

COMPARAÇÃO DE MÉTODOS DE CORREÇÃO DE VIÉS EM DADOS SIMULADOS DO MODELO BRAMS: TEMPERATURA DO AR (2 METROS)

Milena Pereira Dantas^{1,2,4}; **Haroldo Fraga de Campos Velho**³; **Alan Carlos da Costa**^{2,5}; **Leandro Rodrigues da Silva Souza**²

¹Pós-Doutorado em Ciências Agrárias. Ciências Agrárias - Agronomia, Instituto Federal Goiano . Rodovia Sul Goiana, km 01, Zona Rural. | Rio Verde - GO | CEP: 75.901-970;²Pesquisador. Centro de Excelência em Agricultura Exponencial, CEAGRE. Rodovia Sul Goiana, km 01, Zona Rural. | Rio Verde - GO | CEP: 75.901-970;³Pesquisador. Laboratório de Computação e Matemática Aplicada (LAC), Instituto Nacional de Pesquisas Espaciais. Av. dos Astronautas, 1758 , São José dos Campos;⁴Pesquisador. Centro de Excelência em Estudos, Monitoramento e Previsões Ambientais do Cerrado (CEMPA-Cerrado). Avenida Esperança, s/n, Câmpus Samambaia, 74.690-900.;⁵Professor. Ciências Agrárias - Agronomia, Instituto Federal Goiano. Rodovia Sul Goiana, km 01, Zona Rural. | Rio Verde - GO | CEP: 75.901-970

RESUMO

Esse estudo avalia a eficácia de diferentes métodos de correção de viés nas simulações de temperatura do ar simuladas pelo modelo BRAMS. Foram comparados os métodos de correção de viés Scaling-linear, Delta, Model Output Statistic (MOS) e Redes Neurais Artificiais (RN-MPCA). Foram utilizados dados observados de temperatura do ar em estações meteorológicas no estado de Goiás, Brasil, durante o período de janeiro a dezembro de 2023. Com o objetivo de capturar variações de temperatura e entender melhor como os métodos de remoção de viés se comportam em cada estação do ano. Os resultados mostram que todos os métodos são eficazes em determinados meses, mas nenhum deles é consistentemente eficaz em todas as estações do ano e locais. O método RN-MPCA, em particular, demonstrou grande potencial, mas ainda necessita de ajustes para maximizar seu desempenho.

PALAVRAS-CHAVE: simulações; Scaling-linear; Delta; Redes Neurais Artificiais;

INTRODUÇÃO

O modelo BRAMS foi baseado do Regional Atmospheric Modeling System (RAMS), desenvolvido no CSU/EUA. Foi desenvolvido com o propósito de simular circulações atmosféricas que vão desde ondas em escalas planetárias até grandes turbilhões na camada limite planetária (GRELL, FREITAS, 2014). Apesar do grande desenvolvimento do modelo BRAMS, as simulações ainda apresentam vieses nos resultados. Teutschbein e Seibet (2012) revelaram que grande da presença dos vieses nos resultados das simulações tem sua origem na discretização dos modelos numéricos.

Diversas metodologias são utilizadas para corrigir o viés em simulações de modelos regionais. Essas técnicas variam desde escalonamento simples até abordagens mais complexas, como o Método Delta, Scaling-linear, regressão linear múltipla e através de redes neurais (GETAHUN et al., 2021; HAYKIN, 1998). Luo et al. (2018) compararam diferentes métodos de correção de viés e concluíram que todos os métodos testados melhoraram o desempenho das simulações de temperatura e precipitação no modelo RCM. SHI et al. (2021) aplicaram os métodos de mapeamento quantil e mapeamento quantil delta nas simulações de temperatura e precipitação na China durante o verão e inverno usando o modelo RegCM4, observando que a eficácia dos métodos varia conforme a variável e a estação do ano. Dantas et al. (2022) analisaram três métodos de remoção de viés (Delta, Scaling-linear e Model Output Statistic (MOS)) para simulações de temperatura do ar no centro-oeste, entre janeiro e agosto de 2022. Concluíram que o método scaling apresentou os melhores resultados. Dando continuidade ao trabalho, Dantas et al. (2023) compararam esses métodos com o resultado via redes neurais artificiais para o verão de 2023, os resultados sugerem que as metodologias de Delta, *Scaling-linear* e Redes Neurais são eficazes na correção das previsões do modelo BRAMS para diferentes áreas na região.

