



Revista Brasileira de Geografia Física

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



Modelo de previsão meteorológica decendial para fins agrícolas utilizando regressão linear múltipla

Igor Cristian Oliveira Vieira¹, José Reinaldo da Silva Cabral de Moraes², Valter Barbosa dos Santos³, Deborah Luciany Pires Costa⁴, Rogério Teixeira de Faria⁵, Paulo Jorge de Oliveira Ponte de Souza⁶, Glaucio de Souza Rolim⁷

¹ Msc. em Agronomia pelo Programa de Pós-Graduação Stricto Sensu de Ciência do Solo, Universidade Estadual Paulista "Júlio de Mesquita Filho" (Unesp), e-mail: igor.vieira@unesp.br (autor correspondente). ² Dr. em Agronomia, pelo Programa de Pós-Graduação Stricto Sensu de Produção Vegetal, Universidade Estadual Paulista "Júlio de Mesquita Filho" (Unesp), e-mail: reinaldojmoraes@gmail.com ³ Msc. em Agronomia pelo Programa de Pós-Graduação Stricto Sensu de Ciência do Solo, Universidade Estadual Paulista "Júlio de Mesquita Filho" (Unesp), e-mail: valterbarbosa_santos@hotmail.com ⁴ Dra. em Agronomia, pelo Programa de Pós-Graduação Stricto Sensu em Agronomia, Universidade Federal Rural da Amazônia (UFRA), e-mail: deborahpires.agro@gmail.com ⁵ Professor Assistente Doutor II Universidade Estadual Paulista "Júlio de Mesquita Filho" (Unesp), e-mail: rogerio.faria@unesp.br ⁶ Professor Associado III, Universidade Federal Rural da Amazônia (UFRA), e-mail: paulo.jorge@ufra.edu.br ⁷ Professor Associado, Universidade Estadual Paulista "Júlio de Mesquita Filho" (Unesp), e-mail: glaucio.rolim@unesp.br

Artigo recebido em 11/04/2023 e aceito em 07/02/2024

RESUMO

A previsão das condições climáticas auxilia nas tomadas de decisões devido a sua grande influência nos cultivos, possibilitando estratégias produtivas mais eficientes e diminuição de danos, principalmente nas fases mais críticas da cultura do milho que determinam seu potencial produtivo. Foi desenvolvido um modelo de regressão linear múltipla (RLM) para previsão decendial dos elementos meteorológicos com pelo menos 2 meses de antecedência para 15 localidades que são destaque na produção de milho no Brasil. Foi utilizado um conjunto de dados diários de temperatura média, mínima e máxima do ar, velocidade do vento, umidade relativa e radiação global fornecidos pelo sistema NASA/POWER e dados de precipitação obtidos da Agência Nacional de Águas (2003 a 2019), organizados em decêndios (DEC) em função do ciclo médio do milho e agrupados em dois tipos de clima (Am e Aw). As previsões utilizando 14 DEC nos dois tipos climáticos apresentaram, em média, elevada acurácia para todos os elementos. Os resultados indicaram que o MLR tem alta precisão na previsão dessas variáveis, especialmente na estimação da velocidade do vento. Para os elementos mais voláteis, como precipitação, o modelo ainda conseguiu manter uma confiabilidade aceitável, apesar das complexidades inerentes à sua previsão. Complementarmente, o desempenho do modelo de Camargo para calcular o balanço hídrico foi destacado. Este modelo necessitou de menos dados de entrada para o cálculo de armazenamento de água no solo, que é decisivo para o planejamento do cultivo do milho, sendo uma ferramenta eficaz para a previsão de elementos climáticos em escala decendial.

Palavras-chave: agrometeorologia. machine learning. modelos preditivos. previsão tempo

Multiple linear regression to forecast decendial weather for agricultural purposes

ABSTRACT

Predicting climate conditions helps in decision-making due to its great influence on crops, enabling more efficient production strategies and reducing damage, especially in the most critical phases of corn cultivation that determine its productive potential. A multiple linear regression model (RLM) was developed to forecast meteorological elements at least 2 months in advance for 15 locations that are prominent in corn production in Brazil. A set of daily data on average, minimum and maximum air temperature, wind speed, relative humidity and global radiation provided by the NASA/POWER system and precipitation data obtained from the National Water Agency (2003 to 2019) was used, organized into decennials (DEC) depending on the average corn cycle and grouped into two types of climate (Am and Aw). Forecasts using 14 DEC in both climate types showed, on average, high accuracy for all elements. The results indicated that the MLR has high accuracy in predicting these variables, especially in estimating wind speed. For the more volatile elements, such as precipitation, the model was still able to maintain acceptable reliability despite the complexities inherent in its prediction. In addition, the performance of the Camargo model to calculate the water balance was highlighted. This model required less input data to calculate water storage in the soil, which is decisive for planning corn cultivation, being an effective tool for predicting climatic elements on a ten-day scale.

Keywords: Agrometeorology, machine learning, predictive models. weather forecast

Introdução

A dinâmica climática exerce uma influência direta e substancial sobre o desenvolvimento e a produtividade dos cultivos agrícolas, ocasionando consideráveis variações e perdas de rendimento em função da instabilidade das condições meteorológicas. Nesse contexto, a aplicação de modelagem meteorológica preditiva emerge como uma ferramenta essencial para elucidar as complexas interações entre os fenômenos climáticos e as culturas agrícolas, bem como para mitigar as incertezas inerentes aos cenários climáticos futuros. A adoção estratégica desses modelos permite uma compreensão mais aprofundada das dinâmicas climáticas locais e regionais, oferecendo insights cruciais para aprimorar a resiliência e a adaptabilidade das práticas agrícolas diante dos desafios impostos pelas mudanças climáticas (Habib-ur-rahman et al., 2022).

Prever com antecedência os elementos climáticos, como precipitação acumulada, médias de temperatura do ar, radiação solar, velocidade do vento, umidade relativa do ar, evapotranspiração, umidade do solo, deficiência e excedente hídrico são essenciais para o planejamento agrícola e nas tomadas de decisões no campo, promovendo a otimização dos processos produtivos, a redução de riscos operacionais e a maximização da resiliência das práticas agrícolas diante das flutuações climáticas (Bochenek; Ustrnul, 2022).

No cultivo do milho, grande parte da redução na produtividade de grãos pode ser causada por estresses ambientais, principalmente no período que compreende as duas semanas antes e as duas semanas após o florescimento, em virtude dessa fase definir o potencial produtivo. (SHAO et al., 2021). Portanto, prever a variabilidade climática nessas fases é fundamental para estimar a produtividade final do cultivo.

A rápida expansão das novas tecnologias, em relação a capacidade de armazenamento e processamento dos dados, possibilitou ao longo dos últimos anos uma maior utilização de modelos de previsão. Além disso, com o crescimento de big data, foi possível modelar de forma mais poderosa as diferentes áreas da ciência, engenharia, finanças, economia e principalmente agricultura (LIM; ZOHREN, 2021).

Dentre os elementos climáticos, a

precipitação é um dos fenômenos mais essenciais no dinamismo do sistema natural, sendo um dos principais elementos que causam a variabilidade da produção agrícola. Assim, diversos modelos foram utilizados para sua previsão, como o modelo univariado de Média Móvel Sazonal Autorregressiva Integrada para prever chuvas semanais em Gujarat, utilizando 53 anos de dados históricos para prever chuvas para os cinco anos subsequentes com alta precisão (Damor et al., 2023), bem como redes neurais artificiais (RNAs) para previsão de chuvas com 3 a 4 semanas de antecedência e de temperatura do ar de 2 m (Fan et al., 2023).

