



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Melhoria da acurácia dos dados de temperatura do ar da reanálise ERA5 utilizando redes neurais artificiais

Eduardo Morgan Uliana¹

¹Instituto de Ciências Agrárias e Ambientais (ICAA), Universidade Federal de Mato Grosso (UFMT), Campus de Sinop-MT. E-mail: eduardo.uliana@ufmt.br. ORCID: 0000-0003-2107-4634

Artigo recebido em 15/07/2024 e aceito em 16/02/2025

RESUMO

A temperatura do ar é um dos elementos climáticos cruciais no planejamento agrícola e ambiental. No entanto, a rede de monitoramento em países em desenvolvimento possui baixa densidade, requerendo o desenvolvimento de métodos para estimá-la em locais sem medição. Uma opção é utilizar dados de reanálise, como o ERA5, que possuem vieses e necessitam de correção. O objetivo deste estudo foi estimar a temperatura do ar em locais sem monitoramento a partir de dados diários de reanálise ERA5, utilizando redes neurais artificiais (RNAs) para melhorar a precisão e a acurácia dos dados, baseando-se em medições de superfície. Foram utilizados dados de temperatura do ar de 34 estações meteorológicas automáticas do Instituto Nacional de Meteorologia. O download da grade de reanálise ERA5 foi realizado com auxílio do Google Earth Engine. A arquitetura das RNAs utilizada foi o Perceptron de Múltiplas Camadas. A partir dos resultados obtidos, concluiu-se que é possível melhorar expressivamente a precisão e a acurácia dos dados de temperatura do ar da reanálise ERA5 utilizando dados medidos em estações meteorológicas automáticas da área de estudo, combinados com modelagem por redes neurais artificiais. Essa abordagem permite analisar a variabilidade espacial da temperatura do ar e estimar essa variável em locais sem monitoramento meteorológico. Os dados gerados poderão ser empregados em estudos relacionados à climatologia da temperatura do ar, zoneamento de culturas, gestão de riscos e cálculo da soma térmica para previsão do ciclo das culturas.

Palavras-chave: distribuição espacial, calor sensível, reanálise, meteorologia agrícola, inteligência artificial.

Improving the Accuracy of ERA5 Reanalysis Air Temperature Data Using Artificial Neural Networks

ABSTRACT

Air temperature is one of the most critical climatic elements in agricultural and environmental planning. However, the monitoring network in developing countries has low density, requiring the development of methods to estimate it in locations without measurements. One option is to use reanalysis data, such as ERA5, which have biases and need correction. The objective of this study was to estimate air temperature in locations without monitoring from daily ERA5 reanalysis data, using artificial neural networks (ANNs) to improve the precision and accuracy of the data based on surface measurements. Air temperature data from 34 automatic meteorological stations of the National Institute of Meteorology were used. The ERA5 reanalysis grid was downloaded with the help of Google Earth Engine. The ANN architecture used was the Multilayer Perceptron. Based on the results obtained, it was concluded that it is possible to significantly improve the precision and accuracy of ERA5 reanalysis air temperature data using data measured at automatic meteorological stations in the study area, combined with artificial neural network modeling. This approach allows analyzing the spatial variability of air temperature and estimating this variable in locations without meteorological monitoring. The generated data can be used in studies related to air temperature climatology, crop zoning, risk management, and thermal sum calculation for crop cycle prediction.

Keywords: spatial distribution, sensible heat, reanalysis, agricultural meteorology, artificial intelligence.

Introdução

A temperatura do ar é um dos elementos climáticos cruciais no planejamento agrícola e ambiental. Trata-se de um fator com alto potencial

de afetar diretamente o desenvolvimento fenológico das plantas e a qualidade dos produtos, conforme Lorençone et al. (2022).

De acordo com Freitas et al. (2020), condições climáticas adversas podem causar impacto significativo na agricultura e, consequentemente, na segurança alimentar. Esses autores defendem que o desenvolvimento de ferramentas de previsão da produção com base em elementos climáticos pode auxiliar na tomada de decisões agrícolas e na mitigação de riscos. A base para isso é conhecer, no mínimo, a variabilidade espacial e sazonal dos diversos elementos climáticos na área de produção.

Segundo Santos et al. (2018), compreender as interações entre clima e produtividade pode melhorar o planejamento agrícola e a gestão de riscos climáticos, promovendo uma agricultura mais resiliente e sustentável. Em seu estudo os autores verificaram que tanto anomalias de chuvas quanto variações extremas de temperatura do ar impactam negativamente o rendimento médio do feijão cultivado no Estado de Minas Gerais.

Previsões e estimativas de colheita com base na temperatura do ar estão consolidadas na área de meteorologia aplicada, principalmente no que se refere à metodologia de soma térmica. Segundo Leite et al. (2023), a metodologia de soma térmica pode resultar em uma previsão precisa da data de colheita, reduzindo custos operacionais e evitando problemas relacionados ao armazenamento e à comercialização do fruto. Segundo os autores, trata-se de um método confiável que permite prever com precisão a data da colheita, otimizando a cadeia produtiva.

Renato et al. (2013) avaliaram a influência dos métodos de graus-dia em condições de aumento da temperatura, ou seja, mudanças climáticas, para as culturas do feijão e do milho. Segundo os autores, em condições de temperaturas elevadas é essencial aplicar métodos que incluam limites superiores e inferiores para o desenvolvimento das plantas. Entre os métodos avaliados, o de Ometto (1981) foi o mais adequado para a simulação de mudanças climáticas devido à sua maior precisão em lidar com temperaturas extremas. No entanto, para usar esse método tanto considerando as condições climáticas atuais quanto as futuras, decorrentes das mudanças no clima, é preciso ter conhecimento das temperaturas máximas e mínimas da localidade para onde se pretende prever o ciclo da cultura.

Ainda nesse contexto de elaboração de ferramentas de previsão de safra, Aparecido et al. (2020) desenvolveram um modelo para estimar a produtividade do milho safrinha em função das condições climáticas de Mato Grosso do Sul. Esses autores, assim como os mencionados anteriormente, enfatizam a importância da previsão sazonal para mitigar os efeitos adversos da

variabilidade climática, sobretudo da temperatura do ar e da precipitação. Os autores conseguiram desenvolver um modelo eficaz para estimar a produtividade em função dos elementos climáticos, apresentando uma relação significativa com a temperatura, cujos valores podem ser utilizados como um bom indicador de risco climático em sistemas de produção de milho no referido estado.