As condições climáticas podem variar significativamente de um mês para o outro, mesmo dentro da mesma estação. Por exemplo, a transição do verão para o outono pode apresentar variações bruscas de temperatura. O monitoramento mês a mês permite capturar essas variações e entender melhor como os métodos de remoção de viés se comportam em diferentes condições climáticas.

OBJETIVOS

Avaliar a eficácia dos métodos de remoção de viés (Delta, Scaling-linear, MOS e Redes Neurais Artificiais (RN-MPCA)) nas previsões de temperatura do ar simuladas pelo modelo BRAMS na região Centro-Oeste do Brasil, por uma análise detalhada mês a mês e uma comparação sazonal para o ano de 2023.

MATERIAL E MÉTODOS

Dados e configuração do modelo BRAMS

A tabela 1 apresenta as principais configurações do modelo BRAMS utilizadas para simular a temperatura do ar na região Centro-Oeste do Brasil.

Tabela 1. Informações sobre a configuração do modelo BRAMS

Características	Configuração	Referências
Resolução Horizontal	320x320 pontos	
Níveis Verticais	45	Souza et al. (2020)
Dados de Cobertura do Solo	MapBiomass	
Parametrização de Cúmulos	Grell e Freitas (2014)	Grell & Freitas (2014)
Microfísica de Nuvens	Esquema de um momento de Thompson e Eidhammer (2014)	Thompson & Eidhammer (2014)
Condições Iniciais e de Contorno	Global Forecast System (GFS)	
Domínio de Integração	Todo o estado de Goiás e parte dos estados vizinhos (55°W-43°W e 9°S-21°S)	

Dados observados

Observações de temperatura do ar a 2 metros foram coletadas de estações meteorológicas localizadas em aeroportos no estado de Goiás, durante o período de janeiro a dezembro de 2023. A Tabela 2 apresenta as localizações e informações sobre as estações meteorológicas utilizadas.

Tabela 2. Informações sobre as estações meteorológicas

Código aeroportuário	Estações	Latitude (°)	Longitude (°)	Altitude (m)
SBBR	Brasília	-15,87	-47,92	1061
SBAN	Anápolis	-16,24	-48,97	1137
SBGO	Goiânia	-16,67	-48,26	741

Métodos de correção de viés: Scaling-linear, delta, Model Output Statistic (MOS) e rede neural utilizando o MPCA (RN-MPCA)

Informações detalhadas sobre os métodos de correção de viés foram fornecidas em Dantas et al. (2022) e Dantas et al. (2023), incluindo uma descrição abrangente de como os dados foram utilizados em cada abordagem. Esses estudos apresentam uma análise aprofundada das técnicas de remoção de viés, como o Scaling-linear, Delta, MOS e RN-MPCA, demonstrando o processo de aplicação e avaliação dos métodos utilizando dados de temperatura observados e previstos pelo modelo BRAMS.

Avaliação dos resultados

O desempenho de cada método de correção de viés é avaliado com base no BIAS e no erro Absoluto Médio (MAE) (SPIEGEL; STEPHENS, 1993).

O BIAS é uma medida que avalia o viés médio nas simulações em relação aos dados observados. Representa a tendência sistemática do modelo em superestimar ou subestimar os resultados. Se o BIAS é igual a zero, isto indica não haver viés nas previsões. A fórmula do BIAS é dada:

⇒ Eq. (13)
O módulo diferença entre os valores observado e simulado define a precisão da previsão. Assim, a precisão numérica é denotada por MAE e é descrita por:

⇒ Eq. (14)
em que, Y_{oi} e Y_{si} representam os valores observados e simulados no passo no i -ésimo tempo, respectivamente, e \hat{Y}_s se refere aos valores médios para as variáveis simuladas, respectivamente, sendo N o número de observações.