Modelos de RNAs e Regressão Linear Múltipla (RLM) também foram utilizados para previsões de velocidade do vento (BARHMI et al., 2020) para 12 meses com 3 anos de dados tratados. Os Modelos de Regressão Linear Múltipla (RLM) são utilizados pela sua simplicidade e pela capacidade de explicar as relações entre múltiplas variáveis, ajudando ainda a definir a predominância de uma variável sobre as outras (Lyu et al., 2023).

No estudo realizado por Reddy et al. (2022), utilizou-se RLM para previsão de precipitação demonstrando elevada associação dos dados previstos e observados. As RLM também foram aplicadas nas previsões de radiação solar (Guermoui et al., 2022) e de temperatura do ar Jose et al., 2022), cujo o modelo obteve coeficientes de correlação acima de 0,90 e erros abaixo de 3 MJ/m² com o uso de Support Vector Machine..

Diante disso, este trabalho teve como objetivo desenvolver um modelo de previsão decendial dos elementos meteorológicos: temperatura média, mínima e máxima do ar, precipitação, velocidade do vento, umidade relativa, radiação global e armazenamento de água no solo, deficiência e excedente hídrico, utilizando diferentes conjuntos de dados decendiais por meio de regressão linear múltipla (RLM), com pelo menos 2 meses de antecedência para 15 localidades que são destaque na produção de milho no Brasil. O modelo visa determinar quantos decêndios de dados anuais são necessários para obter resultados de valores previstos dos elementos, os quais possam ser utilizados no manejo do cultivo do milho em modelos mecanísticos de previsão de produtividade.

Material e métodos

Localização e caracterização da área de estudo

Para a realização do estudo foram selecionados os 15 maiores municípios produtores de milho do Brasil com base na sua produção média, independente da variedade, com base na série

histórica que compreende os anos de 2003 a 2019, extraída do Instituto Brasileiro de Geografia e Estatística (IBGE) (Figura 1).




Figura 1 Localização geográfica das 15 maiores localidades produtoras de milho no Brasil utilizada neste estudo. Fonte: Elaborado pelos autores (2022).

Seleção dos locais de estudo

Os modelos de RLM foram aplicados para locais geograficamente diversos, em diferentes estados, porém os locais climaticamente semelhantes foram agrupados com o propósito de diminuir os erros e aumentar a eficiência dos modelos. Além disso, o agrupamento possibilita que os modelos ajustados sejam aplicados para outras localidades com o mesmo tipo de clima avaliado.

As localidades foram divididas em dois tipos de clima, Aw (clima tropical com inverno seco) e Am (clima tropical de monção), segundo a classificação climática de Köppen (ALVARES et al., 2013). Nos casos em que os municípios apresentaram mais de um tipo de clima, foi considerado o clima de maior predominância. As localidades classificadas como o tipo Am foram Campo Júlio (MT); Dourados (MS); Sapezal (MT); Sidrolândia (MS) e Maracaju (MS). Enquanto as

localidades com clima Aw foram Sorriso (MT); Jataí (GO); Rio Verde (GO); Lucas do Rio Verde (MT); Nova Mutum (MT); Nova Ubiratã (MT); Campo Novo do Parecis (MT); Primavera do Leste (MT); Diamantino (MT) e São Desidério (BA).

O clima do tipo Am possui características de clima de monção, classificado como tropical úmido ou subúmido, apresenta médias mensais de temperatura superiores a 18°C durante todo o ano, com precipitação anual e média ou superior a 2500 mm e precipitação no mês mais seco abaixo 60 mm. Esse clima é um tipo de transição entre os tipos Af (clima equatorial) e Aw (clima tropical de savana), com precipitação anual abaixo a 2500 mm e precipitação no mês mais seco abaixo 60 mm correspondendo a aproximadamente 27,5% do território brasileiro (Alvares et al., 2013) (Figura 2).

Assim como o clima Am, o tipo climático Aw abrange uma grande área, em torno de 25,8% do território nacional. As características classificam como um clima tropical, que apresenta

inverno seco e temperatura média do mês mais frio acima de 18°C, além de precipitações superiores a 750 mm anuais, podendo atingir um volume em torno de 1800 mm (Figura 2).




Figura 2 Classificação climática para o Brasil, segundo os critérios de Köppen. Fonte: Alvares et al. (2013)

Foi adotada a data de semeadura do milho de 2º safra de 20 de fevereiro, seguindo a janela de plantio do zoneamento de risco climático do Ministério da Agricultura (MAPA, 2022). Essa data corresponde ao período médio utilizado pelos

produtores das localidades analisadas, e foi empregado o tempo médio do ciclo normal do cultivo, correspondente a 130 dias (13 decêndios).

Dados Meteorológicos

Devido à baixa cobertura de estações meteorológica de superfície em diversas regiões do Brasil e ocorrência de períodos não homogêneos, as informações meteorológicas foram adquiridas na plataforma National Aeronautics and Space Administration/Prediction of World Wide Energy Resources – (NASA/POWER). Os dados foram obtidos, automaticamente, utilizando a linguagem de programação Python com uso de API (SPARKS, 2018), compreendendo o período de 2003 a 2019, em escala diária, avaliando um total de 17 anos. Essa plataforma governamental possui grids com resolução espacial de 0.25° (aproximadamente 25,5 km de latitude-longitude), fornecendo um amplo banco de dados meteorológicos para as diversas regiões do mundo (STACKHOUSE et al., 2018).

Os dados climáticos utilizados e extraídos na base da NASA/POWER foram temperatura máxima

(TMAX, °C), temperatura mínima (TMIN, °C), temperatura média (TMED, °C), velocidade do vento (U_2 , $m\ s^{-1}$), umidade relativa (UR, %), e Radiação Global Diária (R_g , $MJ.m^{-2}.dia^{-1}$). Os dados de precipitação (PP, mm) foram coletados do banco de dados da Agência Nacional de Águas (ANA), utilizando como critério, selecionar as estações mais próximas dos locais de estudo e com os dados de chuva completos do período analisado, ambos as fontes no período de 2003 a 2019.

Os dados climáticos diários da ANA e NASA/POWER utilizados foram organizados de forma decendial (dez dias), totalizando 18 decêndios. Para o estudo, os 13 decêndios compreendem o ciclo da cultura e os 5 decêndios envolve o período antes da semeadura (janeiro e 20 dias de fevereiro) para realizar as estimativas para todo o período do ciclo (Figura 2).

Foram realizadas seis interações com diferentes números de dados decendiais atuais para

previsão dos decêndios futuros. Na primeira interação, foram utilizados 5 decêndios (1 DEC ao

5 DEC) de dados observados, que correspondem a janeiro e 2 decêndios iniciais de fevereiro, para gerar as previsões decendiais dos elementos meteorológicos nos 13 decêndios seguintes, correspondentes ao ciclo do milho.

Enquanto na segunda interação, foram adicionados mais 3 decêndios de dados observados (1 DEC a 8 DEC), correspondendo ao estágio de três folhas, para gerar as previsões subsequentes para 9 DEC a 18 DEC. Na terceira interação,

adicionou-se mais 2 decêndios de dados (10 DEC), compreendendo ao estádio de 10 folhas, e na quarta interação mais 2 decêndios (12 DEC), sendo que esse período compreende a fase de pendoamento, considerada a mais sensível aos fatores do clima. Esse mesmo método foi adotado para as interações 5 e 6, 14 DEC e 16 DEC, respectivamente (Figura 2).