Até agora, mencionou-se apenas a influência da temperatura do ar na agricultura. No entanto, conforme Trindade et al. (2020), esse elemento também pode afetar drasticamente o ambiente urbano, gerando ilhas de calor que causam desconforto térmico e impactam a saúde e o rendimento das atividades humanas. Autores como Pontes et al. (2016), Carvalho et al. (2016), Azevedo et al. (2015) e Roseghini et al. (2011) encontraram uma relação significativa entre a temperatura do ar e a ocorrência de doenças infecciosas e internações hospitalares na população de diferentes localidades do Brasil.

Apesar da importância do conhecimento da climatologia da temperatura do ar em diversas áreas, seu monitoramento ainda é insuficiente no território brasileiro. Regiões como o Centro-Oeste e o Norte do Brasil possuem baixa densidade de estações meteorológicas, o que resulta na falta de informações essenciais para a tomada de decisão no planejamento e na gestão de riscos na agricultura e em outras atividades humanas. Portanto, é necessário desenvolver métodos que permitam a estimativa da temperatura do ar em locais sem monitoramento meteorológico, bem como analisar sua variabilidade espacial e temporal.

Como solução para esse problema, autores como Nascimento et al. (2021), Trindade et al. (2020) e Moreira e Galvêncio (2007) propõem a utilização de técnicas de sensoriamento remoto para estimativa e análise espacial da temperatura do ar. Pantano e Bardin-Camparollo (2012) desenvolveram equações de regressão múltipla baseadas em coordenadas geográficas para estimar a temperatura do ar na região do Médio Paranapanema, em São Paulo. Outra opção para a estimativa da temperatura em locais sem monitoramento são os métodos geoestatísticos, como a krigagem, para interpolação dos dados obtidos pontualmente. Esse método foi utilizado por Ramos et al. (2017) para a obtenção de mapas de temperatura e precipitação no Estado de Mato Grosso.

Percebe-se uma clara necessidade de aprimorar o monitoramento meteorológico e desenvolver métodos alternativos para a estimativa da temperatura do ar em regiões carentes de estações meteorológicas, visando uma melhor

gestão e planejamento em diversas áreas, especialmente na agricultura. Nesse contexto, este trabalho propõe a estimativa da temperatura do ar com base na grade de reanálise ERA5. Os dados ERA5 são uma reanálise de quinta geração do clima global, que combina dados de modelo com observações de todo o mundo (Hersbach et al., 2020), apresentando uma resolução espacial de aproximadamente 28 km.

No entanto, os dados de reanálise ERA5 não serão empregados de forma direta para estimar a temperatura e analisar sua distribuição espacial em locais sem monitoramento. Normalmente, esse tipo de dado está enviesado, requerendo sua correção com base em dados medidos na superfície. Santos Júnior et al. (2022), por exemplo, utilizaram dados ERA5 de forma direta para monitoramento da seca no Estado de São Paulo e os resultados indicaram que a reanálise ERA5 não é adequada para o monitoramento direto desse evento extremo. Isso era esperado devido aos erros sistemáticos inerentes a esse tipo de dado.

Portanto, é fundamental corrigir os dados de reanálise com observações de superfície para garantir a precisão das estimativas de temperatura. Essa abordagem mitigará os vieses e permitirá uma análise mais confiável da variabilidade espacial e temporal da temperatura do ar, contribuindo para uma gestão e planejamento mais eficazes, especialmente na agricultura. Neste estudo, será empregado um modelo de redes neurais artificiais para a estimativa da temperatura do ar, utilizando a grade de reanálise ERA5. Pretende-se, dessa forma, corrigir a reanálise considerando informações medidas em estações meteorológicas automáticas.

Assim, o objetivo deste estudo foi estimar a temperatura do ar para locais sem monitoramento a partir de dados diários de reanálise ERA5 e redes neurais artificiais, além de elaborar mapas mensais para analisar sua variabilidade espacial e temporal no Estado de Mato Grosso. Com essa abordagem, espera-se obter estimativas da temperatura do ar com maior acurácia, contribuindo para um melhor planejamento e gestão em diversas áreas, com ênfase na agricultura.

Material e métodos

Área de Estudo

Este estudo foi conduzido no Estado de Mato Grosso, localizado na região Centro-Oeste do Brasil, reconhecido por sua expressiva produção agrícola de grãos, conforme o Censo Agropecuário de 2017 (IBGE, 2017). Mato Grosso abrange três importantes biomas brasileiros: Cerrado, Pantanal e Amazônia. O estado também abriga as cabeceiras de bacias hidrográficas de relevância nacional, incluindo as bacias dos rios Tocantins-Araguaia, Xingu, Tapajós e Paraguai.

A escolha de Mato Grosso como área de estudo deve-se à sua diversidade climática e geográfica, além do alto potencial para a produção agrícola. Informações relacionadas à temperatura são essenciais para o cálculo da soma térmica e outras aplicações no manejo agrícola, como a determinação de épocas de plantio, previsão de colheitas e gestão de riscos climáticos. A temperatura influencia diretamente esses aspectos, sendo fundamental para a metodologia proposta, que foca na distribuição espacial e sazonal da temperatura do ar e sua estimativa para locais sem monitoramento meteorológico.

Base de dados

Como base de dados de superfície, foram utilizadas séries históricas registradas em 32 estações meteorológicas automáticas, pertencentes ao Instituto Nacional de Meteorologia (INMET). Mais informações relacionadas a essas estações e ao período de dados podem ser verificadas na Tabela 1.

O registro da temperatura do ar nas estações da Tabela 1 foi realizado a uma altura de 2 metros e de forma horária. Esses dados foram submetidos a uma análise de consistência para a remoção de valores espúrios e inconsistentes. Após esse procedimento, os dados horários de temperatura máxima, mínima e média foram convertidos em médias diárias e, posteriormente, em médias mensais.




Figura 1. Mapa da área de estudo com destaque para a localização das estações meteorológicas automáticas e biomas.