RESULTADOS E DISCUSSÃO

As Figuras 1, 2 e 3 mostram o comportamento médio diário mensal e a aplicação dos métodos de remoção de viés da temperatura do ar a 2 metros (t_{2mj}) durante o ano de 2023 para as cidades de Brasília, Anápolis e Goiânia, respectivamente. Os resultados médios dos ciclos diurnos revelam que as simulações do modelo BRAMS apresentam uma subestimativa da temperatura do ar (2 metros) para Brasília (Figura 1), Anápolis (Figura 2) e Goiânia (Figura 3), principalmente durante o período de maior aquecimento da superfície (tarde) (SHRESTHA et al., 2019). Os vieses em modelos numéricos de previsão do tempo podem originar-se de várias maneiras: simplificações inadequadas das equações atmosféricas, representações insuficientes de processos físicos complexos e falhas na assimilação de dados observacionais (VAZ, 2021; AVILEZ-VALENTE et al., 2022; YAMAMOTO; SAMBATI; FERREIRA, 2022). Esses vieses comprometem a confiabilidade das previsões, influenciando as decisões que dependem delas. A compreensão desses vieses é fundamental para o processo de aprimoramento contínuo dos modelos, visando à melhoria da precisão das previsões meteorológicas (BAHNG et al., 2020).

Os resultados para Brasília (Figura 1) mostraram que o método MOS (pontos contínuos rosa) apresentou um desempenho significativo na maioria dos meses, sendo dezembro a única exceção com resultados menos favoráveis. Por outro lado, a técnica Delta (linha vermelha) apresentou os melhores resultados durante o final do outono e inverno (maio, junho, julho e agosto). E os piores resultados aconteceram durante o verão. O método Scaling-linear (linha verde) alcançou melhores resultados nos meses de abril, junho, setembro, novembro e dezembro. Com aplicação de redes neurais (linhas tracejadas) em Brasília, nota-se que, nos meses de janeiro, fevereiro, junho, julho, agosto e setembro, obteve a temperatura corrigida mais próxima da observada. Entretanto, é importante observar que em abril, a rede neural com número de funções de avaliação (NFE) de 50 (NFE=50) apresentou resultado constante.

Os resultados de Anápolis (Figura 2) para método Delta (linha vermelha) destacam-se, mostrando que a linha da temperatura corrigida por esse método está mais próxima da observada nos meses de abril, maio, junho, julho, agosto, outubro e dezembro. O método Scaling-linear, por sua vez, demonstra eficácia em agosto, setembro, outubro, dezembro e novembro (fora do horário de aquecimento). Notavelmente, o método MOS (pontos rosa) exibe um desempenho superior durante o verão, aproximando-se mais dos valores observados. As redes neurais (RN) apresentam resultados superiores em quase todos os meses, indicando sua capacidade de aprendizado e adaptação aos padrões climáticos específicos de Anápolis. Vale ressaltar uma peculiaridade nos resultados da RN em dezembro, onde a configuração com NFE=50 mostra-se constante, e em setembro, apenas a configuração com NFE=500 apresenta resultados significativos.

Para Goiânia (Figura 3), o método MOS se destacou ao apresentar os melhores resultados no verão (janeiro e fevereiro). A técnica Scaling-linear (linha verde) demonstrou sua eficácia ao longo do segundo semestre, apresentando os melhores resultados de agosto a dezembro. O método Delta (linha vermelha) mostrou proximidade com as observações nos meses de maio, junho, julho e agosto (parte do outono e inverno). É notável que a rede neural se destacou nos meses de verão. No entanto, é intrigante observar que a rede neural apresentou valores constantes na maioria dos meses, especialmente de agosto a novembro.

Nos experimentos realizados com RN-MPCA, o NFE foi ajustado para corrigir o ciclo diurno da temperatura, sendo observado que em algumas rodadas as previsões permaneceram constantes. Para o NFE baixo, esse comportamento pode ser atribuído à convergência prematura do modelo, onde um NFE insuficiente não permitiu uma otimização adequada, resultando em previsões subótimas. Além disso, configurações inadequadas do algoritmo de otimização e possíveis estagnações em mínimos locais também podem ter contribuído para esse resultado. Estes achados concordam com estudos prévios que destacam a importância do NFE na eficácia do treinamento de RN (Goodfellow et al., 2016). Através da análise desses resultados, fica evidente que o ajuste apropriado do NFE é crucial para capturar com precisão variações do ciclo diurno da temperatura.

