

**UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL**

**MODELO DE ESTIMATIVA PARA A PREVISÃO METEOROLÓGICA PARA
FINS AGRÍCOLAS UTILIZANDO MACHINE LEARNING**

Igor Cristian de Oliveira Vieira
Engenheiro Agrônomo

**Jaboticabal-SP
2022**

**UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO
FACULDADE DE CIÊNCIAS AGRÁRIAS E VETERINÁRIAS
CAMPUS DE JABOTICABAL**

**MODELO DE ESTIMATIVA PARA A PREVISÃO METEOROLÓGICA PARA
FINS AGRÍCOLAS UTILIZANDO MACHINE LEARNING**

Igor Cristian de Oliveira Vieira

Orientador: Prof. Dr. Glauco de Souza Rolim

Coorientador: Prof. Dr. Paulo Jorge de Oliveira Ponte de Souza

Prof. Dr. José Reinaldo da Silva Cabral de Moraes

Prof. Dr. Rogério Teixeira de Faria

Dissertação apresentada à Faculdade de Ciências Agrárias e Veterinárias – UNESP, Campus de Jaboticabal, como parte das exigências para a obtenção do título de Mestre em Agronomia (Ciência do Solo).

**Jaboticabal-SP
2022**

V658m Vieira, Igor Cristian de Oliveira
Modelo de estimativa para a previsão meteorológica para fins agrícolas utilizando machine learning / Igor Cristian de Oliveira Vieira.
-- Jaboticabal, 2022
51 p. : il., tabs., mapas

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal
Orientador: Glauco de Souza Rolim

1. Agrometeorologia. 2. Meteorologia. 3. Big data. 4. Previsão tempo. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agrárias e Veterinárias, Jaboticabal. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Jaboticabal



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: MODELO DE ESTIMATIVA PARA A PREVISÃO METEOROLÓGICA PARA FINS AGRÍCOLAS UTILIZANDO MACHINE LEARNING

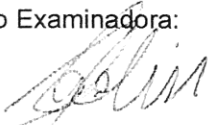
AUTOR: IGOR CRISTIAN DE OLIVEIRA VIEIRA


ORIENTADOR: GLAUCO DE SOUZA ROLIM

COORIENTADOR: JOSÉ REINALDO DA SILVA CABRAL DE MORAES

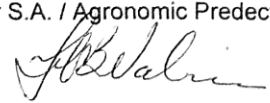
COORIENTADOR: PAULO JORGE DE OLIVEIRA PONTE DE SOUZA

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (CIÊNCIA DO SOLO), pela Comissão Examinadora:


Prof. Dr. GLAUCO DE SOUZA ROLIM (Participação Virtual)
Departamento de Engenharia e Ciências Exatas DECEX / FCAV UNESP Jaboticabal


Prof. Dr. ALEXANDRE BARCELLOS DALRI (Participação Virtual)
Departamento de Engenharia e Ciências Exatas (DECEX) / FCAV / UNESP - Jaboticabal

Dra. TAYNARA TUANY BORGES VALERIANO (Participação Virtual)
Instituição Bayer S.A. / Agronomic Predictive Modeler at Bayer CropScience


Jaboticabal, 29 de julho de 2022

DADOS CURRICULARES DO AUTOR

Igor Cristian de Oliveira Vieira – Brasileiro, nascido em 04 de maio de 1996, natural de Cururupu, Maranhão, filho de Walber Nascimento Vieira e Katiane Cristina de Oliveira (*In memoriam*). cursou engenharia Agrônômica na Universidade Federal Rural da Amazônia, Campus Belém, de Belém – PA, de 2015 a 2020. Bolsista de iniciação científica pela PIBIC/UFRA de 2017 a 2019. Atuando principalmente nos temas: agrometeorologia, irrigação e manejo. Durante a graduação fez parte do Grupo de Pesquisa Interação Solo-Planta-Atmosfera na Amazônia (ISPAAM), na área de agrometeorologia com feijão-caupi, açaí e cupuaçu. Em março de 2020, ingressou no curso de mestrado pelo Programa de Pós-Graduação em Agronomia (Ciência do Solo) da Universidade Estadual Paulista Júlio Mesquita Filho (UNESP/FCAV), no Campus de Jaboticabal - SP na área de pesquisa de Modelagem Agrometeorológica. Em outubro de 2021, ingressou no MBA em agronegócio pela Escola Superior de Agricultura "Luiz de Queiroz", unidade da Universidade de São Paulo (USP). Especialista em piscicultura pela Universidade Federal Rural da Amazônia (2021 – 2022). É integrante do grupo de pesquisa: "Group of Agrometeorological Studies" (GAS), da UNESP – Campus de Jaboticabal e ISPAAM, da UFRA – Campus Belém - PA. Em julho de 2022, submeteu-se à banca para a defesa de dissertação.

Epígrafe

Os que confiam no senhor são como os montes de Sião

Os dias difíceis vêm, mas eles não se abalarão

O tempo tá ruim, tudo tá horrível

Deus não disse que era fácil, só que era possível

“João Gomes”

Dedico

Aos meus pais Walber Nascimento Vieira e
Katiane Cristina de Oliveira (*In memoriam*)
por todo apoio, carinho e amor físico e
espiritual, minha família que é minha fonte
de motivação e aos meus amigos por todo o
incentivo e amizade durante mestrado.

AGRADECIMENTOS

A Deus, pelo dom da vida e por sempre me guiar nos momentos de dificuldade e me mostrar que esses momentos são necessários para o meu crescimento e por ter me apresentando pessoas maravilhosas durante esta caminhada.

À minha família, por todo amor, carinho, paciência e por acreditar em mim e por sempre entender a minha ausência em muitos momentos. Em especial a minha Mãe Katiane Cristina de Oliveira "*in memoriam*", que mesmo ausente nesse plano sinto que esteve presente espiritualmente em todos os momentos tristes e que pensei em desistir, com seu amor e abraço reconfortante me dando forças para continuar lutando.

Ao meu Pai Walber Vieira, por todos os seus sacrifícios por mim, que não foram poucos, todo seu esforço para proporcionar o melhor para nossa família, e por sempre me incentivar em todas as minhas decisões, obrigado por entender a minha ausência nos momentos que precisou de mim.

À minha avó Zelita Oliveira, meus irmãos Gleidson Breno, Gleciane Oliveira, Victor Vieira e Vinícius Vieira, ao meu primo Alexsandro Oliveira e a minha tia Cledionete Ribeiro por todo amor, carinho e por entender os momentos de minha ausência dedicados ao estudo.

À minha avó Antônia Vieira "*in memoriam*", tio Wellington Vieira "*in memoriam*", tio Carlos Luís Vieira "*in memoriam*", por todos os momentos de amor, carinho e pelo incentivo, vocês foram muito importantes na minha vida e essa conquista é para vocês também.

Ao meu orientador professor Dr. Glauco de Souza Rolim pela oportunidade de participar do Grupo de Pesquisa em Agrometeorologia da UNESP – GAS, por todos os seus ensinamentos e pela oportunidade na elaboração deste trabalho e a todos os membros do grupo, em especial, aos meus amigos e parceiros científicos, Valter Barbosa dos Santos, Aline Moreno Ferreira, Kárita Almeida Silva, Kamila Cunha de Meneses, Nayane Jaqueline Costa Maia, Tatiana da Silva Santos, Lígia Negri Corrêa pela amizade, acolhimento e conhecimentos compartilhados.

Aos membros da banca de qualificação, Hildo Giuseppe Garcia Caldas e Eduardo Nardini Gomes e membros da banca de defesa Taynara Tuany

Borges Valeriano e Alexandre Barcellos Dalri pela disponibilidade de participar e pelas contribuições acerca deste trabalho de dissertação.

Aos meus coorientadores, Paulo Jorge de Oliveira Ponte de Souza, Rogério Teixeira de Faria pelas suas contribuições e, em especial, José Reinaldo da Silva Cabral de Moraes pela amizade, parceria e inúmeras orientações, sugestões e conversas que foram determinantes para condução deste trabalho.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Aos meus amigos (as) Deborah Pires, Carmen Grasiela, Erika Teixeira, Matheus Yan, Francisco Souza, Gabriel Teixeira, Alessandra Varela, Izabella Gomes, João Carlos, Marcilene Machado, Saulo Dantas, Maricélio Borges de Souza, Stefany Silva, Lorena Coimbra e Rayssa Ribeiro pela amizade, palavras de apoio, conselhos, momentos e conhecimentos compartilhados que foram essenciais para eu completar essa caminhada.

A todos os demais amigos e colegas, que de alguma forma contribuíram nessa minha trajetória e na realização deste trabalho, e a todos aqueles que de alguma forma estiveram e estão próximos de mim, compartilhando momentos que faz a vida ter sentido.

SUMÁRIO

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	3
2.1 A cultura do milho	3
2.2 Elementos Climáticos	4
2.3 NASA/POWER	5
2.4 Importância da Modelagem	5
2.4.1 Big Data	6
2.4.2 Regressão Linear Múltipla (RLM)	6
2.5 Balanço Hídrico Climatológico Sequencial.....	7
3. MATERIAL E MÉTODOS	8
3.1 Localização e caracterização da área de estudo.....	8
3.2 Seleção dos locais de estudo.....	8
3.3 Dados Meteorológicos	10
3.4 Análise de dados	11
3.5 Análise dos resultados	15
4. RESULTADOS E DISCUSSÃO	15
4.1 Caracterização climática Am e Aw.....	15
4.2 Clima de tipo Am	18
4.3 Clima de tipo Aw.....	21
4.4 Métodos de estimação de Balanço Hídrico.....	23
5. CONCLUSÕES	33
REFERÊNCIAS.....	33

MODELO DE PREVISÃO METEOROLÓGICA DECENDIAL PARA FINS AGRÍCOLAS UTILIZANDO REGRESSÃO LINEAR MÚLTIPLA

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 do banco de dados da Agência Nacional de Águas (ANA) (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, com destaque para a velocidade do vento que com 2 meses de antecedência atingiu $R^2_{ajust} > 0,9$ e RMSE e ES $< 0,9$ m/s. A chuva, mesmo com maior variabilidade no clima Am, obteve um $R^2_{ajust} > 0,62$ e com 12 DEC $R^2_{ajust} > 0,55$ e em ambos RMSE e ES < 30 mm, enquanto no clima Aw com 14 DEC $R^2_{ajust} > 0,70$ e com 12 DEC $R^2_{ajust} > 0,60$ e em ambos RMSE e ES < 50 mm. Conclui-se que a RLM é uma ferramenta eficaz para a previsão de elementos climáticos em escala decendial.

Palavras-chave: agrometeorologia. meteorologia. big data.previsão tempo

MULTIPLE LINEAR REGRESSION TO FORECAST DECENIAL WEATHER FOR AGRICULTURAL PURPOSES

Abstract: Climatic conditions forecast helps in decision making due to its great influence on crops, enabling more efficient production strategies and damages reduction, especially in the most critical corn phenological phases when the productive potential is determined. A multiple linear regression model (MLR) was developed for ten-day forecasting of meteorological elements at least 2 months in advance for 15 locations with emphasis on corn production in Brazil. A set of daily data of average, minimum and maximum air temperature, wind speed, relative humidity and global radiation was provided by the NASA/POWER system and precipitation data was obtained from the National Water Agency (ANA) database (2003 to 2019). The data set was organized into ten days period (DEC) according to the average maize cycle and grouped into two climate classification (Am and Aw). Forecasts with 14 DEC in both weather classification obtained, on average, high accuracy for all elements, with emphasis on the wind speed which, 2 months in advance, reached $R^2_{\text{adjust}} > 0.9$, RMSE and ES < 0.9 m/ s. For rain, even with higher variability, in Am had an $R^2_{\text{adjust}} > 0.62$ and with 12 DEC $R^2_{\text{adjust}} > 0.55$ and in both RMSE and ES < 30 mm and in the climate Aw with 14 DEC $R^2_{\text{adjust}} > 0.70$ and with 12 DEC $R^2_{\text{adjust}} > 0.60$ and in both RMSE and ES < 50 mm. In this way, MLR can serve as an effective tool in predicting climate elements on a ten-day scale.

Keywords: Agrometeorology. meteorology. big data.

LISTA DE ABREVIATURAS E SIGLAS

- Af - Clima equatorial
- Am - Clima tropical de monção
- Arm - Armazenamento
- Aw - Clima tropical com inverno seco
- Big Data - Conjunto de dados com grande volume e complexo
- BHC – Balanço Hídrico Climatológico
- BH - Balanço de água
- CAD – Capacidade de água disponível
- DEC – Decêndio
- DEF – Deficiência Hídrica
- ES - Erro sistemático
- ETR – Evapotranspiração Real
- ETP – Evapotranspiração Potencial
- EXC – Excedente Hídrico
- IA- Inteligência Artificial
- IBGE - Instituto Brasileiro de Geografia e Estatística
- ML - Aprendizado de máquina
- NASA / POWER - NASA's Prediction of Worldwide Energy Resources
- PP - Precipitação
- R^2 - Coeficiente de determinação
- R^2 ajustado - Coeficiente de determinação
- Rg - Radiação Global Diária
- RLM - Regressão Linear Múltipla
- RMSE- Raiz quadrada do erro-médio
- RNA - Redes neurais artificiais
- SVM - Support Vector Machine
- TMAX - Temperatura máxima do ar
- TMED - Temperatura média do ar
- TMIN - Temperatura mínima do ar
- U^2 - Velocidade do vento a 2 metros
- UR - Umidade relativa
- °C - Graus Celsius

LISTA DE FIGURAS

- Figura 1** - Localização geográfica das 15 maiores localidades produtoras de milho no Brasil a ser utilizada neste estudo..... 8
- Figura 2.** Classificação climática para o Brasil, segundo os critérios de Köppen..... 10
- Figura 3** - Fenologia do milho: estádios de desenvolvimento do cultivo de 2 ° safra e organização dos dados observados e dados a serem previstos 12
- 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).... 14
- 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 – U^2 ($m.s^{-1}$); **G e O:** radiação global – Rg ($MJ m^{-2} dia^{-1}$)..... 17
- Figura 6.** 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 Am. Legenda: DEC5 previsão para 5 decêndios antes..., DEC8, DEC10, DEC 12, DEC14, DEC16. 20
- 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. 22
- Figura 8.** Box plot do balanço hídrico sequencial com dados observados pelo método de Penman e Monteith (Allen et al.,1998) em escala decendial para o clima Am e Aw. 25
- 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. 27
- 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. 29
- 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..... 30
- Figura 12.** Desempenho estatístico das interações em relação aos dados observados nos climas Am e Aw na escala decendial 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. 32

1. INTRODUÇÃO

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.