Tabela 1. Estações meteorológicas automáticas utilizadas no estudo, pertencentes ao Instituto Nacional de Meteorologia (INMET)

Código	Município	Bioma	Latitude	Longitude	Altitude (m)	Período
A924	Alta Floresta	Amazônia	09°50'S	56°06'W	289	2008-2020
A910	Apiacás	Amazônia	09°33'S	57°23'W	220	2007-2020
A926	Carlinda	Amazônia	10°00'S	55°47'W	290	2008-2020
A913	Comodoro	Amazônia	13°42'S	59°45'W	591	2007-2020
A919	Cotriguaçu	Amazônia	09°54'S	58°34'W	261	2007-2020
A930	Gaúcha do Norte	Amazônia	13°11'S	53°15'W	379	2009-2020
A906	Guarantã do Norte	Amazônia	09°57'S	54°53'W	320	2003-2020
A914	Juara	Amazônia	11°16'S	57°31'W	260	2007-2020
A920	Juína	Amazônia	11°22'S	58°43'W	200	2008-2020
A928	Nova Maringá	Amazônia	13°02'S	57°05'W	353	2007-2020
A937	Pontes e Lacerda	Amazônia	15°15'S	59°20'W	256	2008-2020
A916	Querência	Amazônia	12°37'S	52°13'W	382	2007-2020
A917	Sinop	Amazônia	11°58'S	55°33'W	371	2007-2020
A902	Tangará da Serra	Amazônia	14°39'S	57°25'W	322	2003-2020
A922	Vila Bela da Santíssima Trindade	Amazônia	15°03'S	59°52'W	222	2007-2020
A908	Água Boa	Cerrado	14°00'S	52°12'W	432	2007-2020
A909	Alto Araguaia	Cerrado	17°33'S	53°22'W	753	2012-2020
A934	Alto Taquari	Cerrado	17°48'S	53°17'W	875	2008-2020
A013	Aragarças	Cerrado	15°54'S	52°14'W	347	2007-2020
A927	Mundo Novo	Cerrado	12°31'S	58°13'W	431	2008-2020
A905	Campo Novo do Parecis	Cerrado	13°47'S	57°50'W	570	2003-2020
A912	Campo Verde	Cerrado	15°31'S	55°08'W	749	2007-2020
A932	Guiratinga	Cerrado	16°20'S	53°45'W	526	2008-2020
A933	Itiquira	Cerrado	17°10'S	54°30'W	585	2009-2020
A929	Nova Ubiratã	Cerrado	13°24'S	54°45'W	518	2008-2020
A915	Paranatinga	Cerrado	14°25'S	54°02'W	474	2007-2020
A935	Porto Estrela	Cerrado	15°21'S	57°13'W	145	2008-2020
A907	Rondonópolis	Cerrado	16°27'S	54°34'W	284	2004-2020
A931	Santo Antônio do Leste	Cerrado	14°55'S	53°53'W	648	2008-2020
A921	São Félix do Araguaia	Cerrado	11°37'S	50°43'W	218	2009-2020
A904	Sorriso	Cerrado	12°33'S	55°43'W	380	2003-2020
A903	São José do Rio Claro	Cerrado	13°27'S	56°39'W	350	2003-2020
A901	Cuiabá	Cerrado	15°37'S	56°06'W	151	2003-2020
A941	Cáceres	Pantanal	16°02'S	57°41'W	116	2012-2020

2.3. Dados de reanálise ERA5

Os dados diários de reanálise ERA5 (Copernicus Climate Change, 2017) de temperatura máxima, mínima e média do ar para o período de 01/01/1980 a 31/12/2019 foram obtidos a partir de um dataset "ECMWF/ERA5/DAILY" presente na plataforma Google Earth Engine (GEE) (Gorelick et al., 2017).

Os dados ERA5 são uma reanálise de quinta geração do clima global, que combinam dados de modelo com observações de todo o mundo (Hersbach et al., 2020). Com uma grade de resolução espacial de aproximadamente 28 km, os dados fornecem valores agregados diários de nove variáveis meteorológicas.

Com o auxílio do Google Earth Engine, foi realizado o download das imagens diárias das seguintes bandas: temperatura do ar média, mínima e máxima a 2 metros de altura, no formato GeoTIFF. Após o download dessas bandas, por meio de uma rotina elaborada no software Matlab, os dados foram extraídos pixel a pixel, organizados temporalmente e armazenados em vetores.

As unidades dos dados de temperatura foram convertidas de Kelvin para graus Celsius (°C). Por fim, foram obtidas as séries históricas das médias mensais de temperatura para cada pixel da grade. Com as etapas descritas, obteve-se um banco de dados de temperatura de reanálise ERA5 (1980-2019), referenciado e organizado cronologicamente para a área de estudo, o qual foi relacionado com os dados de superfície das localidades da Tabela 1.

Arquitetura e treinamento das RNAs

Com o intuito de aumentar a acurácia dos dados de temperatura do ar estimados a partir da reanálise ERA5, foram desenvolvidos modelos de redes neurais artificiais (RNAs). Para desenvolvimento desses modelos foi utilizado procedimento proposto por Uliana et al. (2024), o qual é descrito de forma concisa a seguir. Três redes neurais foram elaboradas, cada uma focada em uma variável específica: a primeira para a temperatura máxima média mensal, a segunda para a temperatura média mensal, e a terceira para a temperatura mínima média mensal, todas considerando as respectivas temperaturas medidas nas estações meteorológicas automáticas como dado de saída.

Como dados de entrada, foram testadas as temperaturas da grade ERA5, incluindo a temperatura máxima, mínima, média e a temperatura do ponto de orvalho médias mensais. Além desses dados, considerou-se também a

radiação solar no topo da atmosfera (R_0) (total mensal), calculada para cada pixel da grade com base no dia do ano e na latitude.

Os dados de entrada e saída das ANNs foram separados aleatoriamente em duas categorias: dados de treinamento (85%) e teste (15%). Posteriormente os dados foram padronizados por meio da Equação 1, conforme Ramos Filho et al. (2024).

$$pn = \frac{2(p - \min p)}{(\max p - \min p)} - 1 \quad (1)$$

em que: pn é o valor padronizado, p é o valor da temperatura do ar, e minp e maxp são, respectivamente, o menor e o maior valor da temperatura do ar na série em estudo.