CULTURADOMILHO 2° SAFRA																	
FASES					FASE VEGETATIVA							FASE REPRODUTIVA					
MESES	JAN		FEV			MAR			ABR		MAI		JUN				
ESTÁDIO																	
					Semeadura	Emergência	Três Folhas	Três Folhas	Sete Folhas	Dez Folhas	Doze Folhas	Pendramento	Florascimento	Bolha D'água	Grão Leitoso	Grão Pastoso	Formação de dente
ITERAÇÃO	DE CÊNDIOS																
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
1	DADOS METEOROLÓGICOS DE CÊNDIAIS DO ANO PREVISTO																
2																	
3																	
4	DADOS METEOROLÓGICOS DE CÊNDIAIS DO ANO ATUAL																
5																	
6																	

Figura 3 - Fenologia do milho: estádios de desenvolvimento do cultivo de 2^o safra e organização dos dados observados e dados a serem previstos. Fonte: Adaptado de APARECIDO et al. (2020).

Os modelos de regressão linear múltipla (RLM) são amplamente utilizados devido sua capacidade de previsão que está relacionada as estruturas não complexas, interpretabilidade do

cálculo e a aptidão de reconhecer outliers ou anomalias em variáveis preditoras específicas (ARULMOZHI et al., 2021). Um modelo RLM pode ser expresso pela seguinte equação:

$$Y = a_0 + a_1X_1 + a_2X_2 + \dots a_iX_i + \varepsilon \quad (1)$$

Em que Y é a variável de resposta (saída); X é a variável preditora (independente) (X1... Xi); an são os coeficientes angulares; a0 é o coeficiente linear; e o ε é o ruído ou erro aleatório do modelo.

Na variável preditora foram utilizados somente dados decendiais da própria variável predita para prever cada elemento.

Estimativa da evapotranspiração potencial

Os métodos testados para estimar a ETP para os tipos climáticos Am e Aw foram:

a. **Penman e Monteith (Allen et al.,1998) (PM):**

$$ET_{OPM} = \frac{0,408 \times s \times (Rn - G) + \frac{\gamma \times 900 \times U_2 \times (es - ea)}{T + 273}}{s + \gamma \times (1 + 0,34 \times U_2)} \quad (2)$$

$$s = \frac{4098 \times es}{(T+273)^2} \quad ea = \frac{UR \times es}{100} \quad es = 0,6108 \times e^{\frac{17,27 \times T}{237,3+T}} \quad (3)$$

No qual s é a declividade da curva de pressão de vapor em relação à temperatura (kPa °C); R_n é o saldo de radiação diário (MJ.m⁻².d⁻¹); G é o fluxo total diário de calor no solo, atribuindo-se o valor igual a zero; γ é o coeficiente psicrométrico

(valor constante de $6,215 \cdot 10^{-2}$ kPa °C); U_2 é a velocidade do vento à 2 m de altura (m s^{-1}); e_s é a pressão de saturação de vapor (kPa); e_a é a pressão atual de vapor (kPa); e T é a temperatura média do ar (°C).

b. Camargo (1971) (CAM):

$$EToC = 0,01 \times \frac{Qo}{2,45} \times T \times ND \quad (4)$$

$$hn = \arccos (-\tan\phi \times \tan\delta) \quad (5)$$

$$Qo = 37,6 \times DR \times \left[\left(\frac{\pi}{180} \right) \times hn \times \text{sen}\phi \times \text{sen}\delta + \cos\phi \times \text{sen} hn \right] \quad (6)$$

$$DR = 1 + 0,33 \times \cos\left(360 \times \frac{NDA}{365}\right) \delta = 23,45 \times \sin\left[\left(\frac{360}{365}\right) \times NDA \times 80\right] \quad (7)$$

No qual Q_0 é a irradiação solar extraterrestre ($\text{MJ.m}^{-2}.\text{d}^{-1}$), ND é o número de dias, hn é a hora que ocorre o nascer do sol, ϕ é a

latitude ($^{\circ}$), δ é a declinação solar ($^{\circ}$), NDA é o dia Juliano, DR é a distância relativa Terra-Sol.

c. Priestley e Taylor (1972) (PT):

$$ET_{oPT} = 1,26 \times W \times \left[\frac{(Rn-G)}{2,45} \right] \quad (8)$$

$$\begin{cases} W = 0,407 + 0,0145 * Tu, \text{ para } 0^{\circ}\text{C} < T \leq 16^{\circ}\text{C} \\ W = 0,483 + 0,01 * Tu, \text{ para } 16^{\circ}\text{C} < T \leq 32^{\circ}\text{C} \end{cases} \quad (9)$$

Em que W é o fator de peso dependente da temperatura e do coeficiente psicrométrico ($^{\circ}\text{C}$) e

Tu é a temperatura do bulbo úmido ($^{\circ}\text{C}$).

Balanço Hídrico Climatológico

O balanço hídrico sequencial foi organizado em escala decenal utilizando todos os dados observados (2003 a 2019) e determinado no período de um ano, utilizando os valores das variáveis previstas em cada interação (Figura 3). De acordo com o método proposto por Thorthwaite e Mather (1955), a capacidade de armazenamento de água disponível no solo (CAD) é de 100 mm

para os dois tipos climáticos, esse valor é um padrão utilizado em análises climáticas e descrição da disponibilidade hídrica regional (BRASIL, 1981; DUARTE et al., 2020). As estimativas de armazenamento de água no solo (STO), deficiência hídrica (DEF) e excedente hídrico (SUR) foram calculadas a partir das equações detalhadas na Fig. 4.




Figura 4. Fluxograma do modelo de balanço hídrico modificado de Thornthwaite e Mather (1955). CAD é a capacidade de água do solo (mm), NAC é o acumulado negativo (mm), ou seja, o potencial de secagem do solo, ALT é a alteração no STO, i é um determinado período, $i - 1$ é o período anterior. Adaptado de Rolim et al.(2020).

Com o objetivo de identificar qual método de estimativa de ETP se adequa melhor com os dados decendiais previstos em cada interação de dados observados (Figura 3), foi calculado o BH utilizando o método de estimativa de ETP proposto por Priestley e Taylor (1972) e Camargo (1971) em

comparação ao método padrão elaborado por Penman e Monteith (ALLEN et al., 1998) – o qual é adotado pela Food and Agriculture Organization of the United Nations (FAO) –, para as cidades de clima Am e Aw (Figura 9 e 10).

Análise dos resultados

Para avaliar o desempenho do modelo de RLM e os modelos de estimativa de ETP em comparação ao modelo FAO-56 PM, foram utilizados índices estatísticos para analisar a acurácia, tendência e precisão. Para a precisão do modelo foi utilizado o coeficiente de determinação (R^2 ajustado) (Equação 2) que avalia a capacidade do modelo de repetir a estimativa avaliada

(CORNELL; BERGER, 1987). A acurácia foi mensurada pela Raiz do Erro Médio Quadrático (RMSE) (Equação 3) que compreende o grau de erro não simétrico entre os valores estimados e os dados medidos/de referência (MOELESTSI; WALKER, 2012). E a tendência foi obtida pelo erro sistemático (ES) que corresponde a estimação da tendência do modelo (Equação 4).

$$R^2_{ajust} = \left[-1 \frac{(1-R^2) \times (N-1)}{N-K-1} \right] \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{OBS_i} - Y_{EST_i})^2}{N}} \quad (3)$$

$$ES = \sqrt{\frac{\sum_{i=1}^n (Y_{OBS_i} - \bar{Y})^2}{N}} \quad (4)$$

Em que, Y_{esti} é o valor estimado; Y_{obs} é o valor observado e N corresponde ao total de

observações e K o número de variáveis independentes.

