 710–717, 2016.
- IBGE. **Censo agropecuário 2017: resultados definitivos**Censo agropecuário. [s.l.: s.n.].
- JEHANZAIB, M.; KIM, T. W. Exploring the influence of climate change-induced drought propagation on wetlands. **Ecological Engineering**, v. 149, n. March, p. 105799, 2020.

JESUS, E. T. de; AMORIM, J. da S.; JUNQUEIRA, R.; VIOLA, M. R.; MELLO, C. R. de. Meteorological and hydrological drought from 1987 to 2017 in Doce River Basin, Southeastern Brazil. **RBRH**, v. 25, p. 1–10, 2020.

JIMÉNEZ-MUÑOZ, J. C.; MATTAR, C.; BARICHIVICH, J.; SANTAMARÍA-ARTIGAS, A.; TAKAHASHI, K.; MALHI, Y.; SOBRINO, J. A.; SCHRIER, G. Van Der. Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015-2016. **Scientific Reports**, v. 6, n. August, p. 1–7, 2016.

JULIANI, B.; OKAWA, C. Application of a Standardized Precipitation Index for Meteorological Drought Analysis of the Semi-Arid Climate Influence in Minas Gerais, Brazil. **Hydrology**, v. 4, n. 2, p. 26, 3 maio 2017.

JUNQUEIRA, R.; VIOLA, M. R.; AMORIM, J. da S.; DE MELLO, C. R. Hydrological response to drought occurrences in a brazilian savanna basin. **Resources**, v. 9, n. 10, p. 1–11, 2020.

KAO, S.-C.; GOVINDARAJU, R. S. A copula-based joint deficit index for droughts. **Journal of Hydrology**, v. 380, n. 1–2, p. 121–134, jan. 2010.

KENDALL, M. G. **Rank Correlation Methods**. [s.l: s.n.]160 p.

KHOURY, S.; COOMES, D. A. Resilience of Spanish forests to recent droughts and climate change. **Global Change Biology**, v. 26, n. 12, p. 7079–7098, 2020.

LI, Y.; HUANG, Y.; LI, Y.; ZHANG, H.; FAN, J.; DENG, Q.; WANG, X. Spatiotemporal heterogeneity in meteorological and hydrological drought patterns and propagations influenced by climatic variability, LULC change, and human regulations. **Scientific Reports**, v. 14, n. 1, 1 dez. 2024.

LIMA, G. C.; RODRIGUES, D. T.; SANTOS E SILVA, C. M.; DE SOUSA COSTA, P. C. Evolution of wind speed observed in Brazil between 1961 and 2020. **International Journal of Climatology**, v. 44, n. 6, p. 1932–1954, 2024. Disponível em: <<https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/joc.8433>>.

LUCAS, M. C.; KUBLIK, N.; RODRIGUES, D. B. B.; MEIRA NETO, A. A.; ALMAGRO, A.; MELO, D. de C. D.; ZIPPER, S. C.; OLIVEIRA, P. T. S. Significant Baseflow Reduction in the Sao Francisco River Basin. **Water**, v. 13, n. 1, 2021. Disponível em: <<https://www.mdpi.com/2073-4441/13/1/2>>.

MADADGAR, S.; AGHAKOUCHAK, A.; FARAHMAND, A.; DAVIS, S. J. Probabilistic estimates of drought impacts on agricultural production. **Geophysical Research Letters**, v. 44, n. 15, p. 7799–7807, 2017. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1002/2017GL073606>>.

MANN, H. B. Nonparametric Tests Against Trend. **Econometrica**, v. 13, n. 3, p. 245–259, 1945. Disponível em: <<http://www.jstor.org/stable/1907187>>.

MARENGO, J. A.; CUNHA, A. P.; CUARTAS, L. A.; DEUSDARÁ LEAL, K. R.; BROEDEL, E.; SELUCHI, M. E.; MICHELIN, C. M.; DE PRAGA BAIÃO, C. F.; CHUCHÓN ÁNGULO, E.; ALMEIDA, E. K.; KAZMIERCZAK, M. L.; MATEUS, N.

P. A.; SILVA, R. C.; BENDER, F. Extreme Drought in the Brazilian Pantanal in 2019–2020: Characterization, Causes, and Impacts. **Frontiers in Water**, v. 3, 23 fev. 2021.