O clima influencia diretamente o desenvolvimento dos cultivos agrícolas que apresentam grandes quebras de produtividade devido a variabilidade das condições meteorológicas (LEE; DANG, 2019). Estudos como de Prasad et al. (2018) reforçam a importância da modelagem meteorológica preditiva para a compreensão das interferências do clima nas culturas e diminuir as incertezas acerca dos cenários climáticos futuros.

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 (SARIMA) (MAHMUD et al., 2016) que previu a chuva de 12 meses para trinta estações pluviométricas, bem como redes neurais artificiais (RNAs) que previram a ocorrência ou não de chuvas maiores de 5 mm em períodos acumulados de 3 a 7 dias para cada estação climática (ESTEVES et al., 2019).

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 e as RNAs para a previsão de temperaturas (FENTE; SINGH, 2018) com 30 dias de antecedência utilizando 10 anos de dados para análise. Outros estudos desenvolveram um modelo Long Short-Term Memory (LSTM) para previsões de variáveis como umidade e radiação solar para 12 meses utilizando uma base de 35 anos de dados (ABAYOMI-ALLI et al., 2019).

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 (AMIRI et al., 2015). Além desses modelos a utilização do balanço hídrico climatológico (BHC) fornece componentes que auxiliam nas estimativas e previsões de produtividade das culturas (PARREIRA et al., 2019).

No estudo realizado por Swain et al. (2017), utilizou-se RLM para previsão de precipitação para um ano de antecedência e obtiveram um coeficiente de determinação ajustado (R^2_{ajust}) de 0,963, demonstrando elevada associação dos dados previstos e observados. As RLM também foram aplicadas nas previsões de radiação solar (SUYONO et al., 2018) e de temperatura do ar (ANJALI et al., 2019), cujo o modelo obteve métricas de erro médio, erro médio absoluto raiz erro quadrático médio (RMSE) e coeficientes de correlação superiores aos modelos de Rede Neural Artificial e 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.

2. REVISÃO DE LITERATURA

2.1 A cultura do milho

O milho (*Zea mays* L.), pertencente à família Poaceae, possui centro de origem genético na América do Norte no México, mas com cultivos distribuídos em diversas regiões do mundo com diferentes climas, manejos e altitudes que variam do nível do mar até 3 mil metros, representando sua importância mundial sendo o terceiro cereal mais produzido no mundo (SILVEIRA et al., 2015; LERAYER, 2018).

A importância econômica do milho está ligada à sua diversidade de uso, estando presente na composição de alimentos e de combustíveis, além de bebidas e polímeros (SILVEIRA et al., 2015). Por possuir um metabolismo fotossintético do tipo C4, ou seja, possui um metabolismo que apresenta alta eficiência na utilização de luz e CO₂ e proporciona alto potencial produtivo, e esse metabolismo é diretamente influenciado pelas radiação, temperatura, precipitação nos processos de fotossíntese, fixação de CO₂ que representa cerca de 90% da matéria seca do milho. Possui um elevado valor nutricional e químico, sendo utilizado na alimentação animal, como de bovinos, caprinos, ovinos e aves, por integrar silagens e rações (FRANCISCO et al., 2017).

O crescente aumento da população mundial só reforça a importância da agricultura para manutenção da sociedade como um todo, dessa forma o fornecimento de alimentos, como na economia de qualquer país, obtém grandes investimentos para implementação de novas tecnologias (JHA, et al., 2019). Com a intensificação da agrotecnologia e a agricultura de precisão em atividades como detecção de plantas daninhas, previsão de colheita, estimativa de produtividade, qualidade da colheita dentre outras aplicações, surgiram as redes neurais artificiais (RNA), aprendizado de máquina (ML) e internet das coisas (IOT), que foram incluídas em um novo modelo de agricultura digital (LIAKOS et al., 2018).

No cenário mundial, o Brasil integra a terceira posição como um dos maiores produtores de milho, atrás somente dos Estados Unidos e China e à frente da União Europeia, Argentina e Ucrânia. No ano de 2019, assumiu o posto de maior exportador do grão passando dos Estados Unidos (USDA, 2020a), tendo como destaque as regiões Centro Oeste e Sul, seguidos por Sudeste,

Nordeste e Norte. A produção e o consumo mundial do grão para a safra de (2018/2019) sofreu um aumento de 3,8% em comparação à safra anterior, com uma produção estimada de 1,118 bilhão de toneladas e consumo de 1,132 bilhão de toneladas de grãos (USDA, 2020b).

No Brasil, o milho possui a segunda maior área cultivada (CONAB, 2018) distribuída em todo território, tendo como destaque as regiões Centro-Oeste, Sudeste e Sul, com produções mais expressivas, possuindo duas safras (inverno e verão) (SALOMÃO, 2015). A segunda safra, em especial, sofre muitas limitações climáticas, com fortes restrições hídricas, térmicas e fototérmicas, sendo cultivadas geralmente entre os meses de janeiro a abril por depender do planejamento do cultivo anterior de verão. A CONAB (2018) estima que a segunda safra supera o plantio de verão com, aproximadamente, 10 milhões de hectares e uma produção em torno de 57 milhões de toneladas.

A safra de 2018/2019 obteve uma produção de 1122,7 milhões de toneladas retratando um aumento de 4,3% em relação à safra de 2017/2018. Porém, apesar do crescente aumento, houve um decréscimo de 7,8% nos estoques mundiais da safra 2017/2018 para a de 2018/2019 (USDA, 2019).

O Brasil apresentou um aumento na produção de 23%, com cerca de 101 milhões de toneladas, levando em consideração a baixa dos Estados Unidos, com diminuição de 1,3% na produção, e da China com 0,7%. Em termos de exportações, o maior exportador mundial são os Estados Unidos com 61,9 milhões de toneladas, em seguida está o Brasil obtendo na safra de 2017/18 uma produção de 25,1 milhões de toneladas, que aumentou para 35 milhões de toneladas na Safra 2018/2019, representando um aumento de 39% entre as safras (USDA, 2019).

2.2 Elementos Climáticos

O clima influencia diretamente no desenvolvimento dos cultivos, no caso do cultivo do milho, especificamente, as alterações nas temperaturas e precipitação em alguns locais afetam a data de semeadura (CHOI et al., 2017) e a necessidade hídrica, ocasionando alterações a cada ano nessas características (LEE; DANG, 2019).

A fenologia do milho em locais com temperaturas mais elevadas, promove um desenvolvimento mais acelerado, com maior acúmulo de graus dias

para completar as fases fenológicas. No entanto, temperaturas altas também podem afetar a produtividade do milho, interferindo na polinização e quando associado ao déficit hídrico, resulta em perdas ainda maiores, onde o aumento de 1°C provoca uma redução de cerca de 10% na produtividade (HATFIELD; DOLD, 2018). Estudos como de Prasad et al. (2018), reforçam a importância da modelagem para a compreensão das anomalias agrônômicas que se intensificarão com os anos, necessitando de estratégias de manejo nos cultivos.

2.3 NASA/POWER

A utilização do banco de dados fornecido pelo NASA/POWER foi avaliado no estudo de Monteiro et al. (2018), onde constataram uma confiabilidade razoável dos dados climáticos para escalas espaciais, regionais e nacionais, utilizando temperatura média do ar (TMED) ($R^2= 0,73$; $d = 0,91$), temperatura mínima do ar (TMIN) ($R^2= 0,72$; $d = 0,91$), temperatura máxima do ar (TMAX) ($R^2= 0,57$; $d = 0,84$), radiação solar (Rg) ($R^2= 0,71$; $d = 0,92$) e evapotranspiração de referência calculada pelo método de Priestley-Taylor (ET0-PT), ($R^2= 0,76$; $d = 0,93$). Dessa forma, é uma ferramenta confiável e com a vantagem de fornecer dados de forma gratuita, suprimindo a deficiência de dados climáticos em locais com ausência de estações ou grande falha de dados de longas séries históricas.

Valeriano et al. (2019) observaram boa acurácia entre os dados de superfície e os dados em GRID da NASA POWER, em escala decenal para as variáveis de temperatura e precipitação em séries longas, nos estados de São Paulo e Minas Gerais. Assim como suscitado por Duarte et al. (2020), onde constataram bons valores de estimativa de produtividade de cultivo com a utilização de dados fornecidos por essa base.

2.4 Importância da Modelagem

O processo de produção de alimentos na agricultura envolve diversos fatores e interações complexas, nesse contexto há diversas técnicas utilizadas a fim de maximizar e assegurar a produtividades dos cultivos, sendo a modelagem matemática uma forma de descrever essas interações (MAMANN et al., 2018). A compreensão desses fenômenos biofísicos juntamente com essas interações é essencial para a modelagem agrícola, dando base na elaboração de ferramentas de suporte que virão facilitar as tomadas de decisões

estratégicas nas operações em campo de forma rápida (KÖPP et al., 2015).

Essas ferramentas já vem sendo empregadas na cultura do milho como o caso de Buske et al. (2019) que utilizaram os modelos de Jensen (1968), Minhas et al. (1974) e Doorenbos e Kassan (1979) na estimativa da produtividade de milho para a microrregião de Cruz Alta, RS. Estudos com milho também foram realizados por Ameline et al. (2018), com o modelo SAFY-WB (algoritmo simples para modelo de produtividade combinado com balanço de água) associado a imagens de satélite para a estimação de produtividade de milho, e por Baup et al. (2019) que utilizaram o mesmo modelo para estimativas diárias de massa seca de milho.

Na modelagem, a acurácia dos resultados é de extrema importância para confiabilidade do modelo, mas apesar de haver diversos modelos de simulação de cultivos, ainda existem baixas correlações entre os manejos utilizados nos cultivos e o sistema solo-planta-atmosfera, necessitando de modelos mais eficientes e robustos (MAROLLI et al., 2018).

2.4.1 Big Data

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 (LIM; ZOHREN, 2021). Aliado a essas modernizações e o crescimento dos big data, proporcionou analisar agrupamentos de dados maiores abrangendo diferentes áreas da ciência, engenharia, finanças, economia e, principalmente, na agricultura (LIM; ZOHREN, 2021).

Big data é um termo utilizado para as análises realizadas com um grande volume de dados que norteiam as tomadas de decisão, sendo amplamente aplicado em diferentes áreas como saúde, economia, segurança e entre outras, porém sua utilização na agricultura ainda é algo recente e com uma ampla área a ser explorada (KAMILARIS; PRENAFETA-BOLDÚ, 2018; EMROUZNEJAD; CHARLES, 2019).

2.4.2 Regressão Linear Múltipla (RLM)

A Regressão Linear Múltipla (RLM) é um dos métodos estatísticos e matemáticos clássicos utilizados para descrever relações entre variáveis dependentes e independentes, ou seja, correlacionando diferentes variáveis a fim

de obter uma relação matemática entre elas e as possíveis interferências que uma poderia causar na outra (AZADI et al., 2016). As variáveis independentes são denominadas como variáveis de entrada e as variáveis dependentes são denominadas como variáveis de saída (CHANTANA et al., 2017).

Cada variável de entrada interfere no valor de saída, tomando como base a associação entre elas, tendo em vista a grande relação entre os coeficientes das variáveis dependentes e independentes. O valor do coeficiente obtido na regressão para cada variável na modelagem é multiplicado pelo parâmetro obtido equivalente, posteriormente é realizado a somatória para determinar o parâmetro previsto, para enfim verificar qual variável possui o maior valor e maior influência no valor previsto (MASHALY et al., 2016).

2.5 Balanço Hídrico Climatológico Sequencial

O Balanço Hídrico Climatológico (BHC) é uma ferramenta que, de maneira simplificada, contabiliza o balanço de água no solo, ou seja, as entradas e saídas de água, possibilitando a caracterização do clima de uma região. As informações geradas pelos métodos desenvolvido por Thornthwaite (1948) e Thornthwaite e Mather (1955), serviram de base para compreender a correlação das variáveis climáticas com as culturas, o que proporcionou uma agricultura mais eficiente para os sistemas de irrigação e manejo da cultura (PARREIRA et al., 2019).

Esse balanço de água (BH) no solo pode ser calculado utilizando valores médios de precipitação e evapotranspiração de um local, sendo caracterizado como BHC Normal. O BHC Normal serve como indicativo climático da disponibilidade de água no local, através da variabilidade sazonal do balanço hídrico no decorrer de um ano médio (cíclico), contabilizando os períodos de deficiências e excedentes hídricos (COSTA et al., 2019).

O BHC também pode ser elaborado utilizando valores de precipitação e evapotranspiração de um período específico ou de uma sucessão de períodos (meses, semanas, dias) de um local específico, sendo identificado como BHC Sequencial. Esse tipo de BHC fornece as mesmas informações de deficiências e excedentes, porém, ao longo de um período determinado. Ambos os métodos são de grande importância no fornecimento de informações que auxiliam nas tomadas

de decisão (COSTA et al., 2019).

3. MATERIAL E MÉTODOS

3.1 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).