Resultados e discussão

Caracterização climática Am e Aw

As características climáticas das duas regiões apresentam uma variabilidade semelhante ao longo do ano, considerando os dados observados no período de 2003 a 2019 (Figura 5). O total médio de chuva (PP) para o agrupamento de cidades do clima Am foi de 1.762,3 mm ($\pm 85,2$ mm), enquanto para as cidades do clima Aw correspondeu a 1.590,11 mm ($\pm 85,0$ mm). Foi observado uma concentração de PP no período de novembro a março, com destaque em janeiro no clima Am com 300,71 mm ($\pm 154,4$ mm) (Figura 5A), e fevereiro no clima Aw com 265,95 mm ($\pm 117,7$ mm) (Figura 5B), os quais foram os meses mais chuvosos. Por outro lado, os meses de junho a agosto, em ambos os climas, foram os meses menos chuvosos, com destaque para agosto com menores índices pluviométricos.

As temperaturas na classificação climática Aw foram mais elevadas em relação as médias de temperaturas máximas anuais, com TMAX de 30,08 °C ($\pm 1,63$ °C) e mínimas de 19,53 °C ($\pm 1,36$ °C) (Figura 5J e 5L). Em relação ao clima Am, atingiu médias de temperaturas máximas anuais de 29,92 °C ($\pm 2,12$ °C) e mínimas (TMIN) de 18,97 °C ($\pm 1,69$ °C) (Figura 5C e 5D). Ambas as regiões climáticas tiveram julho como regime térmico mais ameno com médias de 14,68 °C ($\pm 2,4$ °C) para Am e de 15,82 °C ($\pm 1,8$ °C) para Aw, enquanto que setembro foi o mais quente no período com médias de 33,24 °C ($\pm 2,6$ °C) (Am) e 34,74 °C ($\pm 1,8$ °C) (Aw).

Diante de valores maiores de temperatura e uma atmosfera mais seca, a umidade relativa média no tipo climático Aw foi de 69,52 % ($\pm 8,2$ %) (Figura 3M), menor do que a do clima Am que foi de 72,02 % ($\pm 8,7$ %) (Figura 5E). Entretanto,

ambos tiveram a atmosfera mais seca em agosto, sendo Am de 53, 47 % ($\pm 8,5$ %) e Aw de 44,24 % ($\pm 6,5$ %).

Avariabilidade média anual da velocidade do vento foi semelhante em ambas as regiões climáticas, com médias de $1,42 \text{ m.s}^{-1}$ ($\pm 8,7 \text{ m.s}^{-1}$) (Figura 5F) para o clima Am e $1,24 \text{ m.s}^{-1}$ ($\pm 0,69 \text{ m.s}^{-1}$) (Figura 5N) para o clima Aw. Em relação a radiação solar global (Rg), nas cidades com clima Am atingiu, em média, $17,90 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ ($\pm 2,4$

$\text{MJ.m}^{-2}.\text{dia}^{-1}$), enquanto nas de clima Aw alcançou $18,37 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ ($\pm 2,12 \text{ MJ.m}^{-2}.\text{dia}^{-1}$). Para os dois climas, o mês de junho foi o que recebeu a menor radiação com $13,64 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ ($\pm 3,2 \text{ MJ.m}^{-2}.\text{dia}^{-1}$) (Am) e $16,39 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ ($\pm 2,8 \text{ MJ.m}^{-2}.\text{dia}^{-1}$) (Aw).




Figura 5. Variabilidade média mensal das condições meteorológicas durante 2003 a 2019 nos locais de clima Am e Aw. A e H: precipitação - PP (mm); B e I: temperatura média do ar - Tmed (°C); C e J: temperatura mínima - Tmin (°C); D e L: temperatura máxima - Tmax (°C); E e M: umidade relativa - UR (%); F e N: velocidade do vento - U² (m.s⁻¹); G e O: radiação global - Rg (MJ m⁻² dia⁻¹).

Clima de tipo Am

Aprofundando a análise dos dados decendiais para a previsão de elementos meteorológicos cruciais ao cultivo do milho, a Figura 6 revela uma tendência de melhora nos modelos conforme o aumento do número de decêndios de dados observados. A precipitação, dada sua notória variabilidade, desafia consistentemente os modelos de previsão, mas, conforme mostrado nos gráficos A e C da Figura 6, os erros de previsão decrescem à medida que mais dados são incorporados, com erros abaixo de 35 mm para previsões com 12 decêndios de antecedência. Isso sugere que o acumulado decendial pode suavizar as variações abruptas, permitindo que preditores adicionais aprimorem a precisão.

Ainda na precipitação, o coeficiente de determinação ajustado (R^2_{ajust}) varia mais acentuadamente. A precisão se intensifica com 16 decêndios de dados, atingindo valores de 0,68 e 0,64, enquanto que com 14 decêndios os valores ainda são considerados aceitáveis, ultrapassando 0,64. Isso se alinha com a observação de que escalas decendiais proporcionam uma janela de predição satisfatória para o planejamento do cultivo, como ilustrado nos gráficos B da Figura 6.

Para a temperatura média do ar, os modelos com 12 e 14 preditores mantiveram-se com valores de RMSE e SE abaixo de 3,5°C, exceto no 13º DEC, onde o RMSE atingiu 5,0°C e o SE 4,9°C. Notavelmente, as correlações para temperaturas com 12 e 14 preditores foram robustas, com R^2 maior que 0,60 e 0,80, respectivamente, conforme demonstrado nos

gráficos D, E e F da Figura 6. Isso indica uma forte capacidade preditiva do modelo nesses parâmetros.

Para temperaturas mínima e máxima, as métricas seguiram padrões similares à temperatura média do ar, com maiores erros apenas no 13º DEC. O desempenho das estimativas melhora significativamente nos outros decêndios, com RMSE e SE mantendo-se abaixo de 3,5°C, e coeficientes de correlação robustos, acima de 0,75 para a mínima e 0,60 para a máxima com 14 decêndios de dados (Figura 6G a L).

A discussão destes resultados evidencia a capacidade preditiva do modelo, principalmente em relação à umidade relativa e radiação global, que mostram boa concordância com as variações observadas com até 16 decêndios de dados (Figura 6M a U). A correlação na umidade relativa diminui com o aumento do intervalo de previsão, enquanto na radiação global, ocorre o oposto. Isso é ilustrativo da dinâmica complexa dos elementos meteorológicos e da eficácia do modelo em capturar essas tendências.

Por fim, a velocidade do vento emergiu como a variável com a previsão mais acurada, exibindo valores de RMSE e SE inferiores a 0,9 m.s-1 e correlações superiores a 0,90 para todas as previsões e intervalos, conforme ilustrado nas Figuras 6P, 6Q e 6R. Este desempenho excepcional se alinha com a literatura, como evidenciado por Barhmi et al. (2020), destacando a competência do modelo de regressão linear múltipla em prever esta variável com precisão com os valores de correlação igual a 0,996 corroborando com a boa capacidade do RLM nesta variável.