Como arquitetura neural, foi empregado o Perceptron de múltiplas camadas, conforme ilustrado na Figura 2. As redes neurais artificiais foram do tipo retroalimentadas, compostas por uma camada de entrada, duas camadas ocultas e uma camada de saída. Foram avaliadas duas funções de transferência: logsig (log-sigmoide) e tansig (tangente hiperbólica) nas camadas ocultas, e a linear na camada de saída das ANNs.

O número de iterações, épocas de treinamento e neurônios em cada camada oculta da ANN foram definidos utilizando o algoritmo de otimização SCE-UA (Duan et al., 1992) durante o processo de treinamento da rede, visando obter o menor erro na estimativa da temperatura de interesse. Esse algoritmo de otimização foi integrado ao processo de treinamento da RNA, utilizando o índice de eficiência de Nash-Sutcliffe como função objetivo. No treinamento das RNAs, foi empregado o algoritmo de retropropagação do erro, combinado com o algoritmo de otimização de Levenberg-Marquardt.




Figura 2. Representação de arquitetura de uma RNA do tipo Perceptron de múltiplas camadas.

Fonte: Adaptado de Govindaraju (2000) e Silva et al. (2010)

Métricas de Erro

Para quantificar o erro de estimativa do produto de reanálise ERA5 e das RNAs em relação aos dados medidos nas estações meteorológicas automáticas, utilizou-se as seguintes métricas de erro: erro absoluto médio (Equação 2); raiz do erro quadrático médio (Equação 3); viés (bias) (Equação 4); índice de concordância de Willmott (Equação 5), índice de eficiência de Nash-Sutcliffe (Equação 6), o índice de eficiência de Kling-Gupta (Equação 7) e o teste t pareado ao nível de 5% de significância (Equação 8).

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - P_i| \quad (2)$$

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2 \right]^{0,5} \quad (3)$$

$$viés = \frac{1}{N} \sum_{i=1}^N (O_i - P_i) \quad (4)$$

$$d = 1 - \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{\sum_{i=1}^n (|P_i - O| + |O_i - O|)^2} \right] \quad (5)$$

$$ENS = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - O)^2} \quad (6)$$

$$EKG = 1 - \sqrt{(r-1)^2 + \left(\frac{\sigma_e}{\sigma_o} - 1 \right)^2 + (viés-1)^2} \quad (7)$$

$$t = \sqrt{\frac{(n-1) viés^2}{RMSE^2 - viés^2}} \quad (8)$$

em que P_i é a temperatura do ar estimada ($^{\circ}\text{C}$); O_i , a temperatura observada ($^{\circ}\text{C}$); O , a média da temperatura observada ($^{\circ}\text{C}$); n , o número de valores da amostra; r é o coeficiente de correlação entre os dados observados e estimados; σ_e é o desvio padrão dos dados estimados; e σ_o é o desvio padrão dos dados observados.

As métricas de erros apresentadas também foram utilizadas por autores como Uliana et al. (2024), Ramos Filho et al. (2024) e Sousa Jr et al. (2024) para avaliação de modelos. A interpretação detalhada dessas métricas podem ser consultadas nesses trabalhos.

O teste t pareado (Equação 8) ao nível α de 5% de significância foi utilizado com a finalidade de confirmar se a diferença (Δ) entre os dados observados e simulados foi estatisticamente nula. As hipóteses do teste t foram: $H_0: \Delta = 0$; $H_1: \Delta \neq 0$. Quando o valor em módulo de t (Equação 8) apresentou valor superior ao quantil da distribuição t de Student com $v = n-1$ graus de liberdade $\left(t_{\frac{\alpha}{2}, v} \right)$, então, rejeitou-se a hipótese nula (H_0) bilateral, ou seja, existe diferença entre os valores de temperatura observados e simulados pelo modelo.

A partir dos melhores modelos de RNAs baseados em dados da grade ERA5 foram elaborados mapas da temperatura máxima, mínima e média mensal no Estado de Mato Grosso, considerando o período de 1980 a 2019. Dessa forma foi possível analisar a distribuição espacial e temporal da temperatura do ar no estado.

Resultados e discussão

Os resultados obtidos com a execução da metodologia são promissores e permitiram analisar a distribuição espacial e temporal da temperatura do ar máxima, mínima e média no estado de Mato Grosso. Na Tabela 2, podem ser observadas as métricas de erro das redes neurais artificiais, sua arquitetura, funções de transferência e as melhores variáveis de entrada dos modelos que tinham como saída as temperaturas observadas nas estações meteorológicas automáticas do Instituto Nacional de Meteorologia (INMET).

Em uma análise preliminar realizada durante o treinamento das RNAs, verificou-se que a utilização isolada da temperatura máxima da grade de reanálise (T_{maxERA5}), da temperatura mínima de reanálise (T_{minERA5}) e da temperatura média de reanálise (T_{medERA5}) como entrada das RNAs não resultava em melhoria da acurácia das estimativas. Portanto, optou-se por combinar essas temperaturas com outras variáveis que se relacionavam melhor com as temperaturas registradas nas estações, como a radiação no topo da atmosfera (R_0) e outras temperaturas da própria grade. As melhores variáveis para estimar a temperatura máxima média mensal das estações (T_{max}) foram a T_{maxERA5} e a R_0 . Para a temperatura média mensal das estações automáticas, as variáveis foram T_{maxERA5} , T_{minERA5} , T_{medERA5} , junto com a R_0 . Por último, para a temperatura mínima média mensal, as variáveis foram T_{maxERA5} , T_{minERA5} , T_{medERA5} , T_{orvERA5} (temperatura do ponto de orvalho da reanálise) e a R_0 .

Verifica-se na Tabela 2 que a utilização da radiação no topo da atmosfera total mensal foi

essencial como entrada nas RNAs para estimar as três temperaturas. Isso demonstra que essa variável foi importante para a regionalização da temperatura, possivelmente devido ao fato de que

R_0 depende da latitude e do dia do ano. Portanto, os modelos consideraram implicitamente essas variáveis ao utilizarem R_0 como entrada.