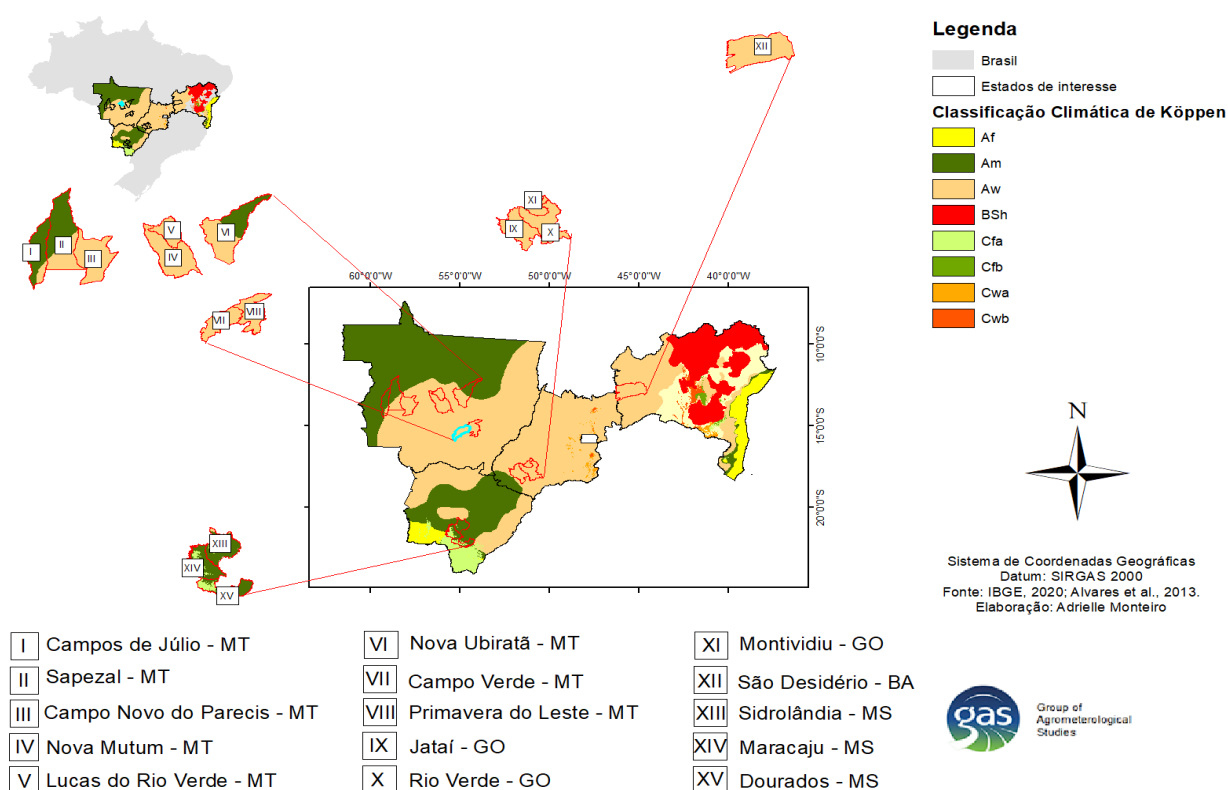


Figura 1 - Localização geográfica das 15 maiores localidades produtoras de milho no Brasil utilizada neste estudo.

Fonte: Elaborado pelos autores (2022).

3.2 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).

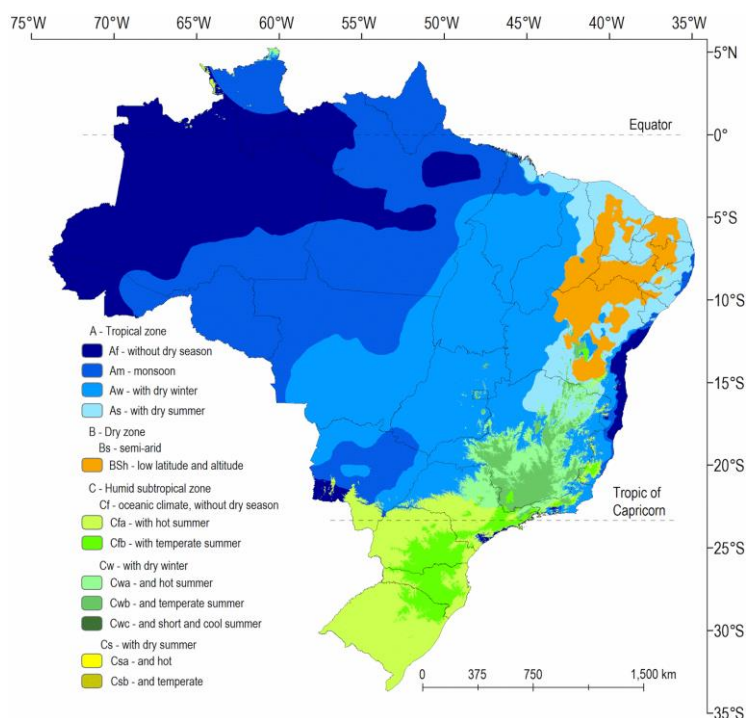


Figura 2. Classificação climática para o Brasil, segundo os critérios de Köppen. Fonte: Alvares et al. (2013)

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).

3.3 Dados Meteorológicos

Devido à baixa cobertura de estações meteorológicas 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 (U2, m s⁻¹), umidade relativa (UR, %), e Radiação Global Diária (Rg, 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).

3.4 Análise de dados

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 estágio 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).

CULTURA DO MILHO 2 ° SAFRA																		
FASES		FASE VEGETATIVA							FASE REPRODUTIVA									
MESES	JAN	FEV		MAR			ABR		MAI		JUN							
ESTÁDIO											Bolha D'água	Grão Leitoso	Grão Pastoso	Formação de dente				
			Semeadura	Emergência	Três Folhas	Três Folhas	Sete Folhas	Dez Folhas	Doze Folhas	Pendoamento	Florescimento					Maturação Fisiológica		
ITERAÇÃO	DECÊNDIOS																	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
1	DADOS METEOROLÓGICOS DECENIAIS DO ANO PREVISTO																	
2																		
3																		
4																		
5																		
6																		
	DADOS METEOROLÓGICOS DECENIAIS DO ANO ATUAL																	

Figura 3 - Fenologia do milho: estádios de desenvolvimento do cultivo de 2 ° 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.

3.4.1 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):

$$ET_{oPM} = \frac{0,408 \times s \times (R_n - G) + \frac{\gamma \times 900 \times U_2 \times (e_s - e_a)}{T + 273}}{s + \gamma \times (1 + 0,34 \times U_2)} \quad (2)$$

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

no qual s é a declividade da curva de pressão de vapor em relação à temperatura (kPa °C); Rn 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):

$$ET_{oC} = 0,01 \times \frac{Q_o}{2,45} \times T \times ND \quad (4)$$

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

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

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

no qual Q_o é a irradiação solar extraterrestre ($MJ \cdot m^{-2} \cdot d^{-1}$), ND é o número de dias, hn é a hora que ocorre o nascer do sol, ϕ é a latitude (°), δ é a declinação solar (°), NDA é o dia Juliano, DR é a distância relativa Terra-Sol.

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

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

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

em que W é o fator de peso dependente da temperatura e do coeficiente psicrométrico (°C) e Tu é a temperatura do bulbo úmido (°C).

3.4.2 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 Thornthwaite 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.

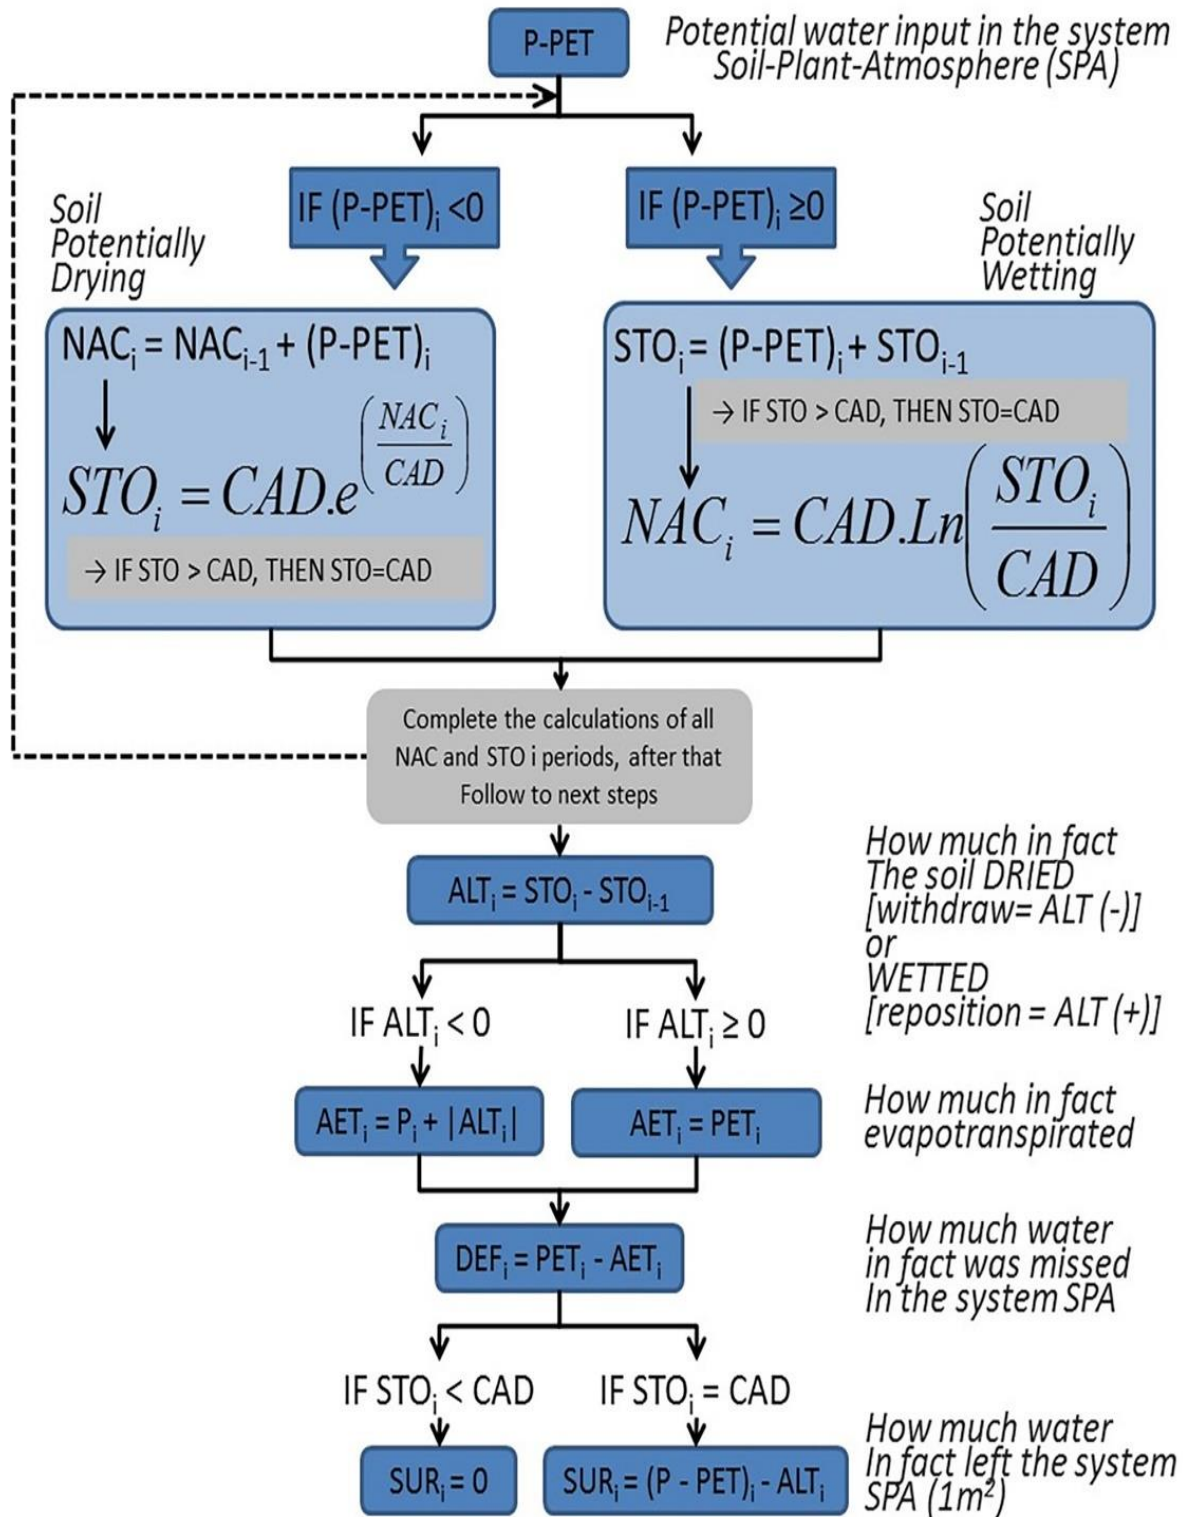


Figura 4. Fluxograma do modelo de balanço hídrico modificado de Thornthwaite e Mather (1955). CAD é a capacidade de água do solo (mm), NAC é o acumulado negativo (mm), ou seja, o potencial de secagem do solo, ALT é a alteração no STO, i é um determinado período, i - 1 é o período anterior. Adaptado de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

3.5 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_{obsi} é o valor observado e N corresponde ao total de observações e K o número de variáveis independentes.

4. RESULTADOS E DISCUSSÃO

4.1 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 m.s⁻¹ ($\pm 8,7$ m.s⁻¹) (Figura 5F) para o clima Am e 1,24 m.s⁻¹ ($\pm 0,69$ 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 MJ.m⁻².dia⁻¹ ($\pm 2,4$ MJ.m⁻².dia⁻¹), enquanto nas de clima Aw alcançou 18,37 MJ.m⁻².dia⁻¹ ($\pm 2,12$ MJ.m⁻².dia⁻¹). Para os dois climas, o mês de junho foi o que recebeu a menor radiação com 13,64 MJ.m⁻².dia⁻¹ ($\pm 3,2$ MJ.m⁻².dia⁻¹) (Am) e 16,39 MJ.m⁻².dia⁻¹ ($\pm 2,8$ MJ.m⁻².dia⁻¹) (Aw).

Clima Am: Campos Júlio; Dourados; Sapezal; Sidrolândia; Maracaju. **Clima Aw:** Campo Novo dos Parecis; Campo Verde; Jataí; Rio Verde; N. Mutum; Lucas do Rio Verde; Montividiu; N. Ubitatã; Primavera do Leste; São Desidério.