MARENGO, J. A.; TOMASELLA, J.; UVO, C. R. Trends in streamflow and rainfall in tropical South America: Amazonia, eastern Brazil, and northwestern Peru. **Journal of Geophysical Research Atmospheres**, v. 103, n. D2, p. 1775–1783, 1998.

MARTINS, M. A.; COLLSTE, D.; BEZERRA, F. G. S.; MIRANDA, M. A. C. N.; GONÇALVES, A. R.; BARROS, J. D.; CARDOSO, M. F.; SILVINO, A. S.; SONETTI-GONZÁLEZ, T.; OMETTO, J. P. H. B.; VON RANDOW, C.; TOMASELLA, J.; DE AGUIAR, A. P. D. Long-term sustainability of the water-agriculture-energy nexus in Brazil's MATOPIBA region: A case study using system dynamics. **Ambio**, v. 53, n. 12, p. 1722–1736, 2024. Disponível em: <<https://doi.org/10.1007/s13280-024-02058-9>>.

MCKEE, T. B.; DOESKEN, N. J.; KLEIST, J. **The relationship of drought frequency and duration to time scales***Eighth Conference on Applied Climatology*. [s.l: s.n.].

MERESA, H.; MURPHY, C.; DONEGAN, S. E. Propagation and Characteristics of Hydrometeorological Drought Under Changing Climate in Irish Catchments. **Journal of Geophysical Research: Atmospheres**, v. 128, n. 10, 27 maio 2023.

MIGUEZ-MACHO, G.; FAN, Y. The role of groundwater in the Amazon water cycle: 1. Influence on seasonal streamflow, flooding and wetlands. **Journal of Geophysical Research: Atmospheres**, v. 117, n. D15, 2012. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2012JD017539>>.

NABIPOUR, N.; DEGHANI, M.; MOSAVI, A.; SHAMSHIRBAND, S. Short-Term Hydrological Drought Forecasting Based on Different Nature-Inspired Optimization Algorithms Hybridized With Artificial Neural Networks. **IEEE Access**, v. 8, p. 15210–15222, 2020.

NOETZOLD, R.; DE CARVALHO ALVES, M.; NETO, D. C.; MACHADO, A. Q. **Variabilidade espacial de Colletotrichum truncatum em campo de soja sob três níveis de sanidade de sementes***Summa Phytopathologica*. [s.l: s.n.].

OCHOA-RIVERA, J. C. Prospecting droughts with stochastic artificial neural networks. **Journal of Hydrology**, v. 352, n. 1, p. 174–180, 2008. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0022169408000322>>.

OLIVEIRA, P. T. S.; NEARING, M. A.; MORAN, M. S.; GOODRICH, D. C.; WENDLAND, E.; GUPTA, H. V. Trends in water balance components across the Brazilian Cerrado. **Water Resources Research**, v. 50, n. 9, p. 7100–7114, set. 2014.

OLIVEIRA-JÚNIOR, J. F. de; TEODORO, P. E.; SILVA JUNIOR, C. A. da; BAIO, F. H. R.; GAVA, R.; CAPRISTO-SILVA, G. F.; GOIS, G. de; CORREIA FILHO, W. L. F.; LIMA, M.; SANTIAGO, D. de B.; FREITAS, W. K.; SANTOS, P. J. dos; COSTA, M. da S. Fire foci related to rainfall and biomes of the state of Mato Grosso do Sul, Brazil. **Agricultural and Forest Meteorology**, v. 282–283, n. November 2019, p. 107861, mar. 2020.

PALMER, W. C. **Meteorological Drought**. 45. ed. [s.l: s.n.]v. 3058 p.