Tabela 2. Métrica estatística do erro do modelo de redes neurais artificiais na etapa de treinamento e teste para os elementos meteorológicos de interesse

Váriavel	Entrada	Função	N1	N2	N3	Etapa	MAE	RMSE	viés	d	ENS	EKG	t
Tmax	Tma _{XERA5} ; R_0	tansig;tansig;purelin	4	5	1	Treinamento	0,203	0,269	0,000	0,995	0,981	0,986	0,005 ^(ns)
						Teste	0,212	0,276	0,000	0,995	0,979	0,989	0,029 ^(ns)
Tmed	Tma _{XERA5} ; Tmin _{ERA5} ; Tmed _{ERA5} ; R_0	tansig;logsig;purelin	4	3	1	Treinamento	0,156	0,207	0,000	0,994	0,976	0,983	0,016 ^(ns)
						Teste	0,147	0,198	0,000	0,994	0,977	0,989	0,016 ^(ns)
Tmin	Tma _{XERA5} ; Tmin _{ERA5} ; Tmed _{ERA5} ; TorV _{ERA5} ; R_0	tansig;logsig;purelin	4	3	1	Treinamento	0,184	0,240	0,000	0,996	0,983	0,988	0,003 ^(ns)
						Teste	0,177	0,224	0,013	0,996	0,985	0,986	1,465 ^(ns)

Tmax, Tmin e Tmed são as temperaturas médias mensais máxima, mínima e média, respectivamente (°C); R_0 é a radiação solar no topo da atmosfera, total mensal (MJ m⁻²); N1, N2 e N3 representam o número de neurônios artificiais nas duas camadas escondidas, e na camada de saída respectivamente; tansig e purelin: função de transferência sigmoide tangente hiperbólica e linear, respectivamente. MAE: erro absoluto médio (°C); RMSE: raiz do erro quadrático médio (°C); viés: °C; d: índice de concordância de Willmott; ENS: índice de eficiência de Nash-Sutcliffe; EKG: índice de eficiência de Kling-Gupta; t: valor da estatística de teste do teste t pareado; e ns: não significativo ao nível de 5% de significância.

A otimização do número de neurônios nas camadas escondidas com o SCE-UA resultou em ótimos globais com 4 e 5 neurônios artificiais nas camadas ocultas da RNA de temperatura máxima e com 4 e 3 neurônios artificiais nas camadas das redes utilizadas para estimativa da temperatura média e mínima. A combinação das funções de transferência em cada camada está apresentada também na Tabela 2.

Para ambos os modelos apresentados na Tabela 2, as métricas de erro indicam estimativas das temperaturas com precisão e acurácia. Os valores de viés foram praticamente iguais a zero, e o índice de concordância de Willmott ficou próximo a 1, indicando boa concordância entre os valores observados e estimados. Os valores dos índices de eficiência de Nash-Sutcliffe e de Kling-Gupta ficaram superiores a 0,75, indicando que os modelos ajustados são "adequados e bons" para a estimativa da temperatura do ar, conforme a classificação de Van Liew et al. (2007). O teste t não significativo com $\alpha = 5\%$ confirmou que não há diferença significativa entre os dados observados e estimados com os modelos. Outro ponto a ser destacado é que os modelos de RNAs não apresentaram underfitting ou overfitting, pois o desempenho dos modelos nas estimativas foi mantido na etapa de teste, cujos valores não foram utilizados no treinamento e, portanto, eram desconhecidos pelos modelos. A partir da análise da Tabela 2, fica evidente que os modelos de RNAs desenvolvidos são adequados para estimar a temperatura do ar com base nos dados da reanálise ERA5 e de R_0 .

Com a finalidade de demonstrar a importância da remoção de erros sistemáticos dos dados de reanálise foram estimadas métricas de erro (Tabela 3) e plotados gráficos de dispersão (Figura 3) entre os dados de temperatura das estações automáticas e as respectivas temperaturas

da reanálise ERA5, bem como com os valores observados e estimados com as RNAs, considerando os dados de treinamento e teste juntos.

Observa-se na Tabela 3 que os dados de reanálise ERA5 utilizados diretamente para estimativa da temperatura possuem precisão, porém requerem melhoria da acurácia, sobretudo, os dados de temperatura média e mínima do ar. Destaca-se que valores adequados e bons das métricas de erro nos dados ERA5 podem estar relacionados a boa precisão da reanálise, porém, como já mencionado não há acurácia desejável.

Ao comparar as métricas de erro dos dados diretos da reanálise com as estimativas das RNAs baseadas nesses dados e em R_0 , nota-se uma expressiva redução do MAE e do RMSE, além de um aumento dos valores de d, ENS e EKG. O teste t indicou que existe diferença significativa entre os dados observados e estimados diretamente com a grade ERA5. No entanto, o mesmo teste indicou que não existe diferença significativa entre os dados de temperatura do ar observados e os estimados com as RNAs.

Nos gráficos de dispersão da Figura 3, pode-se constatar de forma mais clara a melhoria na acurácia das estimativas de temperatura com os modelos de RNAs propostos (Tabela 2). Portanto, esses resultados demonstram que utilizar a grade de reanálise de temperatura do ar ERA5 sem a remoção dos erros sistemáticos, com o auxílio de dados de superfície e modelagem, não é recomendável.

Tabela 3. Métrica estatística do erro dos dados de temperatura observados nas estações meteorológicas, comparados com os dados ERA5 e com os dados derivados das redes neurais artificiais

Observado e ERA5							
Variável	MAE	RMSE	Viés	d	ENS	EKG	t
Tmax	0,488	0,668	0,391	0,970	0,882	0,955	46,418*
Tmed	0,823	0,881	-0,786	0,895	0,556	0,934	126,987*
Tmin	1,891	2,087	-1,891	0,689	-0,271	0,650	137,313*
Observado e ANNs							
Variável	MAE	RMSE	Viés	d	ENS	EKG	t
Tmax	0,204	0,270	0,000	0,995	0,981	0,987	0,016 ^(ns)
Tmed	0,155	0,205	0,000	0,994	0,976	0,984	0,021 ^(ns)
Tmin	0,183	0,238	0,002	0,996	0,984	0,988	0,536 ^(ns)

Tmax, Tmin e Tmed são as temperaturas médias mensais máxima, mínima e média, respectivamente (°C); MAE: erro absoluto médio (°C); RMSE: raiz do erro quadrático médio (°C); viés: °C; d: índice de concordância de Willmott; ENS: ¹índice de eficiência de Nash-Sutcliffe; EKG: índice de eficiência de Kling-Gupta; t: valor da estatística de teste do teste t pareado; e ns: não significativo ao nível de 5% de significância.