Os resultados das avaliações estatísticas dos métodos de correção de viés para as cidades de Brasília, Anápolis, e Goiânia ao longo do ano de 2023 confirmam que a aplicação dessas técnicas contribuiu significativamente para a melhoria da precisão nas previsões de temperatura do ar a 2 metros. Devido ao volume extenso de dados, a tabela não foi mostrada. Para Brasília, o método RN-MPCA demonstrou um desempenho consistente ao longo do ano, apresentou valores de BIAS e MAE baixos, com destaque os meses de verão, onde o BIAS e o MAE foram menores que 1, refletindo uma previsão bastante próxima da observada. O método Delta teve melhor desempenho nos meses de outono e inverno, com o menor MAE em abril ($0,437^{\circ}\text{C}$). O método Scaling-linear mostrou os melhores resultados em meses de verão, com MAEs variando de $0,8^{\circ}\text{C}$ a $1,3^{\circ}\text{C}$. Já as redes neurais (RN), principalmente com NFE=300, se destacaram em janeiro com um MAE de $0,62^{\circ}\text{C}$, sendo o mais próximo das observações. Os resultados para Anápolis indicam que o método Delta foi eficaz em meses de verão e outono, apresentando um MAE de $0,64^{\circ}\text{C}$ a $1,53^{\circ}\text{C}$, se aproximando bastante dos valores observados. O MOS também apresentou um bom desempenho, especialmente durante o verão, com destaque em janeiro, onde o BIAS foi $0,79^{\circ}\text{C}$ e o MAE foi de $0,93^{\circ}\text{C}$. As redes neurais também mostraram bons resultados, especialmente em março, com NFE=50, onde o MAE foi $1,01^{\circ}\text{C}$, mais próximo das observações. Para Goiânia, o método MOS obteve os melhores resultados durante o verão, com um MAE entre $1,21^{\circ}\text{C}$ e $1,70^{\circ}\text{C}$. O Scaling-linear se destacou no primeiro semestre, especialmente em janeiro a abril. O método Delta foi eficaz durante os meses de verão, onde o MAE foi $1,70^{\circ}\text{C}$. As redes neurais, embora com resultados variáveis, mostraram-se eficazes principalmente em dezembro, com o NFE=50 alcançando MAE de $0,92^{\circ}\text{C}$.

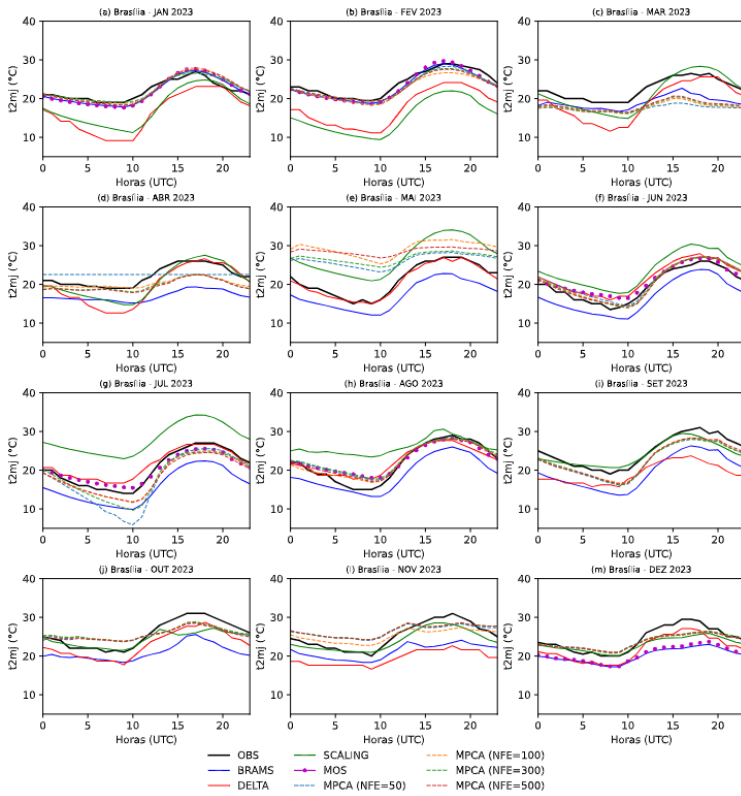


Figura 1. Comparação dos métodos de correção de viés aplicados à temperatura do ar (2m) em Brasília durante o ano de 2023.