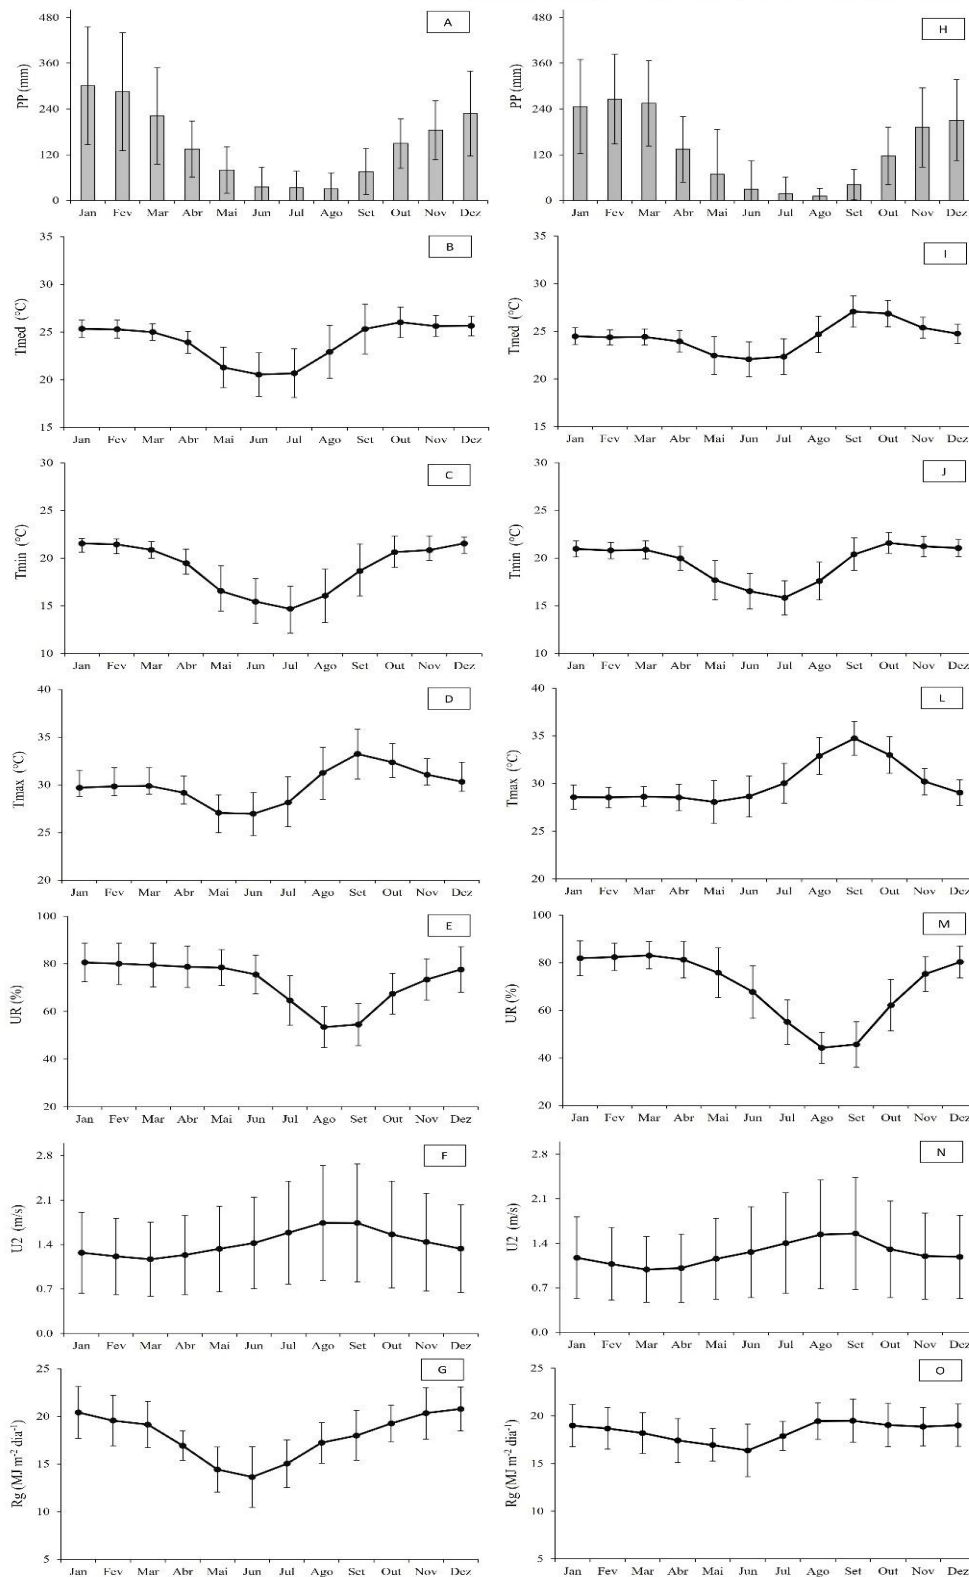


Figura 5. Variabilidade média mensal das condições meteorológicas durante 2003 a 2019 nos locais de clima Am e Aw. **A e H:** precipitação - PP (mm); **B e I:** temperatura média do ar – Tmed (°C); **C e J:** temperatura mínima - Tmin (°C); **D e L:** temperatura máxima - Tmax (°C); **E e M:** umidade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

4.2 Clima de tipo Am

Analisando a variabilidade das previsões de precipitação por meio das métricas de avaliação (Figura 6A e 6C), foi possível observar que os erros foram diminuindo a cada estimativa de decêndio, ocorrendo pouca variação em todas as interações, com valores de erros abaixo de 35 mm nas estimativas com 2 meses de antecedência (utilizando 12 DEC). O R^2_{ajust} teve maior variação na comparação entre as estimativas com maior e menor número de dados observados. O melhor desempenho foram as estimativas de chuva com 16 DEC de dados observados (0,68 e 0,64), contudo os dados preditos com 14 DEC também apresentaram R^2_{ajust} aceitável ($> 0,64$) e com 2 meses de antecedência obteve correlação acima de 0,50 com exceção do DEC 13 que apresentou R^2_{ajust} de 0,30 (Figura 6B).

A precipitação é uma variável com grande variabilidade, em virtude disso apresenta grande dificuldade de gerar estimativas de seus valores. No entanto, ao organizar em escala decendial, esse efeito sofreu uma diminuição possibilitando a introdução de novos preditores para uma melhor correlação dos valores e diminuição dos erros. Dessa forma, é possível obter dados satisfatórios com 2 meses de antecedência que podem ser introduzidos em modelos de simulação de produtividade de culturas.

Os valores de RMSE e SE de temperatura média do ar (TMED) nas estimativas com 12 e 14 preditores se mantiveram abaixo de 3,5 °C. Com exceção do 13 DEC, as estimativas com 12 decêndio (RMSE = 5,0 °C e SE = 4,9 °C) apresentaram $R^2 > 0,60$ e $R^2 > 0,80$ com 12 e 14 preditores, respectivamente (Figura 6D, 6E e 6F).

As métricas da temperatura mínima (TMIN) (Figura 6G, 6H e 6I) e temperatura máxima (TMAX) (Figura 6J, 6K e 6L) tiveram variabilidade semelhante como as da TMED. Apresentaram maiores erros nas estimativas do 13 DEC utilizando 12 DEC de dados observados com valores de RMSE = 6,5 °C e SE = 6,4 °C para TMIN e RMSE = 3,9 °C e SE = 3,8 °C para TMAX. Nos demais decêndios, ambas obtiveram o RMSE abaixo de 3,5°C e o SE menor que 3,8°C. O coeficiente de correlação com 2 meses de antecedência na TMIN obteve um valor acima de 0,75 e na TMAX acima de 0,60, com 14 DEC o R^2 ficou acima de 0,76 na TMIN e na TMAX ficou com R^2 superior a 0,77.

As menores variações nos valores de temperaturas possibilitaram maiores valores de correlação nas estimativas com 12 decêndios, acima de 0,60, e com 14 decêndios, acima de 0,70, chegando a obter 0,80 na temperatura média. Os resultados obtidos foram próximo dos observados por Anjali et al. (2019), que ao comparar o modelo de RLM com Rede Neural Artificial (RNA) e Support Vector Machine (SVM), verificaram que a RLM obteve melhor desempenho com coeficiente de correlação de 0,81 e RMSE de 1,85.

Os erros de umidade relativa (Figura 6M e 6O) e de radiação global (Figura 6R e 6U) indicaram uma boa capacidade do modelo de acompanhar as variações dessas variáveis com 16 decêndios (16 DEC) de dados até com apenas 5 decêndios.

O coeficiente de correlação na variável umidade relativa (UR) apresentou diminuição na similaridade dos dados com o avanço dos decêndios com 2 meses de antecedência, e da radiação global (Rg) foi observado o comportamento inverso. Com 14 preditores, a UR obteve $R^2 > 0,74$ (Figura 6N), enquanto a Rg obteve $R^2 > 0,57$ (Figura 6T). Além de obter valores de Rg abaixo de $6,0 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ com 2 meses, o desempenho se repetiu em trabalhos como o de Suyono et al. (2018), onde conseguiram alcançar RMSE de radiação global de $8,81 \text{ MJ.m}^{-2}.\text{dia}^{-1}$ em escala anual, utilizando a RLM.

A velocidade do vento (U^2) foi a variável que apresentou melhor desempenho pelo modelo, com valores de RMSE e SE, nas estimativas com 12 e 14 DEC preditores, abaixo de $0,9 \text{ m.s}^{-1}$, e elevada correlação, acima de 0,9, em todos os valores preditos e em todas as interações realizadas (Figura 6P, 6Q e 6R). Nos trabalhos de Barhmi et al. (2020), os valores de correlação foram igual a 0,996 corroborando com a boa capacidade do RLM nesta variável.

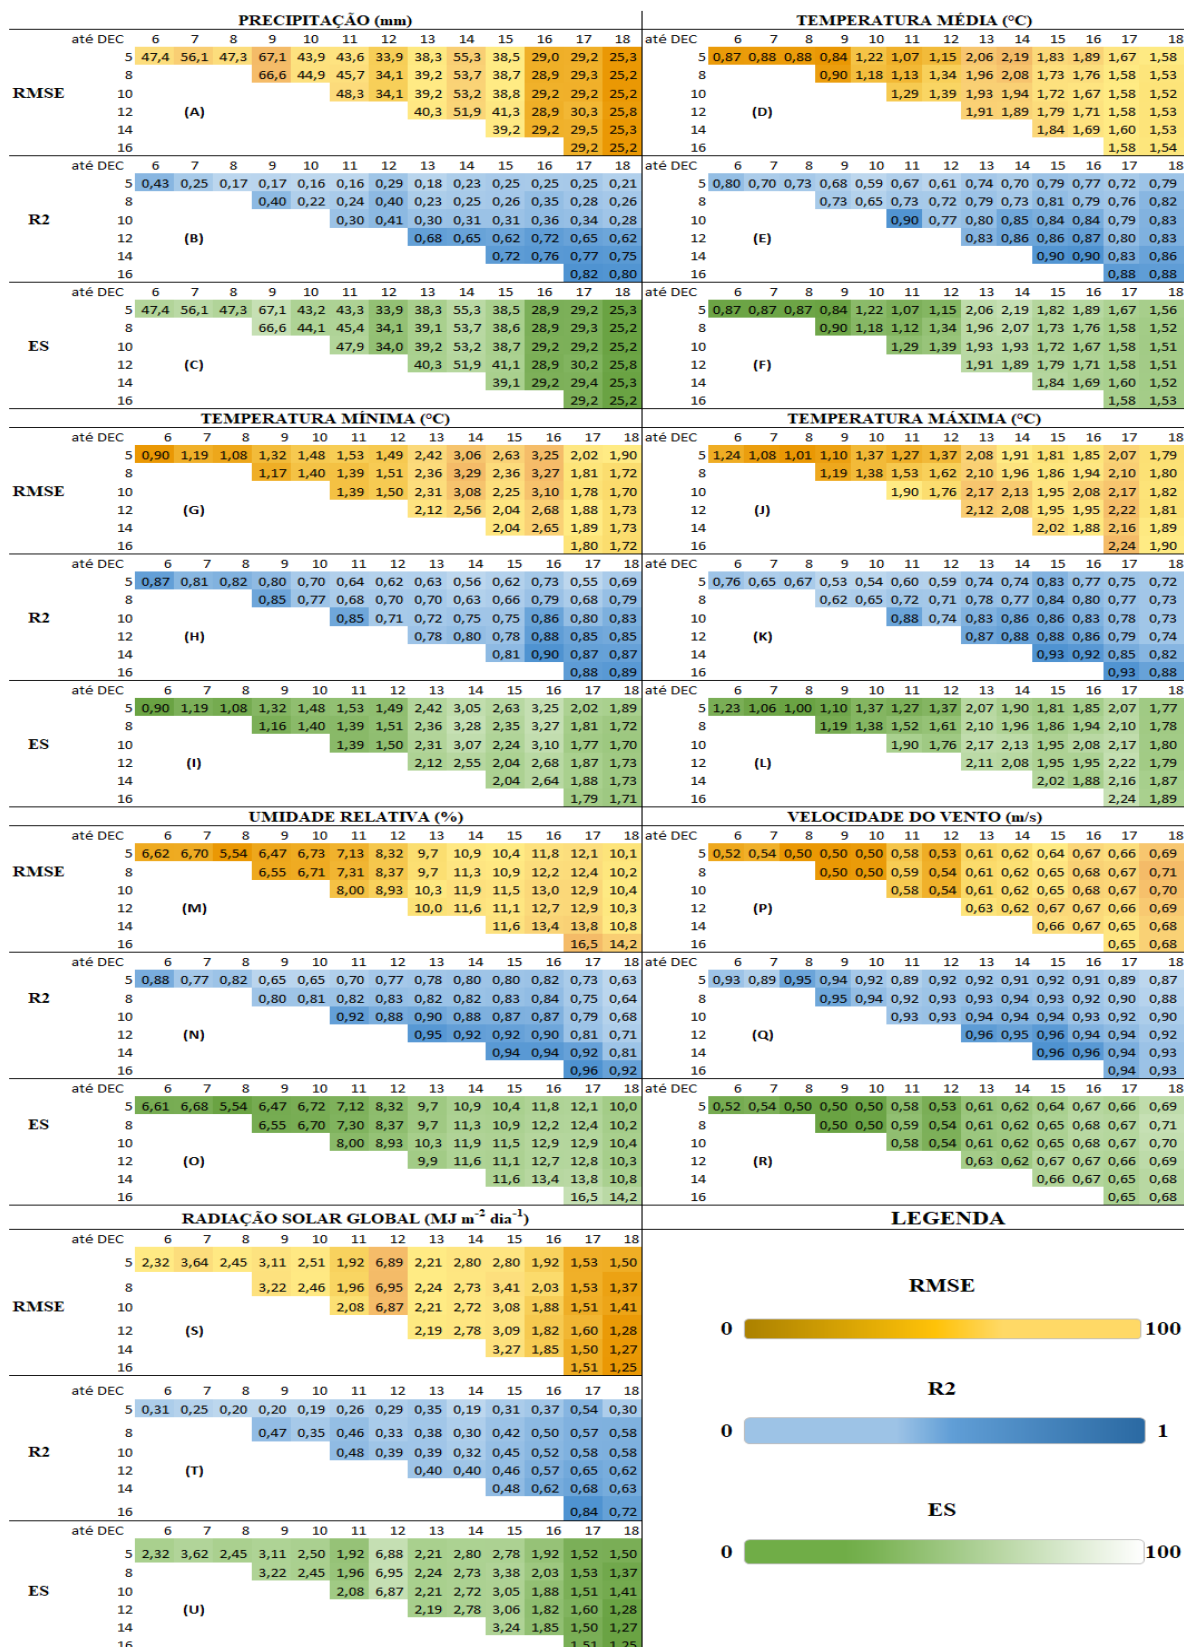


Figura 6. Avaliação de modelos de previsão decendial de elementos meteorológicos utilizando coeficiente de determinação (R^2 ajustado), raiz do erro quadrático médio (RMSE) e erro sistemático (ES) das cidades de clima Am. Legenda: DEC5 previsão para 5 decêndios antes da colheita, DEC8, DEC10, DEC12, DEC14, DEC16.