Figura 3. Dispersão dos dados de temperatura do ar máxima (Tmax), média (Tmed) e mínima (Tmin) média mensal medidos nas estações meteorológicas automáticas do INMET, estimados pela reanálise ERA5 (coluna da esquerda) e corrigidos pelo modelo de redes neurais artificiais (coluna da direita).

Nas Figuras 4, 5 e 6, são apresentados os mapas da temperatura do ar máxima, mínima e média diária mensal, considerando o período de 1980 a 2019, estimadas para cada pixel da grade de reanálise com o modelo de redes neurais artificiais, cuja arquitetura foi descrita na Tabela 2. Além dos mapas, foram calculadas as médias mensais dessas temperaturas para as áreas dos biomas Pantanal, Cerrado e Amazônia no estado de Mato Grosso. Os valores e o comportamento temporal dessas médias podem ser consultados na Figura 7.

Ao analisar de forma conjunta as Figuras 4 a 7, verifica-se que as maiores temperaturas máxima e média do ar entre outubro e abril, meses que correspondem à primavera, verão e parte do outono, ocorrem no Pantanal de Mato Grosso, seguidas pelas áreas de cerrado. No Pantanal, as temperaturas máximas e médias são expressivamente altas. Já as menores temperaturas máxima e média nesse período são registradas na região amazônica de Mato Grosso, onde os valores são mais amenos. Em alguns meses desse período, os valores médios das temperaturas da Amazônia e do Cerrado ficam próximos, como pode ser observado na Figura 7. No que se refere à temperatura mínima para esse período, o Pantanal é ainda o bioma com os maiores valores, seguido pela Amazônia. O cerrado é o bioma que registra as menores mínimas no período, o que pode ser explicado pela menor umidade em comparação a Amazônia e ao Pantanal. A umidade atua como um regulador térmico, evitando decréscimo acentuado da temperatura do ar.

Já no período de maio a agosto, o comportamento se inverte, com as maiores temperaturas máxima e média ocorrendo na área da Amazônia, seguidas pelo Cerrado. O Pantanal apresenta os menores valores dessas temperaturas no período. No que se refere à temperatura mínima, os menores valores entre maio e agosto ocorrem nas áreas de Cerrado. No entanto, a Amazônia é que, de forma geral, possui os maiores valores dessas temperaturas dentre os três biomas. Em setembro, as temperaturas dos biomas apresentam valores muito próximos, mas com algumas particularidades. No Pantanal, as temperaturas máximas médias são elevadas, enquanto no Cerrado e na Amazônia as médias são ligeiramente menores.

De forma geral, a análise dos dados meteorológicos estimados confirma que os meses com as maiores temperaturas nos biomas do estado são agosto, setembro e outubro, sendo outubro o mês mais crítico no Pantanal. Junho apresenta as menores temperaturas médias e julho possui a menor temperatura mínima média, embora a temperatura média e máxima seja um pouco mais alta que em junho. Esses resultados refletem a influência das estações do ano e sistemas sinóticos que atingem a região durante o inverno, bem como a transição entre o inverno e a primavera.

Na Amazônia, a temperatura máxima média variou de 30,1°C em janeiro a 33,7°C em agosto, indicando que o período mais quente se concentra no final do inverno e início da primavera. A temperatura média oscila entre 23,4°C em junho e 26,2°C em setembro, enquanto a temperatura mínima apresenta uma variação de 15,7°C em julho a 21,4°C em outubro.

No Pantanal, as variações de temperatura são igualmente expressivas. As temperaturas máximas médias variam de 30,1°C em junho a 34,0°C em outubro, demonstrando que o calor extremo ocorre na primavera. A temperatura média varia entre 21,5°C em junho e 27,2°C em outubro. A temperatura mínima apresenta os menores valores em julho, com 14,4°C, e os maiores em outubro, com 21,8°C.

O Cerrado, por sua vez, também exibe variações consideráveis na temperatura do ar. A temperatura máxima média vai de 30,2°C em janeiro a 33,5°C em setembro, indicando um pico de calor durante o final do inverno e início da primavera, como nos outros biomas. A temperatura média oscila entre 22,2°C em junho e 26,5°C em setembro, enquanto a temperatura mínima varia de 13,7°C em julho a 21,6°C em outubro.

Para fins de consulta direta, foram extraídos dos mapas das Figuras 4 a 6 os valores de temperatura máxima, média e mínima do ar para a sede dos principais municípios produtores de grãos do Estado de Mato Grosso. Esses valores são apresentados no heatmap da Figura 8. O comportamento temporal observado nos dados é semelhante ao descrito para os biomas Cerrado e Amazônia, onde os municípios estão localizados.




Figura 4. Distribuição espacial da temperatura máxima média mensal (1980-2019) para Mato Grosso, obtida a partir do modelo de redes neurais artificiais (RNA) e dados de reanálise ERA5.




Figura 5. Distribuição espacial da temperatura média mensal (1980-2019) para Mato Grosso, obtida a partir do modelo de redes neurais artificiais (RNA) e dados de reanálise ERA5.




Figura 6. Distribuição espacial da temperatura mínima média mensal (1980-2019) para Mato Grosso, obtida a partir do modelo de redes neurais artificiais (RNA) e dados de reanálise ERA5.




Figura 7. Temperatura máxima, média e mínima diária mensal (1980-2019) para os biomas do estado de Mato Grosso.

Os resultados obtidos neste trabalho foram promissores e demonstraram que a grade de reanálise ERA5 é uma excelente alternativa para a estimativa da temperatura do ar em locais sem estações de monitoramento, desde que seja realizada uma correção com dados de superfície. Para essa correção, os modelos de redes neurais artificiais mostraram-se adequados ao utilizar dados da própria grade de reanálise e da radiação no topo da atmosfera, a qual pode ser estimada para qualquer local com base na latitude e no dia do ano. A comparação dessa abordagem com outras metodologias descritas na literatura revelou que as estimativas de temperatura obtidas com o método proposto apresentaram maior precisão e acurácia.

