

O USO DE MACHINE LEARNING NA PREVISÃO DE SECAS EM DIFERENTES ESCALAS DE TEMPO

João V. S. Ribeiro¹ (IC), Sandro C. Izidoro¹ (PQ)

¹ Universidade Federal de Itajubá - Campus Theodomiro Carneiro Santiago

Palavras-chave: Machine Learning. Secas. Predição. Rede neural. Inteligência artificial. Clima.

Introdução

As secas são fenômenos climáticos severos, com impactos econômicos e sociais significativos. De acordo com o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN, 2024), uma seca é caracterizada por uma prolongada ausência de precipitação, com a perda de umidade do solo superando sua reposição. No Brasil, o semiárido do Nordeste é a região mais vulnerável, afetando nove estados, onde a agricultura familiar depende do sequeiro. A estiagem causa perdas de safras e rebanhos, impactando a economia regional.

Esta pesquisa aplica a ferramenta desenvolvida por Duarte (2023) para prever secas na região Norte de Minas Gerais, utilizando algoritmos de clustering para agrupar áreas com base em características climáticas. Um modelo específico será testado e ajustado para um município da região, para posteriormente testá-lo nos demais municípios limítrofes, permitindo uma avaliação mais precisa dos padrões de seca e contribuindo para estratégias de mitigação mais eficazes.

Metodologia

A metodologia adotada nesta pesquisa é organizada em etapas sequenciais, visando a construção e calibração de um modelo de Rede Neural Recorrente para a previsão de secas na região Norte de Minas Gerais.

Inicialmente, foram coletados dados de satélites referentes à região, abrangendo informações climáticas e ambientais relevantes. Com os dados coletados, foram geradas tabelas para cada município, organizando as informações em coordenadas geográficas específicas.

Em seguida, aplicaram-se técnicas de clustering para agrupar os municípios com base em suas características climáticas. Essa etapa permite identificar padrões e semelhanças entre as localidades.

O próximo passo consistiu na construção do modelo de

Rede Neural Recorrente. Foram realizados testes de predição do SPEI em diferentes municípios da região. A calibração da Rede Neural foi feita alterando parâmetros como o número de neurônios, camadas e entradas, a fim de otimizar o desempenho do modelo.

Por fim, foram confeccionados gráficos e elementos visuais para facilitar a análise dos resultados obtidos, permitindo uma melhor interpretação dos dados.

Esta abordagem é fundamentada nos estudos de Ribeiro (2024), que analisaram e previram secas no Norte de Minas Gerais utilizando *machine learning*, e proporcionaram uma base sólida para a aplicação das técnicas propostas.

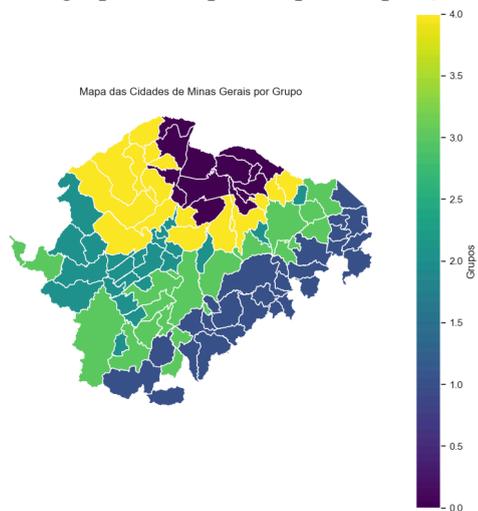
Resultados e discussão

Neste capítulo, serão apresentados os resultados obtidos a partir da predição do SPEI para diversos municípios da região Norte de Minas Gerais. Aqui, destacam-se apenas alguns resultados, sendo o relatório completo disponibilizado no documento oficial.

Os agrupamentos com base na média dos índices climáticos da região apresentaram comportamento semelhante à distribuição do índice usado por eles, sendo a média do SPEI mais dispersa por levar muitos fatores para seu cálculo.