Figura 6. Avaliação de modelos de previsão decendial de elementos meteorológicos utilizando coeficiente de determinação (R² ajustado), raiz do erro quadrático médio (RMSE) e erro sistemático (ES) das cidades de clima Am. Legenda: DEC5 previsão para 5 decêndios antes da colheita, DEC8, DEC10, DEC 12, DEC14, DEC16.

Clima de tipo Aw

Analisando os modelos de previsão decendial para cidades de clima Aw e correlacionando-os com os resultados obtidos para o clima Am, observa-se que ambos apresentam padrões de previsão semelhantes, particularmente na variável de precipitação. No clima Aw, tal como no Am, houve uma diminuição dos erros estimados (RMSE e SE) com a progressão dos decêndios, destacando uma confiabilidade crescente do modelo à medida que se incorporam mais dados (Figura 7A e 7C).

Este fenômeno é ilustrado pela melhoria substancial na precisão das previsões, mantendo-se os erros abaixo de 50 mm. A análise do coeficiente de determinação ajustado para a precipitação reforça esta tendência, apresentando um R^2_{ajust} superior a 0,62 para previsões com dois meses de antecedência e ultrapassando 0,73 para previsões feitas com um mês e dez dias de antecedência (Figura 7B). No entanto, em comparação com o clima Am, os valores de R^2 ajustado para o clima Aw parecem ter menos variabilidade entre os diferentes decêndios, o que pode indicar um modelo de previsão mais estável para esta variável neste clima específico.

Ao avançarmos para as variáveis de temperatura — média (TMED), mínima (TMIN) e máxima (TMAX) —, os modelos para as cidades do clima Aw mostram erros de previsão menores que os observados para o clima Am. Com 12 e 14 decêndios de dados, o RMSE e SE se mantiveram abaixo de 2,0 °C para TMED e abaixo de 3,0 °C para TMIN e TMAX, enfatizando a acurácia do modelo (Figuras 7D, 7F, 7G, 7I, 7J, 7L).

A forte correlação dessas temperaturas com r^2 acima de 0,80 em todas as previsões, refletem uma consonância significativa entre os valores gerados pelo modelo e os dados observados. Especificamente, a TMIN e a TMAX com 12 e 14 decêndios de dados apresentaram um R^2_{ajust} superior a 0,77 e 0,80, respectivamente (Figuras 7H e 7K). Isso é uma indicação de que as técnicas de modelagem estão capturando eficientemente os padrões de temperatura e que essa consistência trans-climática realça a aplicabilidade do modelo de regressão linear múltipla através de diferentes contextos climáticos.

O desempenho do modelo na previsão da umidade relativa (UR) e da radiação global (Rg) no

clima Aw também foi bastante positivo. Os erros se mantiveram abaixo de 10% para UR e abaixo de 3 MJ.m⁻².dia⁻¹ para Rg, ressaltando a eficiência do modelo de regressão linear múltipla (RLM). Isto pode ser devido às características do clima Aw, que tende a ter uma estação seca mais pronunciada, possivelmente tornando a radiação solar uma variável mais difícil de prever com precisão devido à variação sazonal da cobertura de nuvens.

A previsão de UR com 12 preditores alcançou um R^2_{ajust} impressionante, superior a 0,9, indicando uma alta correlação até o decêndio 16, mesmo com uma leve diminuição da correlação para o decêndio 18, onde o R^2_{ajust} ainda se mostrou robusto (0,72) (Figuras 7M e 7O). Para a Rg, o modelo não manteve a mesma consistência correlativa vista em UR, mas ainda assim, o R^2_{ajust} foi superior a 0,40, com uma tendência de aumento ao longo dos decêndios (Figuras 7N e 7T).

Quanto à velocidade do vento (U2), os resultados foram consistentes com os encontrados no clima Am, evidenciando a alta precisão do modelo, que manteve os erros de previsão abaixo de 0,7 m.s⁻¹ (Figura 7P e 7R) e apresentou um R^2_{ajust} acima de 0,9 em todas as previsões (Figura 7Q). Este padrão de alta performance na previsão da velocidade do vento reitera a robustez do modelo de RLM nessa variável meteorológica específica.

A consistência entre os dois climas sugere que a metodologia empregada para desenvolver esses modelos de previsão é amplamente aplicável no contexto agrícola brasileiro. No entanto, é importante notar que a complexidade inerente à previsão de certas variáveis, como a precipitação e a radiação solar, pode requerer aprimoramentos específicos do modelo ou a integração de mais preditores para aumentar a precisão nessas áreas.

Em resumo, a análise comparativa dos resultados de previsão para os climas Am e Aw demonstra a eficácia do modelo de RLM, especialmente em termos de previsibilidade e precisão das variáveis de temperatura e velocidade do vento. A aplicabilidade do modelo é reforçada por sua capacidade de manter baixos valores de erro e alta correlação em diferentes climas, o que pode ser de extrema utilidade para o manejo agrícola e a previsão de produtividade do milho em várias regiões do Brasil.




Figura 7. Avaliação de modelos de previsão decendial de elementos meteorológicos utilizando coeficiente de determinação (R^2 ajustado), raiz do erro quadrático médio (RMSE) e erro sistemático (ES) das cidades de clima Aw. Legenda DEC5 previsão para 5 decêndios antes..., DEC8, DEC10, DEC 12, DEC14, DEC16.

Métodos de estimação de Balanço Hídrico

Os dois tipos climáticos Am e Aw apresentaram diferentes padrões nos componentes do balanço hídrico como demonstrado na Figura 8, utilizando os dados observados de ambos os climas no período da série histórica. O monitoramento sistemático das condições de armazenamento de água no solo é um grande parâmetro das condições hídricas em que as plantas estão sujeitas. A figura 8A detalha a variabilidade do armazenamento no clima Am, que durante o período de janeiro a junho obteve uma média de 80,7 mm ($\pm 12,6$ mm), enquanto o clima AW teve um armazenamento médio de 80,7 ($\pm 6,72$ mm) durante o período analisado, este padrão sugere que, apesar de ambos os climas terem uma capacidade semelhante de reter água no solo, o clima Am exibe uma maior flutuação.

Foi possível observar uma maior distribuição das chuvas no clima Am (Figura 5A) o que promoveu maior oscilação nas entradas e saídas de água no solo, uma vez que a precipitação é a principal forma de entrada de água no sistema, somada as temperaturas elevadas observadas neste clima (Figura 11B) influenciou em uma maior variação do armazenamento. O armazenamento no clima Aw acompanhou o regime das chuvas, onde a partir do segundo decêndio de abril começou a apresentar diminuição consecutiva da água no solo até o final do período analisado.

Observa-se que a curva da evapotranspiração real (ETR) para ambos os climas acompanha o regime pluviométrico. Com a diminuição das chuvas ao longo dos meses, consequentemente houve menor volume de água disponível para evaporação, o que provocou gradativamente a diminuição das taxas de ETR.

No clima Am (Figura 8E), observou-se uma ETR média de 567 mm ($\pm 50,1$ mm) com uma variação e distribuição desses valores ao longo do período, devido as entradas de água no sistema que aumentaram a umidade disponível para ETR. Já no Clima Aw (Figura 8F), com o cessar das chuvas, a ETR diminuiu significativamente até o fim do ciclo da cultura estipulado, obtendo uma média de 564 mm ($\pm 37,85$ mm) indicando que a disponibilidade hídrica é um fator limitante mais crítico conforme

a estação seca se estabelece.

A mesma variabilidade da ETR nos dois tipos climáticos foi observada na deficiência hídrica, onde no clima Am (Figura 8C) teve uma deficiência média de 73,8 mm ($\pm 46,9$ mm) e grande oscilação ao longo do período devido as entradas de água no sistema.