- PARAJULI, A.; PARAJULI, R.; BANJARA, M.; BHUSAL, A.; DAHAL, D.; KALRA, A. Application of Machine Learning and Hydrological Models for Drought Evaluation in Ungauged Basins Using Satellite-Derived Precipitation Data. **Climate**, v. 12, n. 11, 1 nov. 2024.
- PAREDES-TREJO, F.; BARBOSA, H. A.; GIOVANNETTONE, J.; KUMAR, T. V. L.; THAKUR, M. K.; BURITI, C. de O.; UZCÁTEGUI-BRICEÑO, C. Drought Assessment in the São Francisco River Basin Using Satellite-Based and Ground-Based Indices. **Remote Sensing**, v. 13, n. 19, 2021. Disponível em: <<https://www.mdpi.com/2072-4292/13/19/3921>>.
- PAZ, A. R.; BRAVO, J. M.; ALLASIA, D.; COLLISCHONN, W.; TUCCI, C. E. M. Large-Scale Hydrodynamic Modeling of a Complex River Network and Floodplains. **Journal of Hydrologic Engineering**, v. 15, n. 2, p. 152–165, 2010. Disponível em: <<https://ascelibrary.org/doi/abs/10.1061/%28ASCE%29HE.1943-5584.0000162>>.
- PEÑA-GALLARDO, M.; VICENTE-SERRANO, S. M.; HANNAFORD, J.; LORENZO-LACRUZ, J.; SVOBODA, M.; DOMÍNGUEZ-CASTRO, F.; MANETA, M.; TOMAS-BURGUERA, M.; KENAWY, A. El. Complex influences of meteorological drought time-scales on hydrological droughts in natural basins of the contiguous Unites States. **Journal of Hydrology**, v. 568, p. 611–625, jan. 2019.
- PENEREIRO, J. C.; BADINGER, A.; MACCHERI, N. A.; MESCHIATTI, M. C. Distributions of seasonal average temperature and precipitation trends in Brazilian Biomes. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 97–113, 1 mar. 2018.
- PENG, S.; HUANG, J.; SHEEHY, J. E.; LAZA, R. C.; VISPERAS, R. M.; ZHONG, X.; CENTENO, G. S.; KHUSH, G. S.; CASSMAN, K. G. Rice yields decline with higher night temperature from global warming. **Proceedings of the National Academy of Sciences**, v. 101, n. 27, p. 9971–9975, 6 jul. 2004. Disponível em: <<https://pnas.org/doi/full/10.1073/pnas.0403720101>>.
- PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: fundamentos e aplicações práticas**. [s.l.] Agropecuaria, 2002.
- PORTO DE CARVALHO, J. R.; ASSAD, E. D.; DE OLIVEIRA, A. F.; SILVEIRA PINTO, H. **Annual maximum daily rainfall trends in the midwest, southeast and southern Brazil in the last 71 years** *Weather and Climate Extremes* Elsevier B.V., 2014.
- PRASAD, R.; DEO, R. C.; LI, Y.; MARASENI, T. Input selection and performance optimization of ANN-based streamflow forecasts in the drought-prone Murray Darling Basin region using IIS and MODWT algorithm. **Atmospheric Research**, v. 197, p. 42–63, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169809517303460>>.
- PRIESTLEY, C. H. B.; TAYLOR, R. J. On the Assessment of Surface Heat Flux and Evaporation Using Large-Scale Parameters. **Monthly Weather Review**, v. 100, n. 2, p. 81–92, fev. 1972. Disponível em: <<http://journals.ametsoc.org/doi/abs/10.1175/1520-0493%281972%29100%3C0081%3AOTAOSH%3E2.3.CO%3B2>>.

PRODHAN, F. A.; ZHANG, J.; HASAN, S. S.; PANGALI SHARMA, T. P.; MOHANA, H. P. **A review of machine learning methods for drought hazard monitoring and forecasting: Current research trends, challenges, and future research directions***Environmental Modelling and Software* Elsevier Ltd, 1 mar. 2022.

RODRIGUES, T. R.; CURADO, L. F. A.; PEREIRA, V. M. R.; SANCHES, L.; NOGUEIRA, J. S. Hourly interaction between wind speed and energy fluxes in Brazilian wetlands - Mato Grosso - Brazil. **Anais da Academia Brasileira de Ciencias**, v. 88, n. 4, p. 2195–2209, 2016a.

RODRIGUES, T. R.; VOURLITIS, G. L.; LOBO, F. D. A.; DE OLIVEIRA, R. G.; NOGUEIRA, J. D. S. Seasonal variation in energy balance and canopy conductance for a tropical savanna ecosystem of south central Mato Grosso, Brazil. **Journal of Geophysical Research: Biogeosciences**, v. 119, n. 1, p. 1–13, jan. 2014.

RODRIGUES, T. R.; VOURLITIS, G. L.; LOBO, F. de A.; SANTANNA, F. B.; DE ARRUDA, P. H. Z.; NOGUEIRA, J. de S. Modeling canopy conductance under contrasting seasonal conditions for a tropical savanna ecosystem of south central Mato Grosso, Brazil. **Agricultural and Forest Meteorology**, v. 218–219, p. 218–229, mar. 2016b.