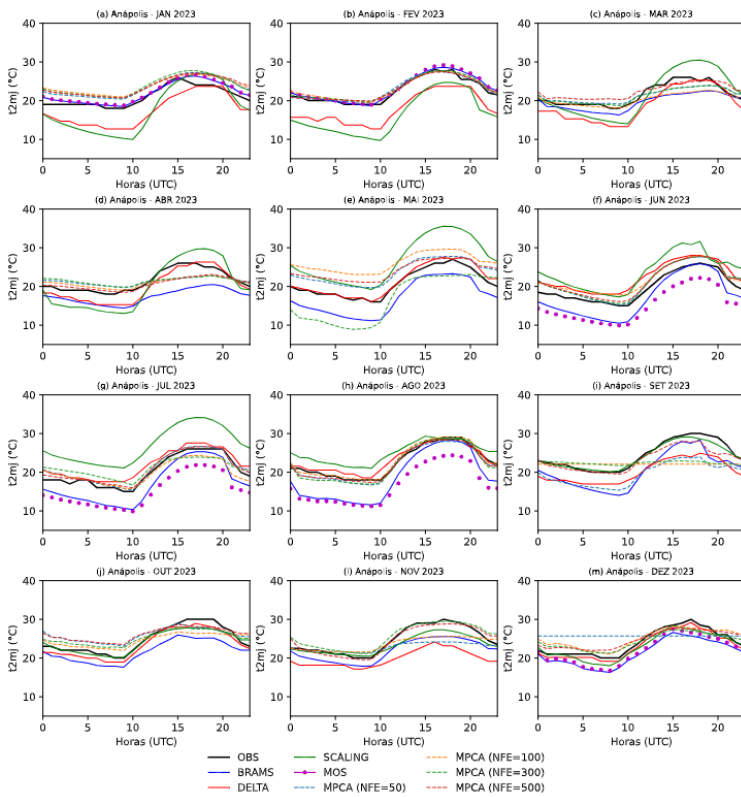


Figura 2. Comparação dos métodos de correção de viés aplicados à temperatura do ar (2m) em Anápolis durante o ano de 2023.