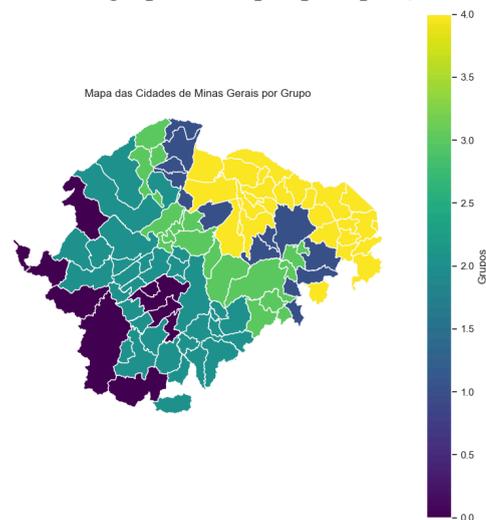
Após a análise dos dados foi escolhido o município de São João da Ponte para ser utilizado como modelo, tanto por sua posição geográfica como pelos resultados do estudo de Ribeiro (2024), onde ele foi o modelo mais eficaz na predição de secas. Após o treinamento o modelo escolhido foi utilizado para realizar a predição dos demais municípios limítrofes.

Figura 1 – Agrupamento por evapotranspiração média.



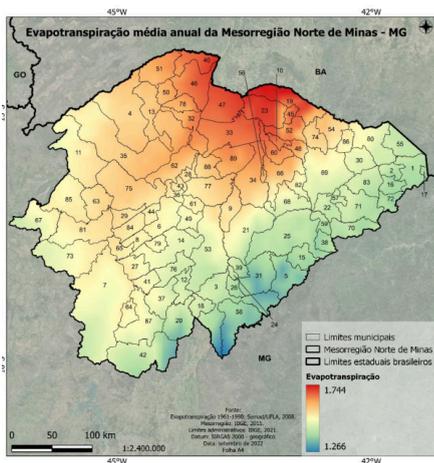
Fonte: O autor.

Figura 3 – Agrupamento por precipitação média.



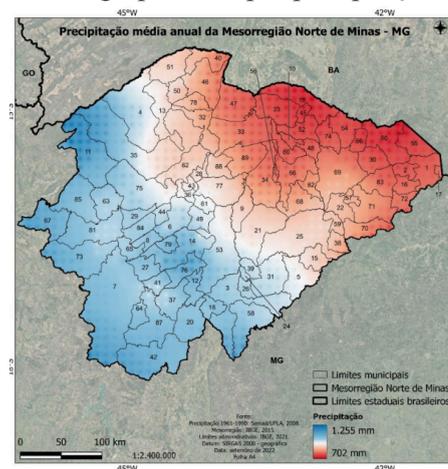
Fonte: O autor.

Figura 2 – Agrupamento por precipitação média.



Fonte: Adaptado de Ribeiro (2024).

Figura 4 – Agrupamento por precipitação média.



Fonte: Adaptado de Ribeiro (2024).

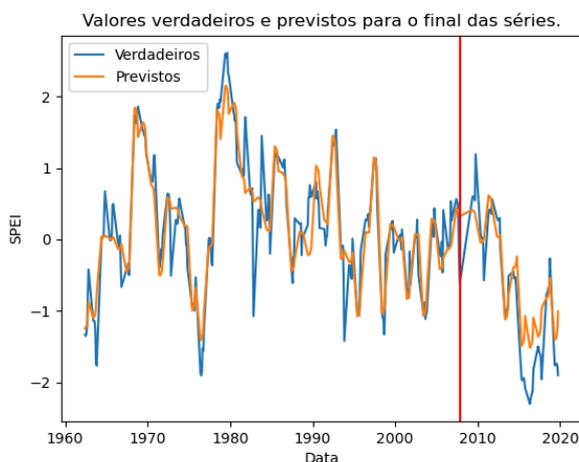
A Figura 1 representa o agrupamento utilizando os índices de evapotranspiração média e a Figura 2 é o mapa da região com sua evapotranspiração média anual.