A diminuição do volume de chuvas, a partir de abril nas cidades do clima Aw (Figura 8D), promoveu um aumento consecutivo da deficiência de água no solo, com decréscimos concentrados entre o segundo decêndio de abril até o último decêndio de junho, representando o fim do ciclo da cultura do milho, obtendo uma deficiência média de 75,2 mm ($\pm 37,06$ mm).

Ao relacionar os possíveis efeitos da deficiência na cultura do milho Sen et al. (2023) indicaram esta variável climática como uma das que mais influenciam nos cultivos agrícolas, podendo promover resultados positivos ou negativos, dependendo do estágio fenológico da cultura e a intensidade da deficiência.

Em relação ao excedente hídrico, este componente do balanço no clima Am (Figura 8G) teve maior distribuição ao longo do período em consequência dos grandes volumes de chuva que ocorrem neste tipo climático, no período analisado de janeiro a junho (Figura 5A), com um valor médio para este ano e cidades de 218,8 mm ($\pm 136,1$ mm). O excedente hídrico no clima Aw (Figura 8H) acompanhou o período de maior volume de chuvas neste clima (Figura 5H), concentrando-se entre o primeiro decêndio de janeiro ao segundo decêndio de abril, com uma média neste ano e cidade analisada de 827,1 mm ($\pm 245,73$ mm).

Estes resultados são semelhantes ao encontrados por Aparecido et al. (2020) que relacionam os maiores valores deste componente do balanço aos períodos de maior oferta hídrica. Os baixos valores de excedentes, observados no clima Am e no clima Aw, estão relacionados as temperaturas elevadas e baixa oferta hídrica, que corroboram com os dados observados nas figuras 11 e 5A e 5B.




Figura 8. Box plot do balanço hídrico sequencial com dados observados pelo método de Penman e Monteith (Allen et al., 1998) em escala decenal para o clima Am e Aw.

Analisando o desempenho dos modelos evidenciados na figura 9, nos gráficos 9A e 9B, que abordam o armazenamento de água no solo, os coeficientes de determinação (R^2) são de 0,7592 e 0,8076, respectivamente. Isso indica uma forte correlação entre os modelos de Camargo e Priestley-Taylor e o método padrão de Penman e Monteith, sugerindo que ambos os modelos simplificados podem ser eficazmente aplicados para a previsão do armazenamento hídrico em um clima Am. No entanto, nota-se uma ligeira vantagem para o modelo de Camargo, possivelmente devido à sua calibração mais específica para condições tropicais.

A deficiência hídrica, crucial para entender o estresse hídrico em culturas, é representada nos gráficos 9C e 9D. Os valores de R^2 são de 0,7558 e 0,7327, respectivamente, denotando também uma boa concordância entre os modelos e o método de Penman e Monteith, ainda que a correlação seja marginalmente mais fraca do que para o armazenamento hídrico. Este leve decréscimo pode refletir desafios inerentes à previsão de períodos e intensidades de deficiência hídrica.

Para a evapotranspiração real (ETR), mostrada nos gráficos 9E e 9F, encontramos os valores de R^2 de 0,8456 e 0,7899, respectivamente. Estes valores mais elevados sublinham uma correlação muito forte entre os métodos

estimativos e o método de Penman e Monteith, reforçando a confiabilidade dos modelos simplificados na estimação da ETR em climas Am.

Finalmente, os gráficos 9G e 9H avaliam o excedente hídrico, com R^2 de 0,8223 e 0,9303, respectivamente. O excedente hídrico, que indica a água além da capacidade de uso pelas plantas ou de retenção pelo solo, mostra um ajuste excelente para o modelo de Priestley-Taylor, sugerindo que este modelo pode ser particularmente apropriado para prever excedentes hídricos em condições climáticas tropicais.

A análise coletiva destes dados enfatiza a utilidade dos modelos de Camargo e Priestley-Taylor como ferramentas simplificadas, porém robustas, que podem ser empregadas com confiança para a estimativa do balanço hídrico em climas tropicais como o clima Am.

A precisão desses modelos tem implicações diretas para o manejo agrícola, permitindo a implementação de práticas de cultivo otimizadas e o desenvolvimento de estratégias de irrigação mais eficientes, potencialmente melhorando a produtividade e a sustentabilidade das culturas em face das variações climáticas. A validação destes modelos, conforme apresentado, é uma contribuição valiosa para a ciência agrônoma e para as práticas de manejo hídrico em regiões tropicais.




Figura 9. Desempenho entre os dados decendiais do balanço hídrico do clima Am calculados pelo método de Penman and Monteith e os modelos de Camargo e Priestley-Taylor.

A Figura 10 fornece uma visão comparativa do desempenho dos modelos de Camargo e Priestley-Taylor em relação ao método de Penman-Monteith para a estimativa do balanço hídrico decendial no clima Aw. Ao correlacionar esses dados com os resultados do clima Am (Figura 9), observa-se que ambos os modelos mostram uma excelente capacidade preditiva, embora algumas nuances entre os dois climas sejam evidentes.

Para o armazenamento de água no solo (Gráficos 10A e 10B da Figura 10), os coeficientes de determinação são extremamente altos, $R^2 = 0,9514$ e $0,9821$, respectivamente. Isso sugere que os modelos de Camargo e Priestley-Taylor são altamente eficazes em replicar os valores calculados pelo método de Penman-Monteith, potencialmente até com maior precisão no clima Aw em comparação com o clima Am, onde os valores de R^2 eram ligeiramente inferiores.

A deficiência hídrica, indicada pelos gráficos 10C e 10D, apresenta $R^2 = 0,8774$ e $0,9146$, indicando uma boa correspondência com os dados de Penman-Monteith, similar ao observado para o clima Am. Estes valores de R^2 mostram que, embora ambos os modelos possam prever com precisão a deficiência hídrica, há uma leve variação entre os climas, com o clima Aw tendo um ligeiro aumento na precisão.

A evapotranspiração real (ETR), essencial para o planejamento do manejo de água na agricultura, é representada nos gráficos 10E e 10F com R^2 de $0,9439$ e $0,9394$, respectivamente. Essas taxas de concordância são comparáveis aos resultados para o clima Am, embora no clima Am o modelo de Priestley-Taylor pareça ter se alinhado

um pouco mais estreitamente com o método de Penman-Monteith.

Para o excedente hídrico (Gráficos 10G e 10H), os R^2 são extremamente altos ($0,9801$ e $0,9948$), indicando uma precisão quase perfeita na estimativa deste componente hídrico para o clima Aw, superando os resultados do clima Am, onde o R^2 foi menor.

Em termos comparativos, a análise desses dados sugere que, para o clima Aw, os modelos de Camargo e Priestley-Taylor estão mais alinhados com o método de Penman-Monteith do que para o clima Am. Esta descoberta reforça a validade dos modelos simplificados em climas tropicais e oferece um respaldo sólido para sua utilização em estudos hidrológicos e agrônômicos. A capacidade de prever com precisão o balanço hídrico é crucial para a gestão sustentável da água, especialmente em regiões vulneráveis à variabilidade climática, e estes modelos provam ser ferramentas valiosas para esse fim.

Segundo Yu et al. (2023), as temperaturas mais altas observadas no clima Am (Figura 11A) podem intensificar a deficiência hídrica nos locais avaliados, provocando um aumento do déficit de pressão de vapor e consequentemente gerando um aumento nas taxas de evapotranspiração.