4.3 Clima de tipo Aw

Um padrão semelhante ao clima Am foi verificado na precipitação das cidades do clima Aw, onde o RMSE e SE (Figura 7A e 7C) também apresentaram ação decrescente em todos os tratamentos com baixa variação de valores, obtendo um desempenho inferior com erros abaixo de 50 mm nas duas métricas. A correlação dos dados de chuvas com 2 meses de antecedência, apresentou $R^2_{ajust} > 0,62$ e, com 1 mês e 10 dias (14 DEC), o R^2_{ajust} foi acima de 0,73 (Figura 7B).

Os erros nas variáveis de temperatura média (Figura 7D e 7F), mínima (Figura 7G e 7I) e máxima (Figura 7J e 7L), nas cidades do clima Aw, apresentaram valores preditos com 12 e 14 decêndios menores que as do clima Am, com RMSE e SE abaixo de 2,0 °C na TMED e abaixo de 3,0 °C na TMIN e TMAX. A correlação obtida foi acima de 0,80 em todos os decêndios preditos com 2 meses e 1 mês e 10 dias de antecedência na TMED (Figura 7E), enquanto a TMIN apresentou $R^2 > 0,77$ e $R^2 > 0,80$ com 12 e 14 decêndios de dados preditores, respectivamente (Figura 7H). Com relação a TMAX, a correlação foi maior que 0,80, com 12 e 14 decêndios de dados preditores, respectivamente (Figura 7K), demonstrando uma melhor concordância dos valores gerados pelo modelo com os dados observados.

O modelo de RLM teve uma boa performance em prever a UR (Figura 7M e 7O) e Rg (Figura 7R e 7U) no clima Aw, apresentando valores de erros abaixo de 10 % e 3 MJ.m⁻².dia⁻¹. A previsão dos dados de UR com 12 preditores obteve $R^2_{ajust} > 0,9$ nos decêndios 13,14,15 e 16, porém a correlação diminuiu até atingir R^2_{ajust} de 0,72 no 18 DEC, onde mesmo assim, indica um bom desempenho do modelo. A RLM não teve a mesma performance na correlação dos dados de Rg, apresentando $R^2_{ajust} > 40$ (Figura 7N), aumentando a cada decêndio previsto (Figura 7T).

A variabilidade da velocidade do vento (U^2), assim como no clima Am, teve um elevado desempenho nas previsões com erros abaixo de 0,7 m.s⁻¹, nos valores preditos com 2 meses e 1 mês e 10 dias de antecedência (Figura 7P e 7R). Além de obter correlação com R^2_{ajust} acima de 0,9 em todos os decêndios previstos (Figura 7Q). Esses dados corroboram com os evidenciados por Kayri et al. (2017), com correlação de 0,96 utilizando RLM.

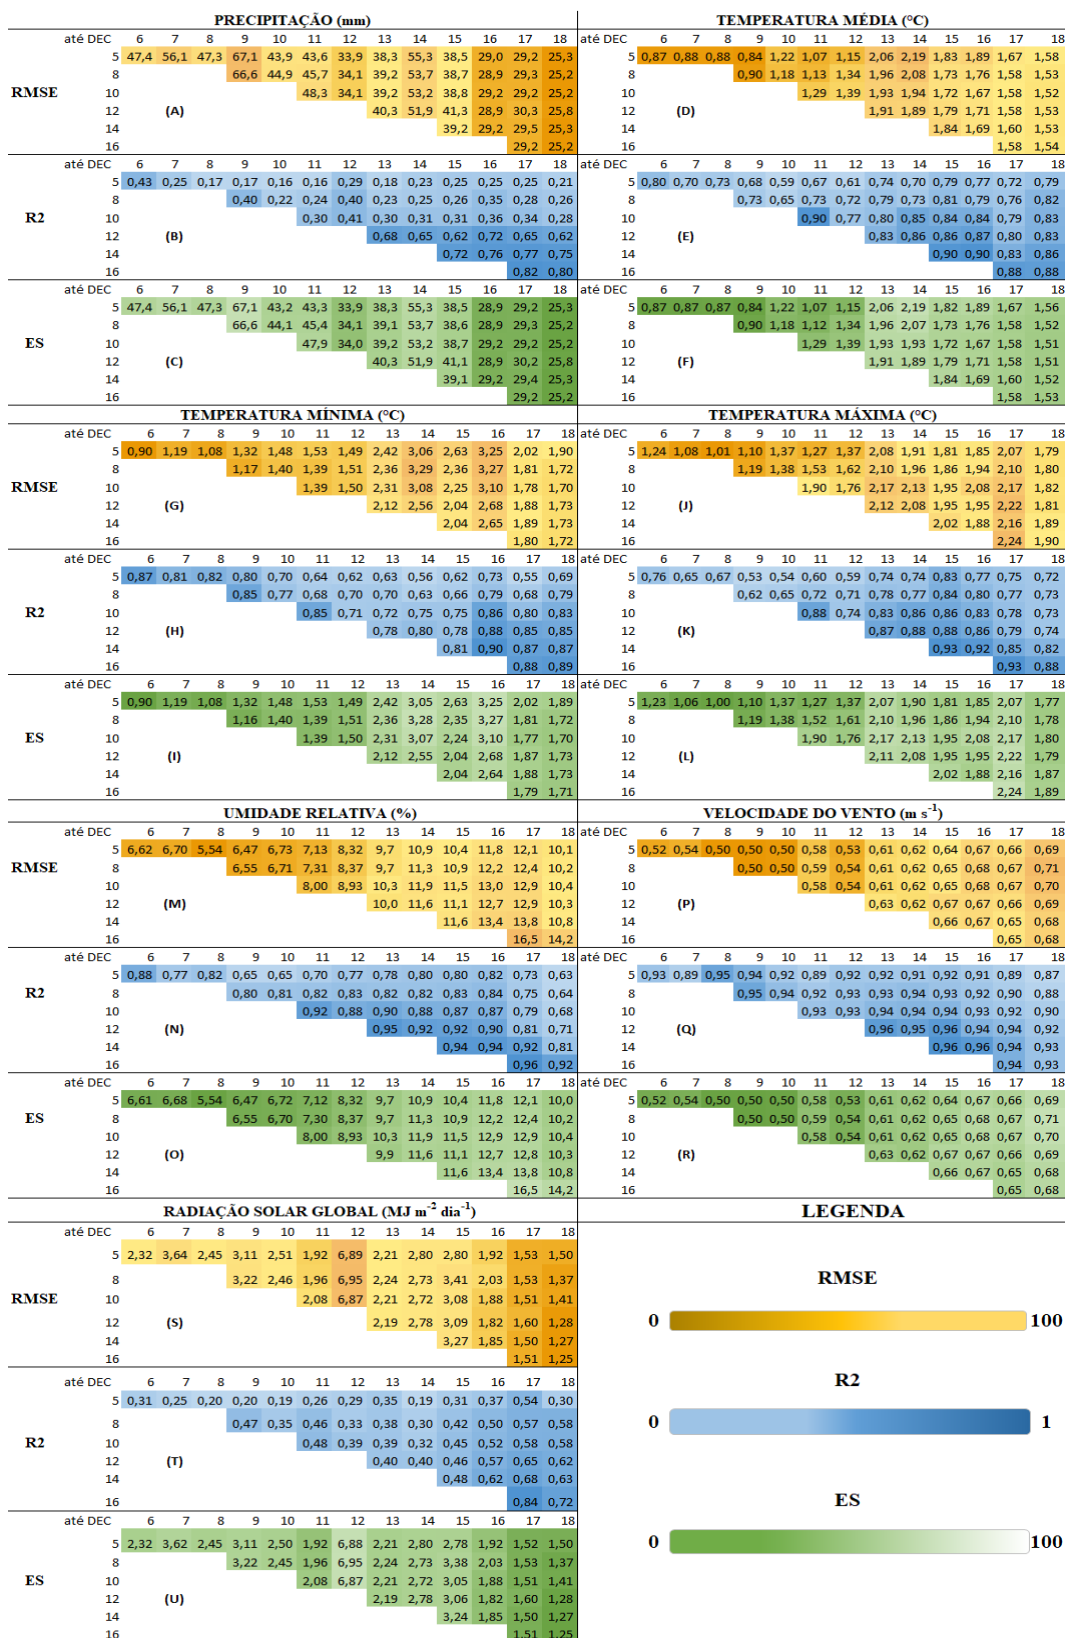


Figura 7. Avaliação de modelos de previsão decenal de elementos meteorológicos utilizando coeficiente de determinação (R^2 ajustado), raiz do erro quadrático médio (RMSE) e erro sistemático (ES) das cidades de clima Aw. Legenda DEC5 previsão para 5 decêndios antes..., DEC8, DEC10, DEC 12, DEC14, DEC16.

4.4 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.

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, conseqüentemente 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).

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, Martins et al. (2015) e Aparecido et al. (2018) 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 (APARECIDO et al., 2020).