Pantano e Bardin-Camparollo (2012) regionalizaram a temperatura do ar para a região do Médio Paranapanema, em São Paulo, utilizando regressão linear múltipla. As equações empregadas tinham como variáveis independentes a latitude, a longitude e a altitude. Os coeficientes de

determinação obtidos pelos autores variaram de 0,76 a 0,89 para a temperatura máxima média mensal e entre 0,36 e 0,96 para a temperatura mínima média mensal. Com base nessas equações, os autores geraram mapas de temperatura máxima e mínima média mensal, o que permitiu uma análise detalhada da distribuição espacial da temperatura na região.

Ao comparar os dados obtidos por Pantano e Bardin-Camparollo (2012) com os resultados derivados da reanálise ERA5 e das Redes Neurais Artificiais (Tabelas 2 e 3), observou-se que a nova abordagem proposta neste estudo proporcionou uma melhoria significativa na precisão e na acurácia das estimativas de temperatura. A utilização da grade ERA5 combinada com os modelos de redes neurais artificiais demonstrou ser uma metodologia mais eficaz em comparação com os métodos tradicionais descritos na literatura.

Ramos et al. (2017) espacializaram a temperatura do ar no Estado de Mato Grosso

utilizando o método geoestatístico de Krigagem Ordinária. Na validação cruzada, utilizaram como métrica de erro a raiz do erro médio quadrático (RMSE), obtendo valores que variaram de 0,85 a 1,46°C para a temperatura mínima mensal, entre 0,81 e 1,66°C para a temperatura média mensal e entre 0,90 e 2,45°C para a temperatura máxima mensal.

Ao comparar esses valores de RMSE obtidos com o método geoestatístico com os valores obtidos pela combinação ERA5 e Redes Neurais Artificiais (Tabelas 2 e 3), verificou-se que os erros da última abordagem foram expressivamente menores. Isso demonstra que a metodologia resulta em valores com maior acurácia para analisar a distribuição espacial da temperatura do ar e estimá-la em locais sem medição.

Destaca-se que é um desafio trabalhar com a metodologia geoestatística para espacializar variáveis hidrometeorológicas em locais como o Estado de Mato Grosso, onde a rede de monitoramento possui baixa densidade e distribuição irregular.

O banco de dados obtido a partir deste estudo, especialmente os mapas das Figuras 4 a 6, poderá ser utilizado em pesquisas relacionadas à gestão de riscos climáticos, soma térmica para a previsão do ciclo das culturas, bem como em atividades de planejamento agrícola, como o zoneamento de culturas no estado de Mato Grosso.




Figura 8. Temperaturas máximas, médias e mínimas diárias mensais (1980-2019) nas sedes das principais cidades produtoras de grãos do estado de Mato Grosso.

Conclusões

A partir dos resultados obtidos, pode-se concluir que é possível melhorar expressivamente

a precisão e a acurácia dos dados de temperatura do ar da reanálise ERA5 utilizando dados medidos em estações meteorológicas automáticas da área de estudo, combinados com modelagem por redes neurais artificiais com arquitetura do tipo perceptron de múltiplas camadas. Essa abordagem permite analisar a variabilidade espacial da temperatura do ar e estimar essa variável em locais sem monitoramento meteorológico. Os dados gerados poderão ser empregados em estudos relacionados à climatologia da temperatura do ar, zoneamento de culturas, gestão de riscos e cálculo da soma térmica para previsão do ciclo das culturas.

Destaca-se que a precisão e a acurácia da metodologia proposta possuem potencial para reduzir erros na regionalização da temperatura do ar, em comparação com metodologias geoestatísticas e de regressão linear múltipla que utilizam como variáveis independentes as coordenadas geográficas e a altitude.

A análise dos dados estimados de temperatura do ar para o estado de Mato Grosso revela variações expressivas entre os biomas Pantanal, Cerrado e Amazônia ao longo do ano. O Pantanal registra as temperaturas mais altas durante a primavera e o verão. Em todo o estado, o período mais crítico em termos de altas temperaturas ocorre entre agosto e outubro.

Referência

- Aparecido, L.E.O., Torsoni, G.B., Mesquita, D.Z., Meneses, K.C., Moraes, J.R.S.C., 2020. Modelagem da produtividade do milho safrinha em função das condições climáticas do Mato Grosso do Sul. *Revista Brasileira de Climatologia*, 26. <https://doi.org/10.5380/abclima.v26i0.69183>
- Azevedo, J.V.V.D., Santos, C.A.C.D., Alves, T.L.B., Azevedo, P.V.D., Olinda, R.A.D., 2015. Influência do clima na incidência de infecção respiratória aguda em crianças nos municípios de campina grande e monteiro, paraíba, brasil. *Revista Brasileira de Meteorologia*, 30, 467-477. <https://doi.org/10.1590/0102-778620140066>
- Carvalho, E.K.M.A., Dantas, R.T., Carvalho, J.R.M., 2016. Análise da influência entre as variáveis meteorológicas e doenças respiratórias na cidade de Campina Grande, PB. *Revista Brasileira de Climatologia*, 18. <https://doi.org/10.5380/abclima.v18i0.41099>
- Copernicus Climate Change Service, 2017. ERA5: Fifth generation of ECMWF atmospheric reanalyses of the global climate. Copernicus Climate Change Service Climate Data Store (CDS), (date of access). Available at: <<https://cds.climate.copernicus.eu/cdsapp#!/home>>. Access on january 2023.
- Duan, Q., Sorooshian, S., Gupta, V. K. (1992). Effective and efficient global optimization for conceptual rainfall-runoff models. *Water Resources Research*, 28(4), 1015-1031. <https://doi.org/10.1029/91WR02985>
- Freitas, G.N., Quadro, F.L., Vitor, A., 2020. Análise das variáveis agroclimáticas na estimativa de produtividade do arroz irrigado em Uruguaiana, Rio Grande do Sul. *Revista Brasileira de Climatologia*, 27, 845-863. Disponível: <https://doi.org/10.5380/rbclima.v27i0.72866>. Acesso: 5 jul. 2024.
- Govindaraju, R. S., 2000. Artificial neural networks in hydrology I: preliminary Journal of Hydrologic Engineering, 5(2), 115-123. [https://doi.org/10.1061/\(ASCE\)10840699\(2000\)5:2\(115\)](https://doi.org/10.1061/(ASCE)10840699(2000)5:2(115))
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R., 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Hersbach, H., Bell, B., Berrisford, P. et al. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society* 146(730), 1999-2049. <https://doi.org/10.1002/qj.3803>
- IBGE (2017). Instituto Brasileiro de Geografia e Estatística. Censo Agropecuário 2017. Rio de Janeiro. <https://censoagro2017.ibge.gov.br/>. Accessed 14 November 2023.
- Leite, G.B., Araújo, C.E.S., Silva Ricce, W., Couto, M., 2023. Previsão de colheita de maçãs com base na soma térmica. *Agropecuária Catarinense*, 36(1), 62-66. <https://doi.org/10.52945/rac.v36i1.1515>
- Lorençone, P.A., Aparecido, L.E.D.O., Lorençone, J.A., Torsoni, G.B., Lima, R.F.D., 2022. Estimation of Air Temperature Using Climate Factors in Brazilian Sugarcane Regions. *Revista Brasileira de Meteorologia*, 37(1), 121-140. <http://dx.doi.org/10.1590/0102-77863710008>
- Moreira, E.B.M., Galvêncio, J.D., 2007. Espacialização das temperaturas à superfície na cidade do Recife, utilizando imagens TM-LANDSAT 7. *Revista de Geografia*, 24(3), 101-115.