Já as figuras 3 e 4 representam o agrupamento e o mapa utilizando a precipitação média da região, respectivamente.

A Figura 5 representa a predição do SPEI em laranja e os dados reais em azul, é possível observar que a curva laranja acompanha o comportamento da curva azul porém sem manter uma exatidão extrema, indicando que a rede teve êxito no treinamento e não possui overfitness. No período de transição entre os dados utilizados para treinamento e os dados de teste houve um erro brusco, esse erro acentuado, que no entanto, não se mantém.

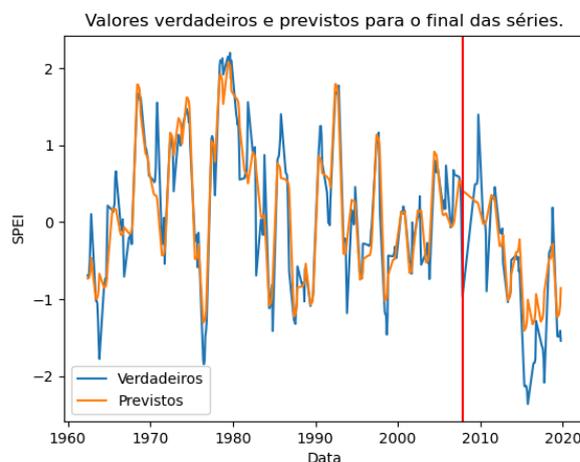
A figura 6 representa a distribuição do SPEI, os pontos em cima da linha representam o acerto na predição enquanto os pontos mais separados e distantes representam um maior erro.

Figura 5 – Predição de São João da Ponte



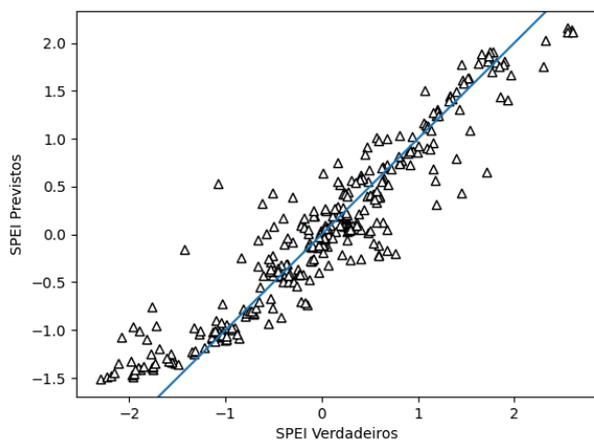
Fonte: O autor.

Figura 7 – Predição de Capitão Enéas.



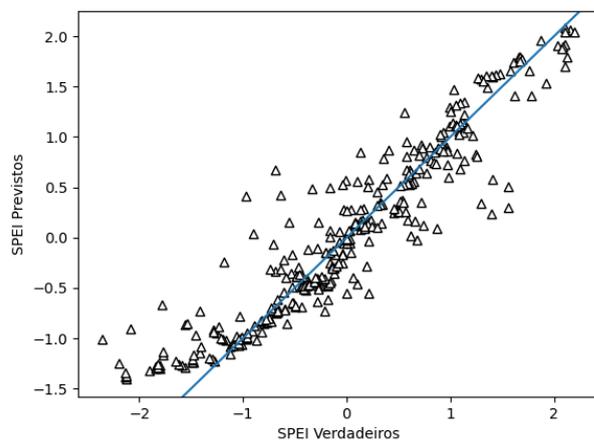
Fonte: O autor.

Figura 6 – Distribuição do SPEI de São João da Ponte.



Fonte: O autor.

Figura 8 – Distribuição do SPEI de Capitão Enéas.



Fonte: O autor.

O procedimento foi repetido para os outros municípios, Capitão Enéas, Ibiracatu, Janaúba, Japonvar, Lontra, Montes Claros, Patis, Varzelândia e Verdelândia, utilizando São João da Ponte como modelo de treinamento.

