

ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA POR REDES NEURAS ARTIFICIAIS

Geovani da Silva Santana¹, Ramilos Rodrigues de Brito², Cícero Manoel dos Santos³, Victoria Libertad de Assis Paes⁴, Eduarda Silva de Lima⁵, Ângelo Cezar Lucizani⁶

RESUMO: O conhecimento da evapotranspiração de referencia (ET_0) é importante em diversas aplicações hidrológicas e devido à escassez de medidas, modelos têm sido desenvolvidos para estimar ET_0 . O objetivo do trabalho foi testar e treinar redes neurais artificiais (RNAs) com cinco combinações de variáveis climáticas para estimar ET_0 para três locais do estado do Pará (Medicilândia, Pacajá e Placas) utilizando a equação de Penman-Monteith-FAO56 (PM-56) para comparar o desempenho das RNA. De acordo com os resultados os modelos de RNA que utilizaram dados de radiação solar e temperatura do ar na entrada foram os que apresentaram melhores resultados se aproximando do valor 0 de rRMSE, rMBE e MAPE e valores próximos de 1 de índice de concordância ‘d’. A RNA mostrou ser uma técnica eficiente na estimativa de ET_0 .

PALAVRAS-CHAVE: Inteligência artificial, Balanço hídrico, PM-56.

ESTIMATION OF REFERENCE EVAPOTRANSPIRATION BY ARTIFICIAL NEURAL NETWORKS

ABSTRACT: The knowledge of reference evapotranspiration (ET_0) is important several hydrological applications, and due to the scarcity of measures, models have been developed to estimate ET_0 . The objective of this work was to test and train artificial neural networks (RNAs) with five combinations of climatic variables to estimate ET_0 for three sites in the state of Pará (Medicilândia, Pacajá and Placas) using the Penman-Monteith-FAO equation56 (PM-56) to compare the performance of ANNs. According to the results, RNA models that

¹ Engenheiro Agrônomo, Altamira, PA.

² Pós doutorando, Programa de Pós-graduação em Ciências Agrárias –PPGCA/UFPI/CPCE, Bom Jesus, PI.

³ Prof. Doutor, Fac. de Engenharia Agronômica, UFPA, Altamira, PA.

⁴ Estudante de Engenharia Agronômica, UFPA, Altamira, PA.

⁵ Estudante de Engenharia Florestal, UFPA, Altamira, PA.

⁶ Mestre em física aplicada, Professor, Rede Estadual de Educação do Paraná, Foz do Iguaçu, PR.

used solar radiation data and air temperature at the entrance were the ones that presented better results approaching the value 0 of rRMSE, rMBE and MAPE and values close to 1 of concordance index d ". RNA showed to be an efficient technique in the estimation of ET_0 .

KEYWORDS: Artificial intelligence, Hydric Balance, PM56.

INTRODUÇÃO

A Evapotranspiração de referência (ET_0) é o processo simultâneo de perda de água por evaporação do solo e transpiração das plantas, é um dos principais componentes do ciclo hidrológico e sua estimativa é de grande importância para vários estudos como de irrigação, balanço hídrico, simulação de produção agrícola e gestão do planejamento de recursos hídricos (Kumar et al., 2011).

A evapotranspiração é um processo bastante complexo que depende da interação de vários fatores atmosféricos como temperatura, radiação solar e velocidade do vento. A ET_0 pode ser medida diretamente através de uso de lisímetros, geralmente, mas os altos custos operacionais e a necessidade de precisão nas medições limitam o uso da metodologia de lisimetria (LÓPEZ-URREA et al., 2006). Durante os anos muitos esforços foram feitos para desenvolver equações físicas empíricas para estimar a ET_0 utilizando variáveis meteorológicas. A Organização das Nações Unidas para Alimentação e Agricultura (FAO) aceitou o modelo Penman-Monteith-FAO-56 (PM56) como equação padrão para estimativa da ET_0 (ALLEN et al., 1998). O modelo PM56 é uma equação física que mais se assemelha as observações de campo (Yassin et al., 2016). No entanto, o modelo necessita de uma significativa quantidade de dados que podem ou não estar disponíveis no local de aplicação. Por conta disso se faz necessário a possibilidade de utilização de métodos alternativos que utilizam uma quantidade menor de dados climáticos na entrada para estimar a ET_0 .

A aplicação de técnicas de aprendizagem máquinas (por exemplo, Redes Neurais Artificiais – RNA) na modelagem de processos hidrológicos como evapotranspiração tem recebido muita atenção. Segundo Antonopoulos e Antonopoulos (2017) através da utilização da RNA a evapotranspiração pode ser estimada com sucesso. Devido à importância que a ET_0 assume em diversas áreas o objetivo desse estudo é a estimar ET_0 com RNA com diferentes combinações para as variáveis de entrada e comparar com modelos empíricos de evapotranspiração que requerem poucas variáveis de entrada em três locais do Pará.