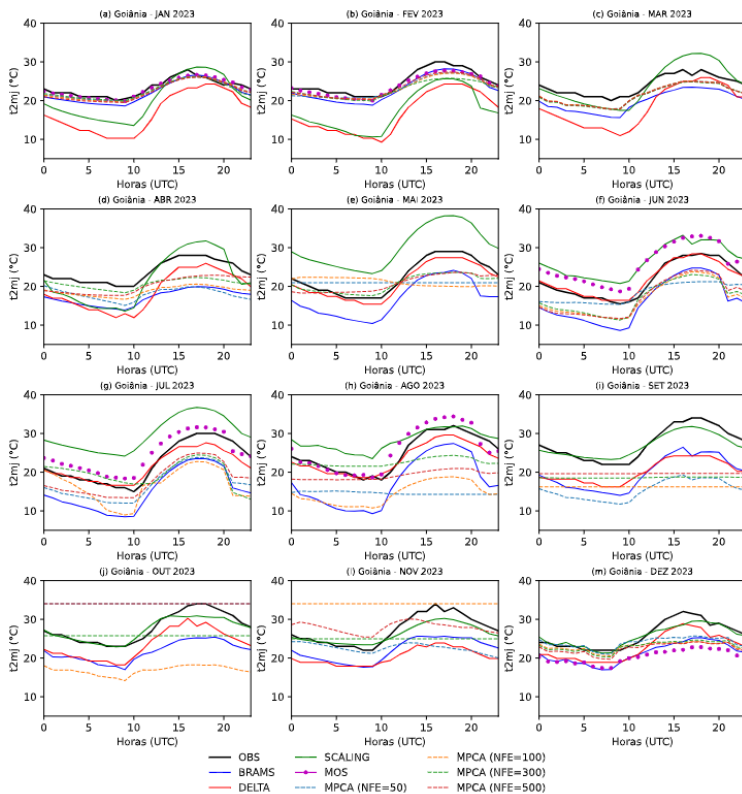
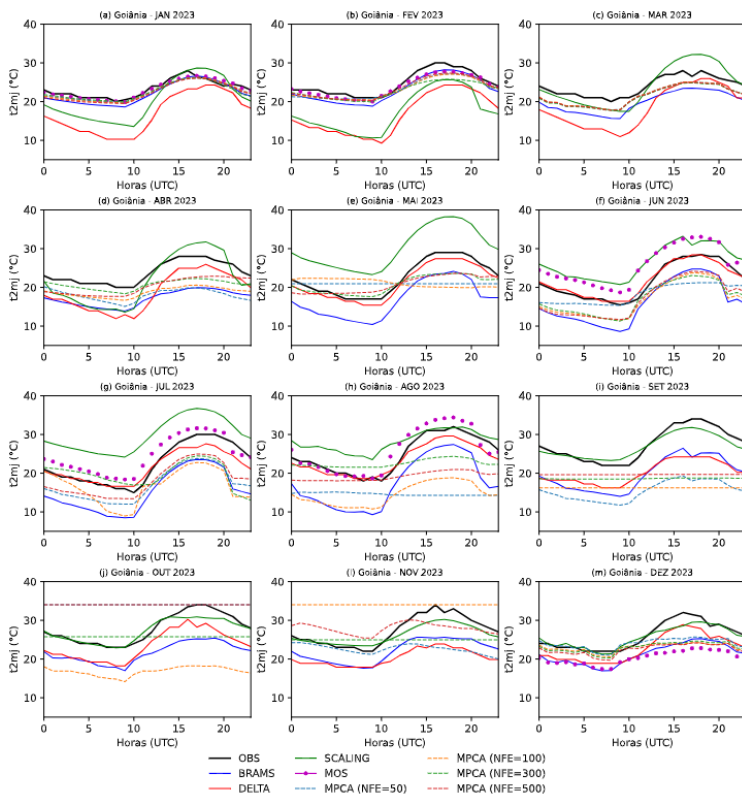


Figura 3. Comparação dos métodos de correção de viés aplicados à temperatura do ar (2m) em Goiânia durante o ano de 2023.

CONCLUSÃO

Os resultados sugerem não haver um método superior a outro para todas as estações do ano e em todos os locais. Independente da complexidade computacional, cada método apresenta desempenho

diferenciado. OU seja, um ou outro método pode apresentar melhores resultados, dependendo do período do ano e/ou das condições climáticas específicas de cada cidade. As redes neurais mostraram grande potencial, mas também apresentaram variabilidade que necessita de ajustes para maximizar seu desempenho e aqui foi avaliada somente uma classe de rede neural (perceptron de múltiplas camadas: PMC) e há muitas outras arquiteturas a se considerar (redes de base radial, redes recorrentes, para citar outras 2 classes - ver: HAYKIN, 1998), além de diferentes técnicas de treinamento (aqui foi apresentado somente treinamento - ou aprendizado - supervisionado (HAYKIN, 1998)). A estabilidade observada em certas configurações de redes neurais aponta para a necessidade de uma análise mais profunda das configurações e parâmetros utilizados. Essas análises são cruciais para o desenvolvimento e aprimoramento de modelos de previsão do tempo, permitindo uma melhor adaptação às condições locais e temporais.

Uma vez que o desempenho das metodologias dependeram das estações do ano e do local, uma proposta para investigação futura é a aplicação da estratégia de Máquinas de Comitê (MC) - ver HAYKIN, 1998 (Capítulo 7), onde a estimativa de todas as metodologias aqui tratadas seriam valores de entrada para o algoritmo de MC.