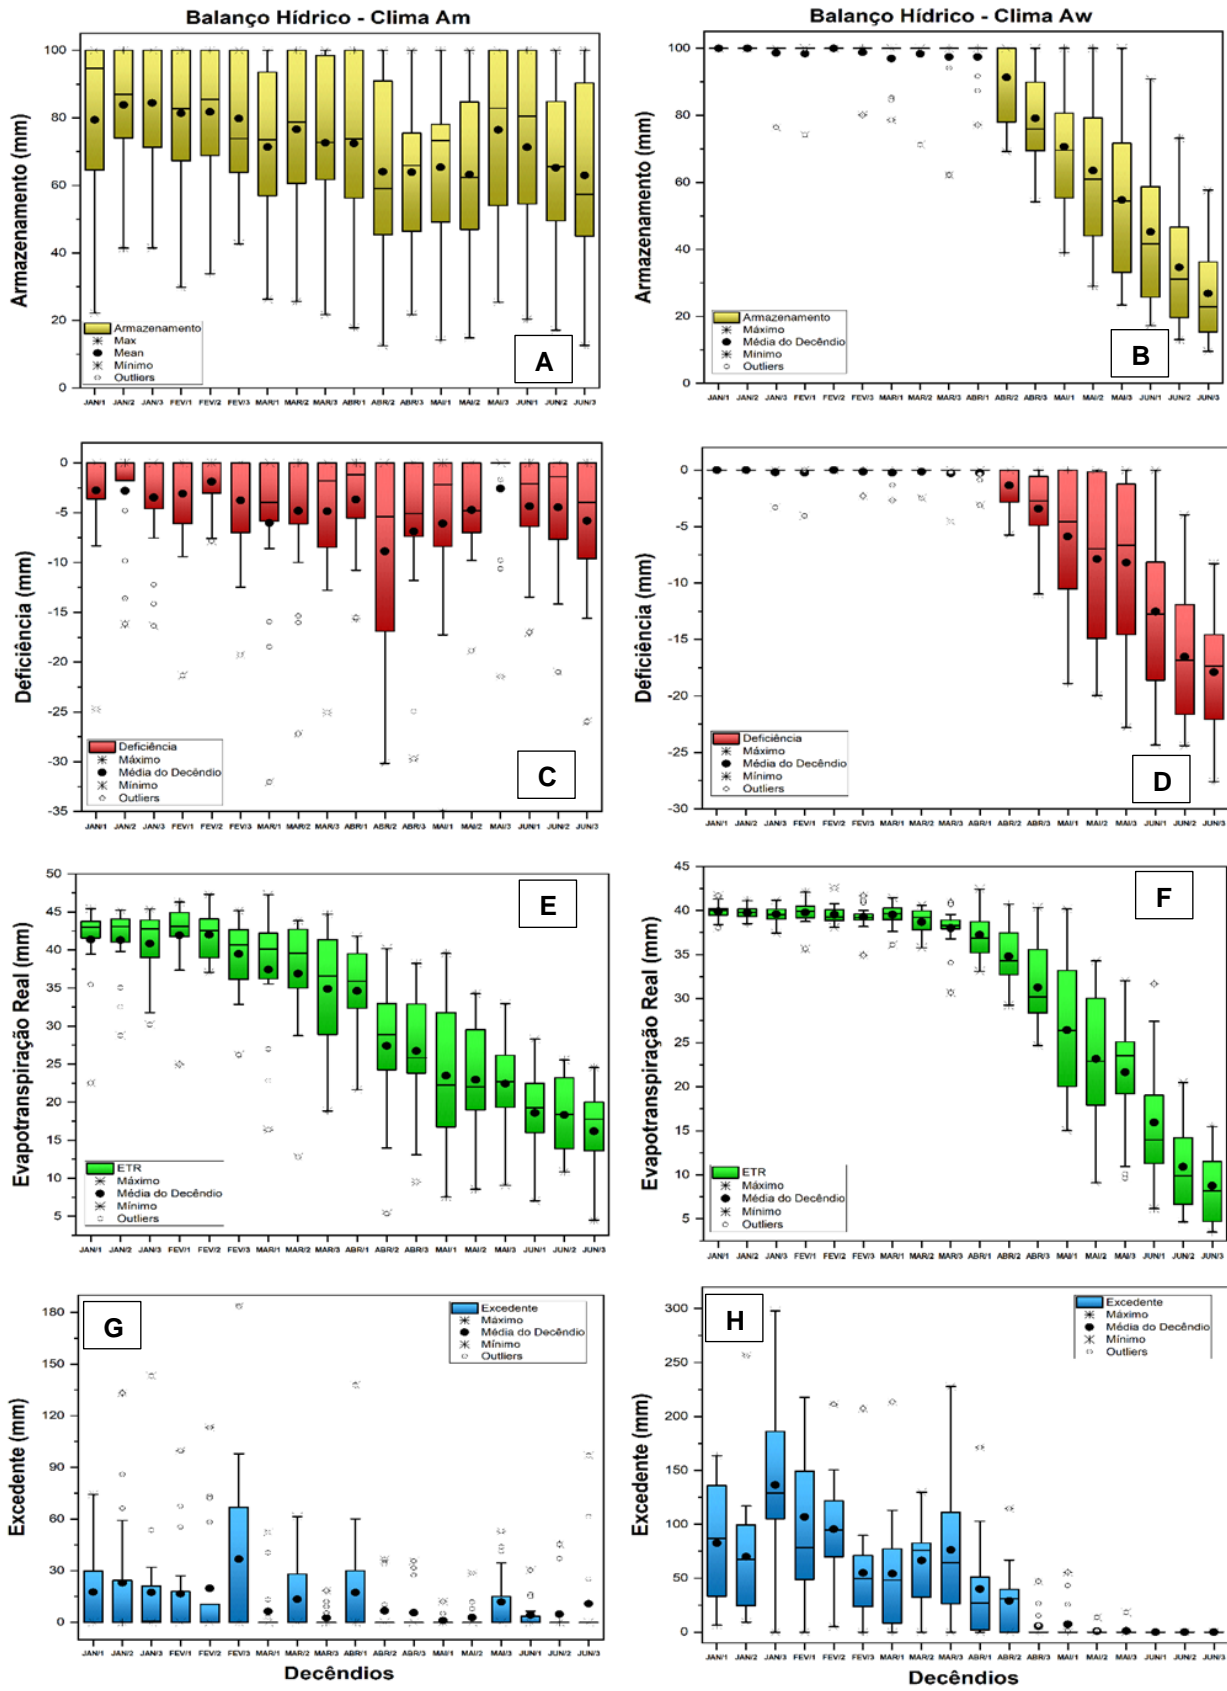


Figura 8. Box plot do balanço hídrico sequencial com dados observados pelo método de Penman e Monteith (Allen et al.,1998) em escala decenal para o clima Am e Aw.

Observando a correlação dos componentes do balanço hídrico calculados utilizando os três tipos de método de estimação de evapotranspiração potencial para as cidades de clima Am, foi possível identificar maior correlação dos valores de armazenamento e excedente do método de Camargo com o modelo da FAO (Figura 9B e 9H). Já o método de Priestley e Taylor teve maior precisão com os dados de deficiência e evapotranspiração real em relação ao método padrão (Figura 9C e 9E).

Embora com o método de Priestley e Taylor tenha obtido valores de deficiência e evapotranspiração ($R^2 = 0,75$ e $R^2 = 0,84$) mais próximo do modelo da FAO, a diferença foi mínima nos valores obtidos pelo método de Camargo com $R^2 = 0,73$ e $R^2 = 0,78$. Dessa forma, o modelo de Camargo é mais acessível para avaliar as previsões no clima Am, por necessitar de um número menor de variáveis de entrada para o cálculo do balanço hídrico, pois leva em consideração apenas valores de TMED e PP, enquanto que o método de Priestley e Taylor necessita de dados de TMAX, TMIN, UR, U² e PP.

Ferreira et al. (2020) em seu estudo realizado no estado do Amazonas, indica que o método de estimativa de ETP de Camargo apresenta melhores desempenhos em climas úmidos por ser mais sensível as variáveis.

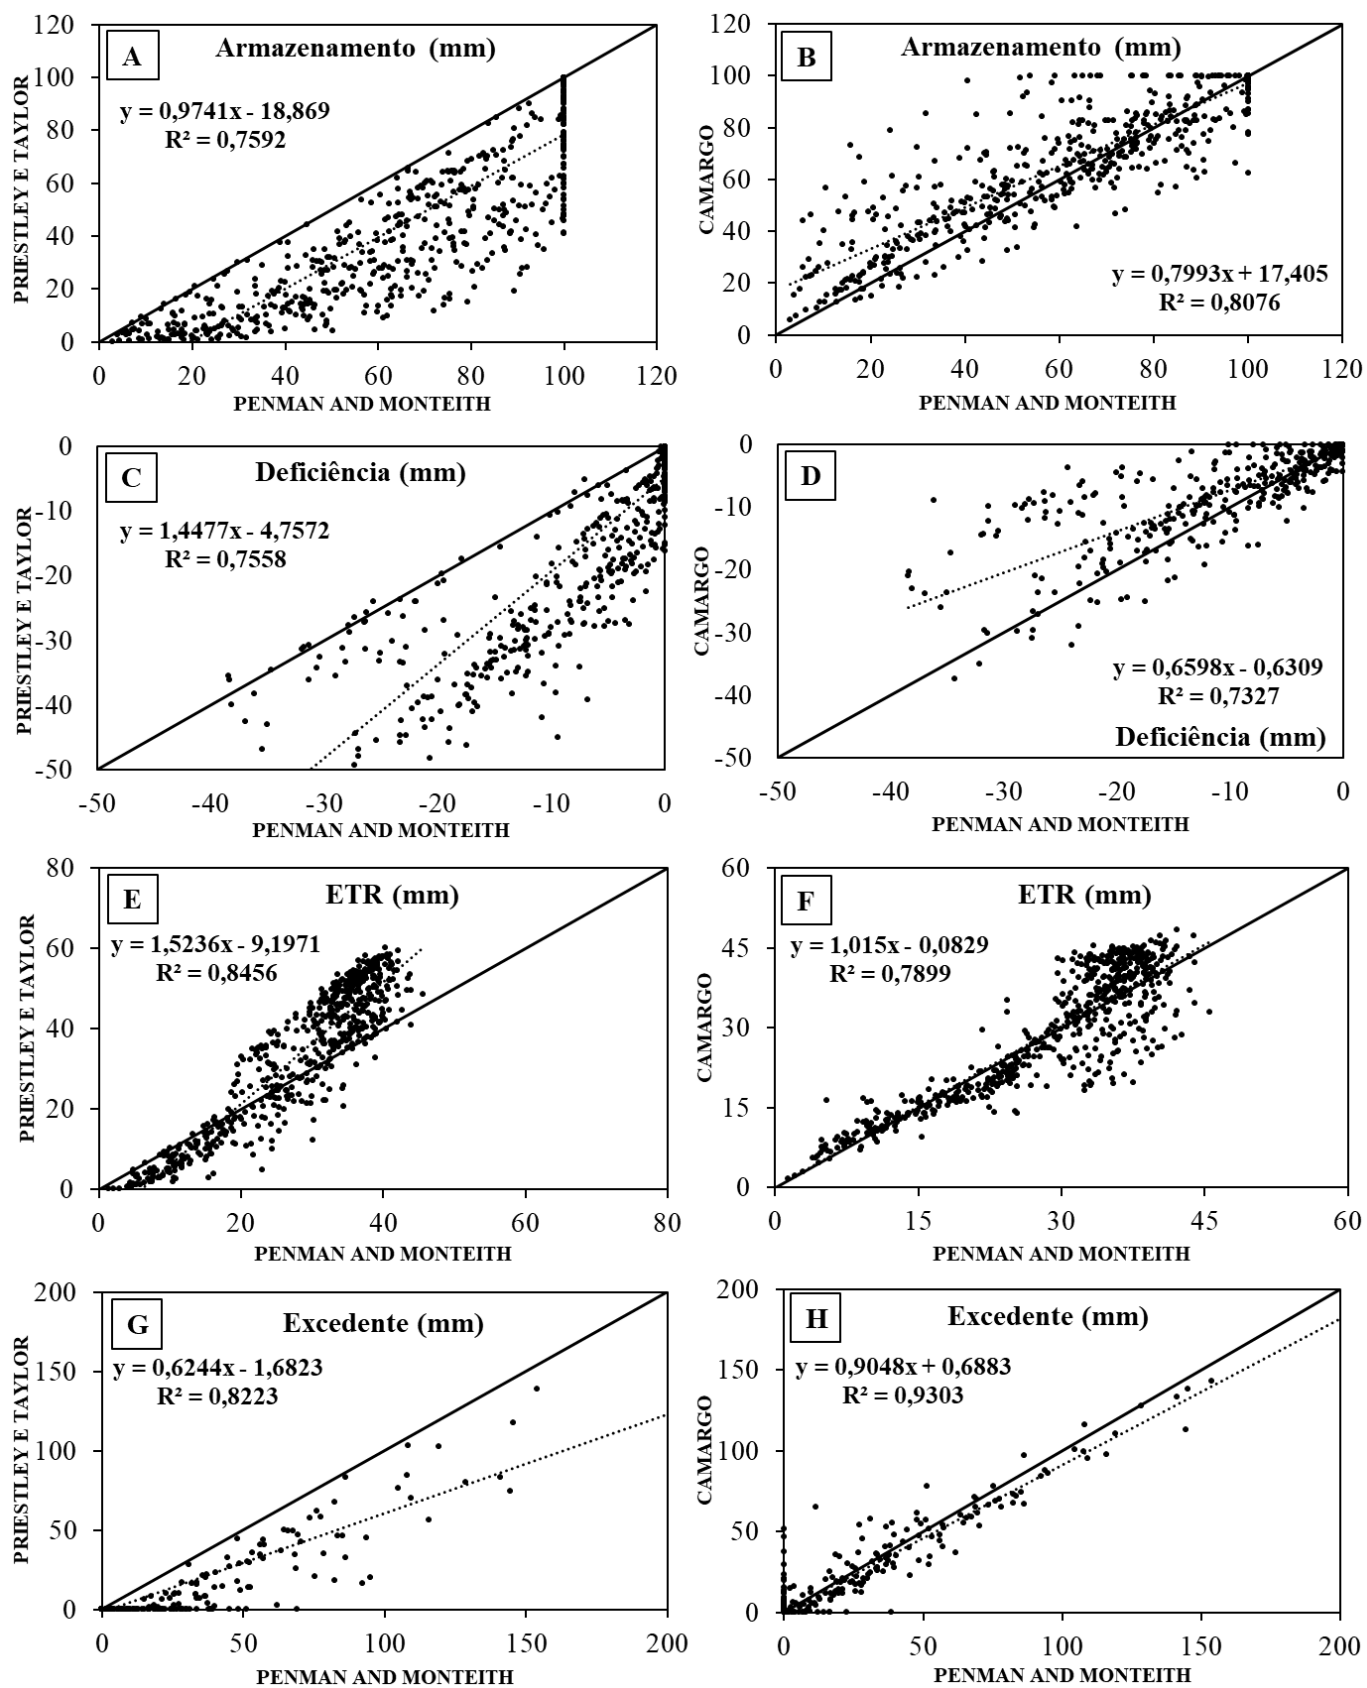


Figura 9. Desempenho entre os dados decendiais do balanço hídrico do clima Am calculados pelo método de Penman and Monteith e os modelos de Camargo e Priestley-Taylor.

No clima Aw foi possível observar que o método de Camargo teve uma precisão superior ao método de Priestley e Taylor, em quase todos os componentes do balanço hídrico como o armazenamento (Figura 10B), deficiência (Figura 10D) e excedente (Figura 10H), com exceção da evapotranspiração real (Figura 10F) que obteve uma correlação de R^2 0,93, um pouco inferior a obtida pelo método de Priestley e Taylor de R^2 0,94 (Figura 10E). Sendo assim, o método de Camargo é o mais indicado para o cálculo de BH com os valores previstos para o clima Aw.

Ao comparar o desempenho dos métodos nos dois tipos climáticos, observa-se uma maior variabilidade dos componentes do balanço no clima Am, influenciando em um menor desempenho nas correlações. O principal fator que pode ter influenciado essa variação é a temperatura, porque no clima Am se mostrou superior em relação ao clima Aw (Figura 11).

Segundo Drake et al. (2018), 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).