A Figura 7 e a Figura 8 apresentam um dos resultados encontrados para o município de Capitão Enéas. Apesar do modelo não ter treinado com os dados dos outros municípios, apresentou resultados satisfatórios

A Tabela 1 apresenta as métricas para predição de cada município, apresentando em vermelho os piores valores para cada métrica e em verde os melhores resultados.

Tabela 1 - Resultados de Treinamento (•) e Validação (★)

Município	MAE •	MAE ★	RMSE •	RMSE ★	MSE •	MSE ★	R ² •	R ² ★
SÃO JOÃO DA PONTE	0,0418	0,0604	0,0609	0,0779	0,0037	0,0061	0,8697	0,8177
CAPITÃO ENÉAS	0,0432	0,0637	0,0644	0,0892	0,0042	0,0080	0,8747	0,7538
IBIRACATU	0,0473	0,0661	0,0708	0,0861	0,0050	0,0074	0,8696	0,8069
JANAÚBA	0,0532	0,0428	0,0777	0,0619	0,0060	0,0038	0,8353	0,8214
JAPONVAR	0,0599	0,0685	0,0895	0,0901	0,0080	0,0081	0,7976	0,8772
LONTRA	0,0600	0,0676	0,0901	0,0885	0,0081	0,0078	0,8008	0,8615
MONTES CLAROS	0,0442	0,0551	0,0661	0,0803	0,0044	0,0064	0,8608	0,7608
PATIS	0,0513	0,0693	0,0741	0,0913	0,0055	0,0083	0,8386	0,7962
VARZELÂNDIA	0,0413	0,0634	0,0623	0,0835	0,0039	0,0070	0,8882	0,8076
VERDELÂNDIA	0,0459	0,0540	0,0696	0,0758	0,0048	0,0057	0,8518	0,7959

Fonte: O autor.

Conclusões

Durante o desenvolvimento desta pesquisa, foram implementadas diversas soluções em Python para analisar as características climáticas da região do Norte de Minas Gerais e agrupar os dados com base em padrões como o SPEI, média de evaporação e precipitação. Após a predição para os municípios de Capitão Enéas, Ibiracatu, Janaúba, Japonvar, Lontra, Montes Claros, Patis, Varzelândia e Verdelândia, utilizando São João da Ponte como modelo de treinamento, avaliou-se a eficácia do modelo proposto.

(Mestrado em Engenharia da Computação) — Universidade Federal de Itajubá, Itabira, 2024.

A rede neural recorrente mostrou um desempenho satisfatório na predição do SPEI, embora não tenha se destacado em todas as métricas, indicando a necessidade de ajustes e aprimoramentos. Apesar disso, a abordagem abre caminho para novos estudos que considerem não apenas as características climáticas, mas também outras variáveis relevantes. Essa expansão pode contribuir para um modelo mais abrangente, capaz de capturar a complexidade das interações climáticas entre os municípios, já que o algoritmo se mostrou eficaz ao prever dados de um município e suas localidades limítrofes.

Agradecimentos

Agradecemos à Universidade Federal de Itajubá (Unifei) pelo apoio institucional crucial ao longo deste trabalho de pesquisa. A Unifei proporcionou recursos e um ambiente acadêmico propício à realização deste estudo.

Também estendemos nossos agradecimentos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo generoso financiamento que tornou possível a execução deste projeto. Seu suporte financeiro foi fundamental para o sucesso deste trabalho.

Por fim, gostaríamos de expressar nossa apreciação a todas as pessoas que, de alguma forma, contribuíram para o desenvolvimento deste projeto.

Referências

Centro Nacional de Monitoramento e Alertas de Desastres Naturais - CEMADEN. Secas. 2024. Disponível em: <http://www2.cemaden.gov.br/secas/>. Acesso em: 03 set. 2024.

DUARTE, L. H. B. Previsão de secas na região Norte de Minas Gerais utilizando Rede Neural Recorrente. Itabira, MG: [s.n.], 2023. Trabalho apresentado em 12 de outubro de 2023.

RIBEIRO, P. L. Análise e previsão de secas no Norte de Minas Gerais utilizando machine learning. 2024. Dissertação