AGRADECIMENTOS

Autor HFCV agradece ao CNPq (Conselho Nacional de Pesquisa e Desenvolvimento) pelo apoio com bolsa de pesquisa (Proc. 314660/2020-8). A autora MPD agradece a Fapeg pelo financiamento da bolsa de pesquisa. Este trabalho foi possível graças aos recursos computacionais do LaMCAD/UFG. Os autores agradecem ao Centro de Excelência em Agricultura Exponencial (CEAGRE) e Centro de Excelência em Estudos, Monitoramento e Previsões Ambientais do Cerrado (CEMPA-Cerrado).

REFERÊNCIAS

AVILEZ-VALENTE, P. et al. Desempenhos de uma rede neural recorrente e de um modelo numérico na previsão de níveis de água no estuário do Rio Douro, Portugal. 2022

BAHNG, H. et al. Learning de-biased representations with biased representations. In: PMLR. International Conference on Machine Learning. [S.l.], 2020. p. 528-539.

DANTAS, M. P. et al. Técnica de remoção de viés para o modelo brams na região do centro-oeste. In: XXII Congresso Brasileiro de Meteorologia. [S.l.]: Bauru SP, 2022. p. 880.

Dantas, M. P. Resultados preliminares para remoção de viés por redes neurais para o modelo BRAMS no Centro-Oeste - Brasil. In XIII Workshop Brasileiro de Micrometeorologia, Alegre- RS, 25-27 de outubro de 2023.

GETAHUN, G. W. et al. Statistical downscaling (delta method) of precipitation and temperature for bilate watershed, Ethiopia. International Journal of Water Resources and Environmental Engineering, Academic Journals, v. 13, n. 1, p. 20-29, 2021

GRELL, G. A.; FREITAS, S. R. A scale, and aerosol aware stochastic convective parameterization for weather and air quality modeling. Atmospheric Chemistry and Physics, Copernicus GmbH, v. 14, n. 10, p. 5233-5250, 2014.

GOODFELLOW, I. et al. Regularization for deep learning. Deep learning, p. 216-261, 2016.

HAYKIN, S., Neural Networks: A Comprehensive Foundation. Prentice Hall, 1998.

- LUO, M. et al. Comparing bias correction methods used in downscaling precipitation and temperature from regional climate models: a case study from the Kaidu river basin in western China. *Water*, MDPI, v. 10, n. 8, p. 1046, 2018.
- SHI, T. et al. A new method for correcting urbanization-induced bias in surface air temperature observations: insights from comparative site-relocation data. *Frontiers in Environmental Science*, Frontiers Media SA, v. 9, p. 625418, 2021.
- SHRESTHA, A. K. et al. Solar radiation, air temperature, relative humidity, and dew point study: Damak, jhapa, nepal. *International Journal of Photoenergy*, Hindawi, v. 2019, 2019.
- SOUZA, C. M. et al. Reconstructing three decades of land use and land cover changes in Brazilian biomes with Landsat archive and earth engine. *Remote Sensing*, MDPI, v. 12, n. 17, p. 2735, 2020.
- SPIEGEL, M. R.; STEPHENS, L. J. *Estatística. coleção schaum. 3ª edição*. Editora Afiliada, São Paulo, v. 2, p. 1, 1993.
- TEUTSCHBEIN, C.; SEIBERT, J. Bias correction of regional climate model simulations for hydrological climate-change impact studies: Review and evaluation of different methods. *Journal of Hydrology*, Elsevier, v. 456, p. 12-29, 2012.
- THOMPSON, G.; EIDHAMMER, T. A study of aerosol impacts on clouds and precipitation development in a large winter cyclone. *Journal of the Atmospheric Sciences*, American Meteorological Society, v. 71, n. 10, p. 3636-3658, 2014.
- VAZ, L. S. d. C. Teste de sensibilidade da pbl (camada limite planetária) no modelo numérico wrf em sinergia com imagens do satélite meteosat para analisar ilhas de calor em fortaleza-ce. Instituto de Ciências do Mar (LABOMAR), 2021.
- YAMAMOTO, R.; SAMBATTI, S. B. M.; FERREIRA, C. C. Correção de viés de previsões meteorológicas com uso do método histogram matching meteorological forecast bias correction. 2022.