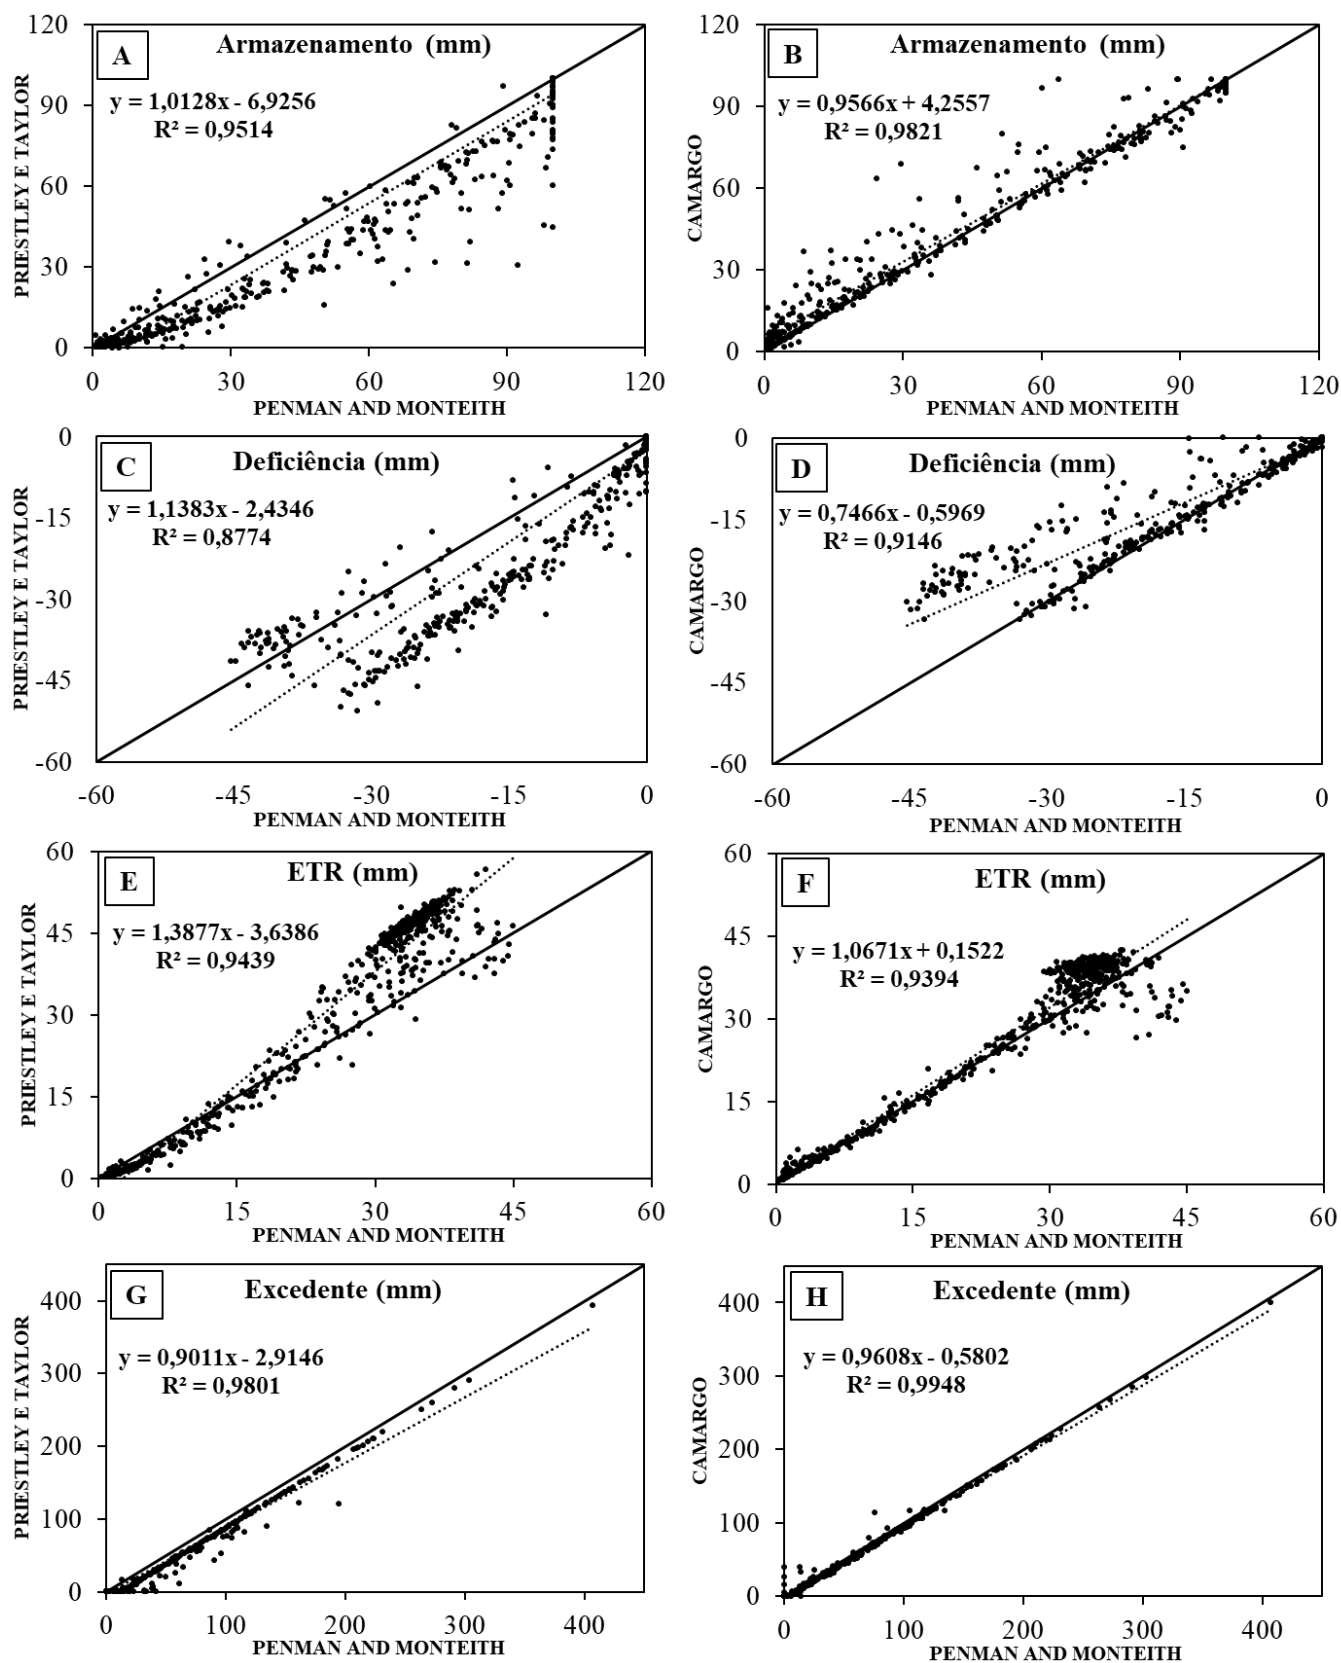


Figura 10. Desempenho entre os dados decendiais do balanço hídrico do clima Aw calculados pelos modelos de Camargo e Priestley-Taylor em relação ao método de Penman-Monteith.

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 Nobre e Assad (2005), 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.

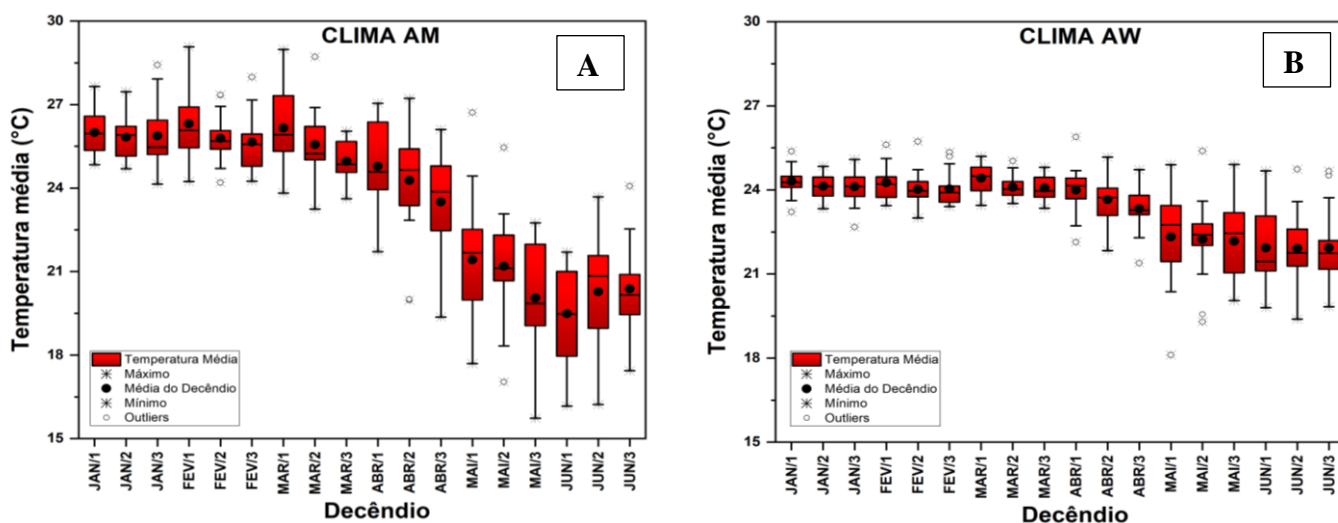


Figura 11. Box plot dos dados observados de temperatura em escala decencial para a cidade de Campo Novo dos Parecís do clima Aw e Sidrolândia do clima Am no período de 2003 a 2019.

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.

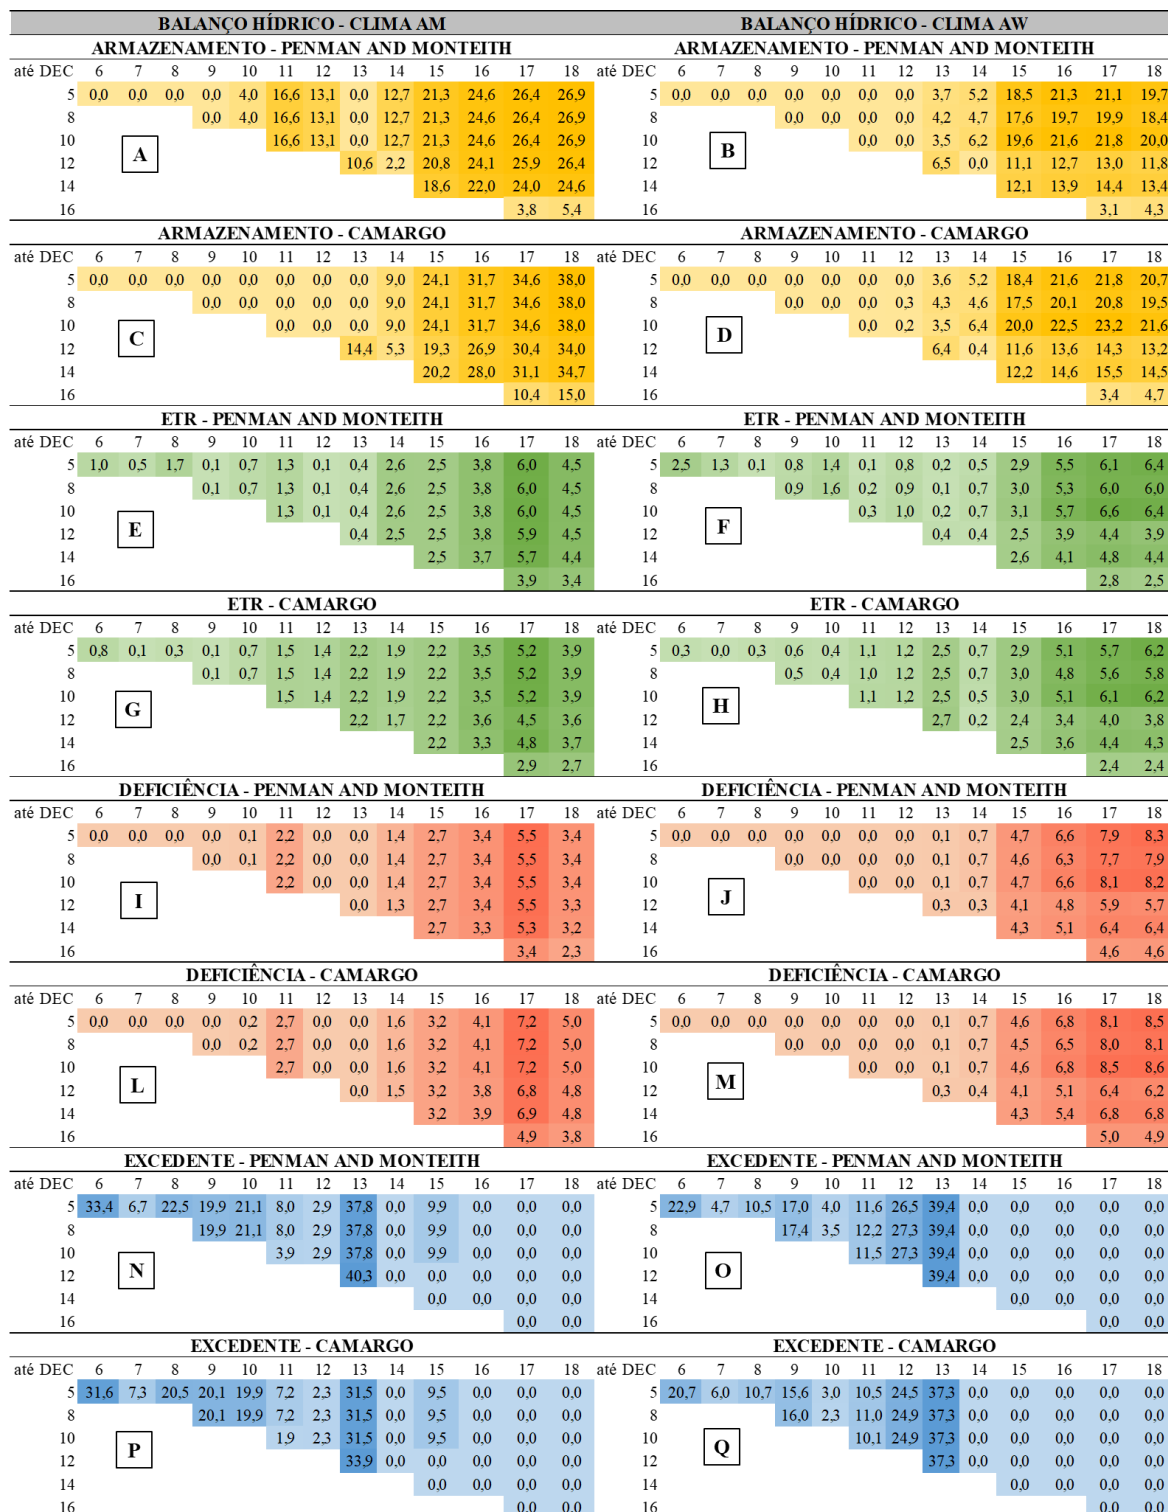


Figura 12. Desempenho estatístico das interações em relação aos dados observados nos climas Am e Aw na escala decenal pelos modelos de Camargo e Penman-Monteith, considerando o desvio padrão (DP). Legenda: Quanto menor o valor de desvio e intensidade da cor, melhor o desempenho.

5. CONCLUSÕES

O modelo de MLR fornece previsão acurada para elementos climáticos como precipitação, temperatura do ar, umidade relativa, velocidade do vento e radiação global, para os climas Aw e Am, utilizando 14 decêndios preditores e com os valores previstos com 2 meses de antecedência.

O MLR viabiliza resultados acurados para previsão da velocidade do vento e valores com confiança razoável para elementos de maior variabilidade e complexidade de previsão, como a precipitação.