- Nascimento, F.H., Jardim, C.H., Silveira Rangel, S.D.A., 2021. Variação da temperatura de superfície através de técnicas de sensoriamento remoto: análise de dois episódios para o concelho de Coimbra, Portugal/2018. *Revista Brasileira de Climatologia*, 28, 118-136. <http://dx.doi.org/10.5380/abclima.v28i0.75954>
- Ometto, J.C., 1981. *Bioclimatologia Vegetal*. Editora Agronômica Ceres, São Paulo, Brazil, p. 440p.
- Pantano, A.P., Bardin-Camparollo, L., 2012. Modelo de estimativa de temperaturas máximas e mínimas mensais para a região do médio Paranapanema, SP. *Revista Engenharia na Agricultura*, 20(3), 250. <https://doi.org/10.13083/reveng.v20i3.345>
- Pontes, C.C., Leite, M.L., Gavão, N., Virgens Filho, J.S., 2016. Efeitos do clima na saúde: análise das internações de crianças menores de cinco anos por pneumonia no município de Ponta Grossa – PR. *Revista Brasileira De Climatologia*, 18. <https://doi.org/10.5380/abclima.v18i0.43444>
- Ramos, H.D.C., Dallacort, R., Neves, S.M.A.S., Dalchiavon, F.C., Santi, A., Vieira, F.F., 2017. Precipitação e temperatura do ar para o estado de Mato Grosso utilizando krigagem ordinária. *Revista Brasileira de Climatologia*, 20(1), 211-233. <http://dx.doi.org/10.5380/abclima.v20i0.43762>
- Ramos Filho, H. A., Uliana, E. M., Aires, U. R. V., da Cruz, I. F., Lisboa, L., da Silva, D. D., Duarte, V. B. R. 2024. Nowcast flood predictions in the Amazon watershed based on the remotely sensed rainfall product PDIRnow and artificial neural networks. *Environmental Monitoring and Assessment*, 196(3), 245. <https://doi.org/10.1007/s10661-024-12396-6>
- Renato, N.D.S., Silva, J.B.L., Sediya, G.C., Pereira, E.G., 2013. Influência dos métodos para cálculo de graus-dia em condições de aumento de temperatura para as culturas de milho e feijão. *Revista Brasileira de Meteorologia*, 28, 382-388. <https://doi.org/10.1590/S0102-77862013000400004>
- Roseghini, W.F.F., Mendonça, F., Ceccato, P., Fernandes, K., 2011. Dengue epidemics in Middle-South of Brazil: climate constraints and some social aspects. *Revista Brasileira de Climatologia*, (9), 94-101. <https://doi.org/10.5380/abclima.v9i0.27522>
- Santos Junior, E.P.D., Blain, G.C., Xavier, A.C.F., 2022. Avaliação dos Dados de Reanálise do Climatic Research Unit (CRU) e do 5th Generation of European Reanalysis (ERA5) no Monitoramento Probabilístico Padronizado da Seca. *Revista Brasileira de Meteorologia*, 37, 243-260. <https://doi.org/10.1590/0102-77863720019>
- Santos, L.F., Martins, F.B., Garcia, S.R. 2018. Padrões climatológicos de precipitação e temperatura do ar associados ao rendimento do feijão comum em Minas Gerais. *Revista Brasileira de Climatologia*. <https://doi.org/10.5380/abclima.v1i0.59108>
- Silva, I.N., Spatti, D.H., Flauzino, R.A., 2010. *Artificial Neural Networks: for Engineering and Applied Sciences*. Editora Artliber, São Paulo, Brazil, p. 399.
- Sousa Jr, M. F., Uliana, E. M., Aires, R. V. U., Rápalo, L. M. C., da Silva, D. D., Moreira, M. C., da Silva Rondon, D. (2024). Streamflow prediction based on machine learning models and rainfall estimated by remote sensing in the Brazilian Savanna and Amazon biomes transition. *Modeling Earth Systems and Environment*, 10(1), 1191-1202. <https://doi.org/10.1007/s40808-023-01837-9>
- Trindade, P.M.P., Saldanha, D.L., Pereira Filho, W., 2020. Análise das variações sazonais da temperatura na área urbana e entorno rural de Santa Maria – RS, Brasil, a partir de pontos fixos de coleta de dados e imagens orbitais. *Revista Brasileira de Climatologia*, 26. <https://doi.org/10.5380/abclima.v26i0.73315>
- Van Liew, M. W., Veith, T. L., Bosch, D. D., and Arnold, J. G., 2007. Suitability of SWAT for the conservation effects assessment project: a comparison on USDA-ARS watersheds. *Journal of Hydrologic Engineering*, 12(2), 173-189. [https://doi.org/10.1061/\(ASCE\)10840699\(2007\)12:2\(173\)](https://doi.org/10.1061/(ASCE)10840699(2007)12:2(173))
- Uliana, E. M., Aires, U. R. V., de Sousa Junior, M. F., da Silva, D. D., Moreira, M. C., da Cruz, I. F., & Araujo, H. B. 2024. Estimated evaporation of lakes by climate reanalysis data and artificial neural networks. *Journal of South American Earth Sciences*, 136, 104811. <https://doi.org/10.1016/j.jsames.2024.104811>