SATTAR, M. N.; KIM, T. W. Probabilistic characteristics of lag time between meteorological and hydrological droughts using a Bayesian model. **Terrestrial, Atmospheric and Oceanic Sciences**, v. 29, n. 6, p. 709–720, 1 dez. 2018.

SEN, P. K. Estimates of the Regression Coefficient Based on Kendall's Tau. **Journal of the American Statistical Association**, v. 63, n. 324, p. 1379–1389, 1 dez. 1968. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01621459.1968.10480934>>.

SEO, J. Y.; LEE, S.-I. Spatio-Temporal Groundwater Drought Monitoring Using Multi-Satellite Data Based on an Artificial Neural Network. **Water**, v. 11, n. 9, 2019. Disponível em: <<https://www.mdpi.com/2073-4441/11/9/1953>>.

SHAMSHIRBAND, S.; HASHEMI, S.; SALIMI, H.; SAMADIANFARD, S.; ASADI, E.; SHADKANI, S.; KARGAR, K.; MOSAVI, A.; NABIPOUR, N.; CHAU, K.-W. Predicting Standardized Streamflow index for hydrological drought using machine learning models. **Engineering Applications of Computational Fluid Mechanics**, v. 14, n. 1, p. 339–350, 1 jan. 2020. Disponível em: <<https://doi.org/10.1080/19942060.2020.1715844>>.

SHEFFIELD, J.; WOOD, E. F.; RODERICK, M. L. Little change in global drought over the past 60 years. **Nature**, v. 491, n. 7424, p. 435–438, 2012. Disponível em: <<https://doi.org/10.1038/nature11575>>.

SHI, W.; XIAO, G.; STRUIK, P. C.; JAGADISH, K. S. V; YIN, X. Quantifying source-sink relationships of rice under high night-time temperature combined with two nitrogen levels. **Field Crops Research**, v. 202, p. 36–46, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378429016301848>>.

SHIAU, J. T. Causality-based drought propagation analyses among meteorological drought, hydrologic drought, and water shortage. **Science of the Total Environment**, v. 888, 25 ago. 2023.

SHUKLA, S.; WOOD, A. W. Use of a standardized runoff index for characterizing hydrologic drought. **Geophysical Research Letters**, v. 35, n. 2, 2008. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/2007GL032487>>.

SILVA, M. E. S.; PEREIRA, G.; DA ROCHA, R. P. Local and remote climatic impacts due to land use degradation in the Amazon “Arc of Deforestation”. **Theoretical and Applied Climatology**, v. 125, n. 3, p. 609–623, 2016. Disponível em: <<https://doi.org/10.1007/s00704-015-1516-9>>.

SILVA, V. O.; DE MELLO, C. R.; CHOU, S. C.; GUO, L.; VIOLA, M. R. Characteristics of extreme meteorological droughts over the Brazilian Pantanal throughout the 21st century. **Frontiers in Water**, v. 6, 2024.

SO, J.-M.; LEE, J.-H.; BAE, D.-H. Development of a Hydrological Drought Forecasting Model Using Weather Forecasting Data from GloSea5. **Water**, v. 12, n. 10, 2020. Disponível em: <<https://www.mdpi.com/2073-4441/12/10/2785>>.

SOLH, M.; VAN GINKEL, M. Drought preparedness and drought mitigation in the developing world's drylands. **Weather and Climate Extremes**, v. 3, p. 62–66, jun. 2014.

SORRIBAS, M. V.; PAIVA, R. C. D.; MELACK, J. M.; BRAVO, J. M.; JONES, C.; CARVALHO, L.; BEIGHLEY, E.; FORSBERG, B.; COSTA, M. H. Projections of climate change effects on discharge and inundation in the Amazon basin. **Climatic Change**, v. 136, n. 3–4, p. 555–570, 9 jun. 2016.

SUHANA, L.; TAN, M. L.; LUHAIM, Z.; RAMLI, M. H. P.; SUBKI, N. S.; TANGANG, F.; ISHAK, A. M. Spatiotemporal characteristics of hydro-meteorological droughts and their connections to large-scale atmospheric circulations in the Kelantan River Basin, Malaysia. **Water Supply**, v. 23, n. 6, p. 2283–2298, 1 jun. 2023.