As elevadas temperaturas nesse clima influenciam também nas taxas de evaporação da água, que ocasiona maiores volumes de precipitação (MARTÍNEZ-LÜSCHER et al., 2020), o que pode ser validado com os dados observados nas Figura 5A, onde o volume de chuva superior no clima Am, impacta em uma maior variação no armazenamento (Figura 8A).




Figura 10. Desempenho entre os dados decendiais do balanço hídrico do clima Aw calculados pelos modelos de Camargo e Priestley-Taylor em relação ao método de Penman-Monteith.

A temperatura é o elemento em comum para o modelo de balanço hídrico calculado pelos métodos de estimativa de evapotranspiração propostos por Camargo e Penman-Monteith, possivelmente pode ser o fator que tenha influenciado em uma maior variabilidade e dispersão dos valores dos componentes do balanço nas cidades de clima Am (Figura 11.A).

No qual a temperatura média (2003 a 2019) para o clima Am foi de 23,75 °C ($\pm 0,65$ °C) e a variação entre os valores mínimos e máximos de temperatura média anual foi de 19,49 °C a 26,31 °C, respectivamente. Enquanto para as cidades de

clima Aw (2003 a 2019), a média foi de 23,39 °C ($\pm 0,51$ °C), com mínima de 21,91 °C e máxima de 24,42 °C (Figura 11B).

A evapotranspiração real e o armazenamento foram os componentes que tiveram uma maior dispersão no clima mais chuvoso (Am). Segundo Jiang et al. (2022), esses elementos tem uma relação direta devido o aumento e variabilidade da temperatura, pois promove uma maior evapotranspiração, fazendo diminuir o armazenamento de água no solo.




Figura 11. Box plot dos dados observados de temperatura em escala decendial para a cidade de Campo Novo dos Parecis do clima Aw e Sidrolândia do clima Am no período de 2003 a 2019.

Com o resultado obtido de maior correlação pelo método de Camargo (1971) em relação ao método da FAO, foi realizado o balanço hídrico e analisado a variabilidade dos componentes. Com os valores previstos por meio das métricas de avaliação (Desvio Padrão) em cada interação, foi possível observar que o desvio dos dados de armazenamento calculados pelo método de Camargo (Figura 12C e 12D) em ambos os climas, foram bem próximos aos valores de desvio do modelo da FAO (Figura 12A e 12B).

Os valores de desvio das estimativas com 2 meses de antecedência no clima Am, variou entre 5,3 mm a 36,0 mm, e no clima Aw variou entre 0,4 mm a 14,3 mm, em se tratando de dados com escala decendial, os desvios estão dentro da margem de valores satisfatórios. Os valores de desvio da

evapotranspiração real calculado pelo modelo de Camargo, no clima Am com 2 meses de antecedência, ficaram abaixo de 5,9 mm e no Aw abaixo de 4,0 mm, onde em ambos os climas tiveram valores similares ao modelo da FAO.

As previsões de 12 DEC dos dados observados para o BH por método de Camargo, geraram valores de deficiência equivalentes ao modelo de Penman-Monteith, onde embora os desvios a cada estimativa de decêndio foram aumentando, os valores no clima Am ficaram abaixo de 6,8 mm e no clima Aw abaixo de 6,4 mm. A mesma variação foi observada no componente do excedente hídrico, no qual o modelo de Camargo também se mostrou robusto, com baixo valores de desvio com 2 meses de antecedência.




Figura 12. Desempenho estatístico das interações em relação aos dados observados nos climas Am e Aw na escala decenal pelos modelos de Camargo e Penman-Monteith, considerando o desvio padrão (DP).
 Legenda: Quanto menor o valor de desvio e intensidade da cor, melhor o desempenho.

Conclusões

O estudo demonstrou que o modelo de Regressão Linear Múltipla (MLR) é eficaz na previsão de variáveis climáticas cruciais como precipitação, temperatura, umidade relativa, velocidade do vento e radiação solar global para os climas Am e Aw com dois meses de antecedência. Utilizando um conjunto de dados de 14 decêndios preditores, o modelo mostrou-se particularmente preciso na previsão da velocidade do vento e ofereceu resultados confiáveis para variáveis com maior variabilidade.

O modelo de Camargo provou ser uma ferramenta prática e confiável para o cálculo do balanço hídrico, utilizando previsões climáticas geradas pelo MLR, o que é menos complexo e exige menos variáveis de entrada. Esta capacidade reforça a utilidade dos modelos MLR para a tomada de decisões informadas no planejamento agrícola e na análise de riscos climáticos, destacando-se como um recurso significativo para o manejo eficiente de culturas de milho, antecipando condições hídricas que afetam a produtividade das culturas.

Referências

- Allen, R. G., Pereira, L. S., Raes, D., Smith, M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. *Fao, Rome*, 300(9), D05109.
- Almorox, J., Quej, V. H., Martí, P. (2015). Global performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. *Journal of Hydrology*, 528, 514-522. <https://doi.org/10.1016/j.jhydrol.2015.06.057>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., Gonçalves, J. D. M., Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische zeitschrift*, 22(6), 711-728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Aparecido, L. E. D. O., Torsoni, G. B., Mesquita, D. Z., & de Meneses, K. 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>
- Aparecido, L. E. D. O., Moraes, J. R. D. S. C. D., Meneses, K. C. D., Torsoni, G. B., & Costa, C. T. S. (2020). Caracterização Hídrica Espacial e Sazonal de Mato Grosso do Sul com Dados em Grid. *Revista Brasileira de Meteorologia*, 35, 147-156. <https://doi.org/10.1590/0102-7786351018>
- Barhmi, S., Elfatni, O., & Belhaj, I. (2020). Forecasting of wind speed using multiple linear regression and artificial neural networks. *Energy Systems*, 11(4), 935-946. <https://doi.org/10.1007/s12667-019-00338-y>
- Radambrasil, P. (1981). Levantamento integrado dos recursos naturais do Brasil. Folha Jaguaribe-Natal. *Ministério das Minas e Energia-MME*, Rio de Janeiro.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento (MAPA). Zoneamento Agrícola de Risco Climático. Disponível em: <https://indicadores.agricultura.gov.br/zarc/index.htm> Acesso em: 25 de março de 2022.
- Bochenek, B., Ustrnul, Z. (2022). Machine learning in weather prediction and climate analyses—applications and perspectives. *Atmosphere*, 13(2), 180. <https://doi.org/10.3390/atmos13020180>
- CAMARGO, A. P. (1971). *Balanço hídrico no Estado de São Paulo*. Campinas: Instituto Agrônômico, 24p. Boletim, n. 116.
- CONAB. Companhia Nacional de Abastecimento (Brasil). Acompanhamento da safra brasileira de grãos, v. 12 Safra 2017/18 - Décimo segundo levantamento. Brasília DF, 2018, p. 1-148. Disponível em: <https://www.conab.gov.br/infoagro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 07 de abril de 2022.
- Cornell, J. A., Berger, R. D. (1987). Factors that influence the value of the coefficient of determination in simple linear and nonlinear regression models. *Phytopathology*, 77(1), 63-70.
- Costa, T. S., de Sales, R. A., de Jesus Santos, R., dos Santos, R. A., Santos, R. L. (2019). Estimativa do balanço hídrico climatológico e classificação climática para o município de Bom Jesus da Lapa-BA. *Revista Ifes Ciência*, 5(2), 208-216. <https://doi.org/10.36524/ric.v5i2.458>
- Damor, P. A., Ram, B., Kunapara, A. N. (2023). Stochastic Time Series Analysis, Modeling, and Forecasting of Weekly Rainfall Using Sarima Model. *International Journal of Environment and Climate Change*, 13(12), 773-782. <https://doi.org/10.9734/ijecc/2023/v13i123740>
- Doorenbos, J., & Kassam, A. H. (1979). Yield response to water. *Irrigation and drainage* 1454