Diante do bom desempenho do modelo de Camargo na elaboração do balanço hídrico utilizando elementos climáticos previstos, e por necessitar de menor número de variáveis de entrada, o método mais prático para avaliar o balanço de água no solo possibilita relacionar os possíveis impactos da condição hídrica nos estádios da cultura do milho.

Dessa forma, conclui-se que os modelos obtidos são eficazes para prever os valores dos elementos climáticos decendiais de elementos climáticos com dois meses de antecedência, possibilitando seu uso em análises de riscos climáticos e estudos de planejamento agrícola.

REFERÊNCIAS

- ABAYOMI-ALLI, A.; ODUSAMI, M. O.; ABAYOMI-ALLI, O.; MISRA, S.; IBEH, G. FABAYOMI-ALLI, A. *et al.* **Long Short-Term Memory Model for Time Series Prediction and Forecast of Solar Radiation and other Weather Parameters** 2019 19th International Conference on Computational Science and Its Applications (ICCSA). **Anais...IEEE**, jul. 2019 Disponível em: <<https://ieeexplore.ieee.org/document/8853618/>>.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop Evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome, v. 300, n. 9, p. D05109, 1998.
- ALMOROX, J.; QUEJ, V.H.; MARTÍ, P. Global performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. **Journal of Hydrology**, v. 528, p. 514-522, 2015
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. M. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- AMIRI, S. S.; MOTTAHEDI, M.; ASADI, S. Using multiple regression analysis to develop energy consumption indicators for commercial buildings in the U.S. **Energy and Buildings**, v. 109, p. 209–216, dez. 2015.
- ANJALI, T. *et al.* Temperature Prediction using Machine Learning Approaches. **2019 2ª Conferência Internacional sobre Computação Inteligente, Instrumentação e**

Tecnologias de Controle (ICICICT), p. 1264–1268, 2019.

APARECIDO, L. E. O.; ROLIM, G. S.; MORAES, J. R. S. C.; ROCHA, H. G.; LENSE, G. H. E. Agroclimatic zoning for urucum crops in the state of Minas Gerais, Brazil. **Bragantia**, v. 77, n. 1, p. 193-200, 2018.

APARECIDO, L. E. D. O.; MORAES, J. R. D. S. C. D.; MENESES, K. C. D.; TORSONI, G. B.; COSTA, C. T. S. Modelagem da produtividade do milho safrinha em função das condições climáticas do Mato Grosso do Sul. **Revista Brasileira de Climatologia**, v. 26, 14 fev. 2020.

APARECIDO, L. E. de O. et al. Caracterização Hídrica Espacial e Sazonal de Mato Grosso do Sul com Dados em Grid. **Revista Brasileira de Meteorologia**, v. 35, p. 147-156, 2020.

AZADI, S.; KARIMI-JASHNI, A. Verifying the performance of artificial neural network and multiple linear regression in predicting the mean seasonal municipal solid waste generation rate: A case study of Fars province, Iran. **Waste management**, v. 48, p. 14-23, 2016.

BARHMI, S.; ELFATNI, O.; BELHAJ, I. Forecasting of wind speed using multiple linear regression and artificial neural networks. **Energy Systems**, v. 11, n. 4, p. 935–946, 11 nov. 2020.

Brasil . Projeto RADAMBRASIL Ministério de Minas e Energia, Rio de Janeiro (1981).

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.

BUSKE, T. C.; ROBAINA, A. D.; PEITER, M. X.; PIMENTA, B. D.; GOLLO, E. A. Avaliação de modelos agrometeorológicos na estimativa de produtividade da cultura do milho. **Revista Brasileira de Agricultura Irrigada**, v. 13, n. 2, p. 3369, 2019.

CAMARGO, A. P. Balanço hídrico no Estado de São Paulo. Campinas: Instituto Agrônomo, 24p. Boletim, n. 116, 1971.

CHANTANA, J.; KAMEI, A.; MINEMOTO, T. (2017). Influences of environmental factors on Si-based photovoltaic modules after longtime outdoor exposure by multiple regression analysis, **Renewable Energy**, 101, 10–15.

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/safra/gaos/boletim-da-safra-de-graos>. Acesso em: 07 de abril de 2022.

CORNELL, J.A.; BERGER, R.D. Factors that influence the coefficient of determination in single linear and nonlinear models. **Phytopathology**, Palo Alto, v. 77, p. 63-70, 1987.

COSTA, T.S.; SALES, R. A.; SANTOS, R. J.; SANTOS, R.A.; SANTOS, R. L. Estimativa do balanço hídrico climatológico e classificação climática para o município de Bom Jesus da Lapa–BA. **Revista Ifes Ciência**, v. 5, n. 2, p. 208-216, 2019.

DOORENBOS, J.; KASSAM, A. H. Yield response to water. **Irrigation and drainage paper**, n. 33, p. 257, 1979.

DRAKE, J. E.; TJOELKER, M. G.; VÅRHAMMAR, A.; MEDLYN, B. E.; REICH, P. B.; LEIGH, A.; BARTON, C. V. Trees tolerate an extreme heatwave via sustained transpirational cooling and increased leaf thermal tolerance. **Global change biology**, v.

24, n. 6, p. 2390-2402, 2018.

DUARTE, Y. C. N.; SENTELHAS, P. C. NASA/POWER and DailyGridded weather datasets—how good they are for estimating maize yields in Brazil? **International Journal of Biometeorology**, v. 64, n. 3, p. 319–329, 24 mar. 2020.

EMROUZNEJAD, A.; CHARLES, V. (Ed.). **Big data for the greater good**. Cham: Springer International Publishing, 2019.

ESTEVEZ, J. T.; ROLIM, G. S.; FERRAUDO, A. S. Rainfall prediction methodology with binary multilayer perceptron neural networks. **Climate Dynamics**, v. 52, n. 3–4, p. 2319–2331, 21 fev. 2019.

FENTE, D. N.; KUMAR SINGH, D. **Weather Forecasting Using Artificial Neural Network** 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT). **Anais...IEEE**, abr. 2018 Disponível em: <<https://ieeexplore.ieee.org/document/8473167/>>.

FERREIRA, J. C. C.; TEIXEIRA FILHO, A. de J.; BARBOSA, J. V. G.; ARRUDA, D. A.: Comparação entre métodos de estimativa da evapotranspiração de referência no município de Parintins, AM. In:____.; SALES, F. O. (Organizador). **Ciências Exatas e da Terra: Aprendizado, Integração e Necessidades do País**. Ponta Grossa, Pr: Atena, 2020.

FRANCISCO, P. R. M.; SANTOS, D.; GUIMARÃES, C. L.; ARAÚJO, S. R. D.; OLIVEIRA, F. P. Aptidão climática do milho (*Zea mays* L.) para o estado da Paraíba. **Revista de Geografia**, Recife, v. 34, n. 1, p. 290-305, 2017.

LEE SEUNG KYU, D. T. A. Influence of climate variability on corn water requirement : A case study of Binh Thuan Province, Vietnam. **Research on Crops**, v. 20, n. 3, 30 set. 2019.

LERAYER, A. **Guia do Milho: Tecnologia do campo a mesa**. São Paulo: Conselhos de Informações Sobre Biotecnologia, 2018.

LIAKOS, K. G.; BUSATO, P.; MOSHOU, D.; PEARSON, S.; BOCHTIS, D. Machine Learning in Agriculture: A Review. **Sensors**. 18 (2674), 1–29, 2018.

LIM, B.; ZOHREN, S. Time-series forecasting with deep learning: a survey. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 379, n. 2194, p. 20200209, 5 abr. 2021.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. Deep learning in agriculture: A survey. **Computers and electronics in agriculture**, v. 147, p. 70-90, 2018.

KAYRI, M.; KAYRI, I.; GENCOGLU, M. T. 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)**. IEEE, 2017. p. 1-4.

MAHMUD, I.; BARI, S. H.; RAHMAN, M. T. U. Monthly rainfall forecast of Bangladesh using autoregressive integrated moving average method. **Environmental Engineering Research**, v. 22, n. 2, p. 162–168, 28 nov. 2016.

MAMANN, A. T. W.; BREZOLIN, A. P.; SCREMIN, A. H.; REGINATTO, D. C.; HENRICHSEN, L.; DORNELLES, E. F.; SILVA, J. A. G. Lógica fuzzy na simulação da produtividade de trigo por nitrogênio e hidrogel. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, v.6, n.1, 2018.

MARTÍNEZ-LÜSCHER, J.; CHEN, C. C. L.; BRILLANTE, L.; KURTURAL, S. K. Mitigating heat wave and exposure damage to “cabernet sauvignon” wine grape with partial shading under two irrigation amounts. *Frontiers in Plant Science*, v. 11, p. 579192, 2020.

MARTINS, E.; APARECIDO, L. E. O.; SANTOS, L. P. S.; MENDONÇA, J. M. A.; SOUZA, P. S. Influência das condições climáticas na produtividade e qualidade do cafeeiro produzido na região do sul de Minas Gerais. *Coffee Science*, v.10, p.499-506, 2015.

MASHALY, Ahmed F.; ALAZBA, A. A. MLP and MLR models for instantaneous thermal efficiency prediction of solar still under hyper-arid environment. *Computers and Electronics in Agriculture*, v. 122, p. 146-155, 2016.

MONTEIRO, L. A.; SENTELHAS, P. C.; PEDRA, G. U. Assessment of NASA/POWER satellite-based weather system for Brazilian conditions and its impact on sugarcane yield simulation. *International Journal of Climatology*, v. 38, n. 3, p. 1571–1581, mar. 2018.

MOELETSI, M. E.; WALKER, S. Assessment of agricultural drought using a simple water balance model in the Free State Province of South Africa. *Theoretical and applied climatology*, v. 108, n. 3-4, p. 425-450, 2012.

MINHAS, B. S.; PARIKH, K. S.; SRINIVASAN, T. N. Towards the structure of a production function for wheat yields with dated inputs of irrigation water. *Water Resource Research*, v. 10, p. 383-393, 1974.

NOBRE, C. A.; ASSAD, E. D. Aquecimento Global e o Impacto na Amazônia e na Agricultura Brasileira. *INPE Eprint*: Disponível em: <http://www.sid.inpe.br/ePrint>, v. 80, p. 09.12, 2005.

PARREIRA, A. G. B.; MARASCA, I.; SOLINO, A. J. S.; SANTOS, G. O. Water balance climatological to the county of Rio Verde, Goiás. *Científica Multidisciplinary Journal*, 6(1), 16-33, 2019.

PRASAD, R.; GUNN, S. K.; ROTZ, C. A.; KARSTEN, H.; ROTH, G.; BUDA, A.; STONER, A. M. Projected climate and agronomic implications for corn production in the Northeastern United States. *PLOS ONE*, v. 13, n. 6, p. e0198623, 11 jun. 2018.

PRIESTLEY, C. H. B.; TAYLOR, R. J. On the assessment of surface heat flux and evaporation using large-scale parameters. *Monthly weather review*, v. 100, n. 2, p. 81-92, 1972.

ROLIM, G. S.; APARECIDO, L. E. O.; SOUZA, P. S.; LAMPARELLI, R. A. C.; SANTOS, É. R. Climate and natural quality of *Coffea arabica* L. drink. *Theoretical and Applied Climatology*, v. 141, n. 1, p. 87-98, 2020.

SHAO, R. *et al.* The effect of elevating temperature on the growth and development of reproductive organs and yield of summer maize. *Journal of Integrative Agriculture*, v. 20, n. 7, p. 1783–1795, jul. 2021.

SALOMÃO, G. R. Produção de milho no verão após cultivo de leguminosas como adubos verdes. 2015.

SPARKS, A. NASAPOWER: A NASA POWER Global Meteorology, Surface Solar Energy and Climatology Data Client for R. *Journal of Open Source Software*, v. 3, n. 30, p. 1035, 19 out. 2018.

SILVEIRA, D. C.; BONETTI, L. P.; TRAGNAGO, J. L.; MONTEIRO, V. Caracterização agromorfológica de variedades de milho crioulo (*Zea mays* L.) na região noroeste do Rio Grande do Sul. **Ciência & Tecnologia**, Piracicaba, v. 1, n. 1, p. 01-11, 2015.

SUYONO, H. *et al.* Prediction of Solar Radiation Intensity using Extreme Learning Machine. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 12, n. 2, p. 691, 1 nov. 2018.

SWAIN, S.; PATEL, P.; NANDI, S. **A multiple linear regression model for precipitation forecasting over Cuttack district, Odisha, India** 2017 2nd International Conference for Convergence in Technology (I2CT). **Anais...IEEE**, abr. 2017 Disponível em: <<http://ieeexplore.ieee.org/document/8226150/>>.

THORNTHWAITE, C. W., 1948. An approach toward a rational classification of climate. **Geographical Review [online]** 38. Disponível: 10.2307/210739. Acesso: 11 de julho. 2022.

THORNTHWAITE, C. W.; MATHER, J. R., 1955. The water balance. Publication in Climatology 8, **Laboratory of Climatology**, Centerton, N. J.

UNITED STATES. Department of Agriculture. Agricultural Statistics. Oilseeds: World Markets and trade. 2019 Disponível em: <https://downloads.usda.library.cornell.edu/usda-esmis/files/5q47rn72z/0g354t050/r494vz32w/production.pdf>. Acesso: 30 de março de 2022.

USDA - United States Department of Agriculture. Circular Series WAP 8-18. 2018. Disponível em: <<http://usda.mannlib.cornell.edu/usda/current/worldagproduction/worldagproduction-08-10-2018.pdf>>. Acesso em: 30 de março de 2022.

USDA - UNITED STATES DEPARTMENT OF AGRICULTURE. Grain: World Markets and trade. Maio, 2019. Disponível em: <https://apps.fas.usda.gov/psdonline/circulars/grain.pdf>. Acesso em: 30 de março de 2022a.

USDA - UNITED STATES DEPARTMENT OF AGRICULTURE. Production, Supply and Distribution (PSD) online. Disponível em: <https://apps.fas.usda.gov/psdonline/app/index.html#/app/advQuery>. Acesso em: 30 de março de 2022b.

VALERIANO, T. T. B. *et al.* Evaluation of air temperature and rainfall from ECMWF and NASA gridded data for southeastern Brazil. **Theoretical and Applied Climatology**, v. 137, n. 3–4, p. 1925–1938, 22 ago. 2019.