SUNDARARAJAN, K.; GARG, L.; SRINIVASAN, K.; BASHIR, A. K.; KALIAPPAN, J.; GANAPATHY, G. P.; SELVARAJ, S. K.; MEENA, T. **A contemporary review on drought modeling using machine learning approaches** CMES - Computer Modeling in Engineering and Sciences Tech Science Press, 2021.

THEIL, H. A Rank-Invariant Method of Linear and Polynomial Regression Analysis. *Em: RAJ BALDEV AND KOERTS, J. Henri Theil's Contributions to Economics and Econometrics: Econometric Theory and Methodology*. Dordrecht: Springer Netherlands, 1992. p. 345–381.

THIELEN, D.; SCHUCHMANN, K.-L.; RAMONI-PERAZZI, P.; MARQUEZ, M.; ROJAS, W.; QUINTERO, J. I.; MARQUES, M. I. Quo vadis Pantanal? Expected precipitation extremes and drought dynamics from changing sea surface temperature. **PLOS ONE**, v. 15, n. 1, p. e0227437, 7 jan. 2020.

TORRES, R. R.; LAPOLA, D. M.; GAMARRA, N. L. R. Future climate change in the Caatinga. *Em: Caatinga: The Largest Tropical Dry Forest Region in South America*. [s.l.] Springer International Publishing, 2018. p. 383–410.

TOUMA, D.; ASHFAQ, M.; NAYAK, M. A.; KAO, S.-C.; DIFFENBAUGH, N. S. A multi-model and multi-index evaluation of drought characteristics in the 21st century. **Journal of Hydrology**, v. 526, p. 196–207, jul. 2015.

VALLE JÚNIOR, L. C. G. do; VOURLITIS, G. L.; CURADO, L. F. A.; PALÁCIOS, R. da S.; NOGUEIRA, J. de S.; LOBO, F. de A.; ISLAM, A. R. M. T.; RODRIGUES, T. R. Evaluation of FAO-56 Procedures for Estimating Reference Evapotranspiration Using Missing Climatic Data for a Brazilian Tropical Savanna. **Water**, v. 13, n. 13, 2021. Disponível em: <<https://www.mdpi.com/2073-4441/13/13/1763>>.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY: Springer New York, 2000.

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**, v. 23, n. 7, p. 1696–1718, abr. 2010.

WMO. **Standardized Precipitation Index - User Guide** (M. Svoboda, M. Hayes, D. Wood). [s.l: s.n.].

WU, J.; ZHANG, X.; WANG, G.; WU, W.; ZHANG, D.; LAN, T. Impacts of hydrometeorological regime shifts on drought Propagation: The meteorological to hydrological perspective. **Journal of Hydrology**, v. 638, 1 jul. 2024.

YERDELEN, C.; ABDELKADER, M.; ERIS, E. Assessment of drought in SPI series using continuous wavelet analysis for Gediz Basin, Turkey. **Atmospheric Research**, v. 260, p. 105687, 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169809521002398>>.

ZHANG, D.-D.; YAN, D.-H.; LU, F.; WANG, Y.-C.; FENG, J. Copula-based risk assessment of drought in Yunnan province, China. **Natural Hazards**, v. 75, n. 3, p. 2199–2220, 13 fev. 2015.

ZHANG, T.; SU, X.; WU, L.; CHU, J. Identification of dynamic drought propagation from a nonstationary perspective and its application to drought warnings. **Journal of Hydrology**, v. 626, 1 nov. 2023.

ZHAO, W.; WU, J.; DU, E.; DENG, X.; SUN, G.; WANG, G. Deciphering the influence of climate change and human activities on the drought propagation. **Journal of Hydrology: Regional Studies**, v. 51, 1 fev. 2024.

ZHOU, J.; DEITCH, M. J.; GRUNWALD, S.; SCREATON, E. Do the Mann-Kendall test and Theil-Sen slope fail to inform trend significance and magnitude in hydrology? **Hydrological Sciences Journal**, v. 68, n. 9, p. 1241–1249, 4 jul. 2023. Disponível em: <<https://doi.org/10.1080/02626667.2023.2212166>>.

ZOU, R.; YIN, Y.; WANG, X.; ZHANG, Z.; MA, X.; LIU, M.; ULLAH, I. Characteristics and propagation of meteorological and hydrological droughts in eastern Gansu, a typical semi-arid region, China. **International Journal of Climatology**, v. 43, n. 12, p. 5327–5347, 1 out. 2023.