- paper, 33, 257.
- Duarte, Y. C., Sentelhas, P. C. (2020). NASA/POWER and DailyGridded weather datasets—how good they are for estimating maize yields in Brazil?. *International Journal of Biometeorology*, 64, 319-329. <https://doi.org/10.1007/s00484-019-01810-1>
- Emrouznejad, A., & Charles, V. (Eds.). (2019). *Big data for the greater good*. Cham: Springer International Publishing.
- Esteves, J. T., de Souza Rolim, G., & Ferraudo, A. S. (2019). Rainfall prediction methodology with binary multilayer perceptron neural networks. *Climate Dynamics*, 52, 2319-2331. <https://doi.org/10.1007/s00382-018-4252-x>
- Fan, Y., Krasnopolsky, V., Van Den Dool, H., Wu, C. Y., & Gottschalck, J. (2023). Using Artificial Neural Networks to Improve CFS Week-3–4 Precipitation and 2-m Air Temperature Forecasts. *Weather and Forecasting*, 38(5), 637-654. <https://doi.org/10.1175/WAF-D-20-0014.1>
- Guermoui, M., Abdelaziz, R., Gairaa, K., Djemoui, L., Benkacali, S. (2022). New temperature-based predicting model for global solar radiation using support vector regression. *International Journal of Ambient Energy*, 43(1), 1397-1407. <https://doi.org/10.1080/01430750.2019.1708792>
- Habib-ur-Rahman, M., Ahmad, A., Raza, A., Hasnain, M. U., Alharby, H. F., Ahmad, S., & EL Sabagh, A. (2022). Impact of climate change on agricultural production; Issues, challenges, and opportunities in Asia. *Frontiers in Plant Science*, 13, 925548. <https://doi.org/10.3389/fpls.2022.925548>
- Jiang, K., Pan, Z., Pan, F., Wang, J., Han, G., Song, Y., ... & Chen, X. (2022). Influence patterns of soil moisture change on surface-air temperature difference under different climatic background. *Science of the Total Environment*, 822, 153607. <https://doi.org/10.1016/j.scitotenv.2022.153607>
- Jose, D. M., Vincent, A. M., Dwarakish, G. S. (2022). Improving multiple model ensemble predictions of daily precipitation and temperature through machine learning techniques. *Scientific Reports*, 12(1), 4678. <https://doi.org/10.1038/s41598-022-08786-w>
- Lyu, B., Li, J. (2023). An Efficient Data Analysis Method for Big Data Using Multiple-Model Linear Regression. In *International Computing and Combinatorics Conference* (pp. 272-284). Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-49190-0_19
- Lim, B., & Zohren, S. (2021). Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Kamilaris, A., Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kayri, M., Kayri, I., & Gencoglu, M. T. (2017, June). The performance comparison of Multiple Linear Regression, Random Forest and Artificial Neural Network by using photovoltaic and atmospheric data. In *2017 14th International Conference on Engineering of Modern Electric Systems (EMES)* (pp. 1-4). IEEE. <https://doi.org/10.1109/EMES.2017.7980368>
- Mahmud, I., Bari, S. H., & Rahman, M. (2017). Monthly rainfall forecast of Bangladesh using autoregressive integrated moving average method. *Environmental Engineering Research*, 22(2), 162-168. <https://doi.org/10.4491/eer.2016.075>
- Mamann, A. T. W., Brezolin, A. P., Scremin, A. H., Reginatto, D. C., Henrichsen, L., Dornelles, E. F., ... & da Silva, J. A. G. (2018). Lógica fuzzy na simulação da produtividade de trigo por nitrogênio e hidrogel. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, 6(1). <https://doi.org/10.5540/03.2018.006.01.0384>
- Martínez-Lüscher, J., Chen, C. C. L., Brillante, L., & Kurtural, S. K. (2020). Mitigating heat wave and exposure damage to “Cabernet sauvignon” wine grape with partial shading under two irrigation amounts. *Frontiers in Plant Science*, 11, 579192. <https://doi.org/10.3389/fpls.2020.579192>
- Monteiro, L. A., Sentelhas, P. C., & Pedra, G. U. (2018). Assessment of NASA/POWER satellite-based weather system for Brazilian conditions and its impact on sugarcane yield simulation. *International Journal of Climatology*, 38(3), 1571-1581. <https://doi.org/10.1002/joc.5282>
- Moeletsi, M. E., & Walker, S. (2012). Assessment of agricultural drought using a simple water balance model in the Free State Province of South Africa. *Theoretical and applied climatology*, 108, 425-450. <https://doi.org/10.1007/s00704-011-0540-7>
- Priestley, C. H. B., & Taylor, R. J. (1972). On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly weather review*, 100(2), 81-92.

- [https://doi.org/10.1175/1520-0493\(1972\)100%3C0081:OTAOSH%3E2.3.CO;2](https://doi.org/10.1175/1520-0493(1972)100%3C0081:OTAOSH%3E2.3.CO;2)
- Reddy, P. C. S., Yadala, S., Goddummarri, S. N. (2022). Development of rainfall forecasting model using machine learning with singular spectrum analysis. *IIUM Engineering Journal*, 23(1), 172-186. <https://doi.org/10.31436/iiumej.v23i1.1822>
- Rolim, G. S., de Oliveira Aparecido, L. E., de Souza, P. S., Lamparelli, R. A. C., & dos Santos, É. R. (2020). Climate and natural quality of *Coffea arabica* L. drink. *Theoretical and Applied Climatology*, 141, 87-98. <https://doi.org/10.1007/s00704-020-03117-3>
- Sen, R., Zambreski, Z. T., & Sharda, V. (2023). Impact of Spatial Soil Variability on Rainfed Maize Yield in Kansas under a Changing Climate. *Agronomy*, 13(3), 906. <https://doi.org/10.3390/agronomy13030906>
- Shao, R. X., Yu, K. K., Li, H. W., Jia, S. J., Yang, Q. H., Xia, Z. H. A. O., ... & Liu, T. X. (2021). The effect of elevating temperature on the growth and development of reproductive organs and yield of summer maize. *Journal of Integrative Agriculture*, 20(7), 1783-1795. [https://doi.org/10.1016/S2095-3119\(20\)63304-4](https://doi.org/10.1016/S2095-3119(20)63304-4)
- Sparks, A. H. (2018). nasapower: a NASA POWER global meteorology, surface solar energy and climatology data client for R. *Journal of Open Source Software*, 3(30), 1035. <https://doi.org/10.21105/joss.01035>
- Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. *Geographical review*, 38(1), 55-94. <https://doi.org/10.2307/210739>
- THORNTHWAITE, C. W.; MATHER, J. R., 1955. The water balance. Publication in Climatology 8, *Laboratory of Climatology*, Centerton, N. J.
- Yu, X., Zhang, Y., Zhao, X., Li, J. (2023). Systemic effects of the vapor pressure deficit on the physiology and productivity of protected vegetables. *Vegetable Research*, 3(1). <https://doi.org/10.48130/VR-2023-0020>