MATERIAL E MÉTODOS

O estudo foi realizado nas cidades de Medicilândia, Pacajá e Placas no estado do Pará (Tabela 1). Para estimar valores da evapotranspiração de referência utilizando modelos empíricos e RNA utilizou-se um conjunto de dados diários de temperatura, umidade relativa, velocidade do vento, precipitação e radiação solar das estações automáticas, fornecidos pelo Instituto Nacional de Meteorologia (INMET). Os dados utilizados passaram por um severo critério de filtragem para eliminação de valores impuros e incoerentes. O período das medidas está compreendido de fevereiro de 2008 a dezembro de 2017. O modelo aceito pela FAO como referência Penman-Monteith-FAO-56 por Allen et al., (1998) foi utilizado como padrão para a validação dos modelos. O modelo PM56 da evapotranspiração diária de referência ET_0 é descrita com base em Allen et al., (1998) na seguinte equação:

$$ET_0 = \frac{0.408\Delta(R_n - G) + (\gamma \frac{900}{T+273})u_2(e_s - e)}{\Delta + [\gamma(1+0.34u_2)]} \quad (1)$$

Onde: ET_0 é a evapotranspiração de referência (mm d^{-1}); R_n é o saldo de radiação à superfície da cultura ($\text{MJ m}^{-2}\text{d}^{-1}$); G é a densidade do fluxo de calor do solo ($\text{MJ m}^{-2}\text{d}^{-1}$), T é a temperatura do ar a 2 m de altura ($^{\circ}\text{C}$); u_2 é a velocidade de vento a 2 m de altura (m s^{-1}); e_s a pressão de vapor de saturação (kPa); e é a pressão parcial de vapor (kPa); Δ a declividade da curva de pressão de vapor de saturação ($\text{kPa } ^{\circ}\text{C}^{-1}$) e γ é o coeficiente psicrométrico ($\text{kPa } ^{\circ}\text{C}^{-1}$).

A rede neural artificial utilizada foi do tipo FeedForward Multiplayer Perceptron (MLP) onde a mesma determina automaticamente a quantidade de camadas e neurônios. Nesta rede, o sinal de entrada se espalha camada por camada (feedForward) então é retropropagado para a correção do erro, este procedimento é repetido por várias interações até a finalização do treinamento. A RNA foi treinada através do WEKA 3.8.2 (Waikato Environment for Knowledge Analysis) que é um conjunto de algoritmos de aprendizado de máquinas que contém ferramentas para pré-processamento de dados, classificação, regressão, regras de associação e visualização. A MLP foi treinada usando o algoritmo de aprendizagem error backpropagation e o termo momentum com a função de ativação sigmoial. Este processo envolve essencialmente 2 fases, a propagação direta de entrada e propagação de erros para trás, onde esses são usados para ajustar os pesos (RUMELHART et al., 1986). O uso do termo momentum diminui o tempo de treinamento, aumentando a estabilidade do processo de treinamento e o mantendo na direção geral. Foram desenvolvidas cinco combinações

diferentes para as variáveis de entrada, de acordo com os modelos de Priestley e Taylor (1972), Turc (1961), Mahringer (1970) e Valiantzas (2012). Para comparação dos resultados dos modelos empíricos com PM-56, foram utilizados os índices estatísticos de validação: Relative Mean Bias Error (rMBE, %), Relative Root Mean Square Error (rRMSE, %), Mean Absolute Percentage Error (MAPE) e “d” de Willmott.

Tabela 1. Coordenadas geográfica das estações meteorológicas

Local	Latitude	Longitude	Altitude (m)
Medicilândia	03°30'S	52°57'W	251,0
Placas	03°52'S	54°14'W	100,0
Pacajá	03°50'S	50°38'W	89,0

RESULTADOS E DISCUSSÃO

Nas Figuras 1, 2 e 3 são representadas as dispersões dos valores estimados pelos modelos RNA-1 (a), RNA-2 (b), RNA-3 (c), RNA-4 (d) e RNA-5 (e) com relação ao modelo de PM56 para as cidades de Medicilândia (Fig. 1), Pacajá (Fig. 2) e Placas (Fig. 3). A partir dos gráficos de dispersão fica claro que o modelo RNA-1 (que leva em consideração a radiação global como variável de entrada) obteve melhor correlação para estimar a ET_0 , acompanhando linearmente a linha ideal (1:1). Verificou-se que o modelo RNA-1, para as três cidades, as estimativas foram próximas dos valores de ET_0 e r^2 igual a 0,99. Resultados semelhantes de r^2 foram obtidos com a RNA-5 que apresentou maior combinação de variáveis em relação a todos os modelos. Laaboudi et al., (2012) concluíram que o desempenho dos modelos variam de acordo com o número de entradas, também destaca-se que a velocidade do vento e a umidade relativa melhoraram a precisão baseada na temperatura quando incorporadas na rede como variável de entrada, corroborando com os resultados obtidos pela RNA-5. A RNA-2 apresentou bom valor de r^2 igual 0,98 para as três cidades, a RNA-3 não obteve bons resultados com baixos valores de r^2 0,43; 0,10; 0,49 para Medicilândia (Fig. 1c), Pacajá (Fig. 2c) e Placas (Fig. 3c), respectivamente. Nos gráficos de dispersão e r^2 o pior desempenho evidenciou-se na RNA-4 com baixos valores de concordância r^2 para Medicilândia (0,42) (Fig. 1d), Pacajá (0,05) (Fig. 2d) e Placas (0,48) (Fig. 3d).

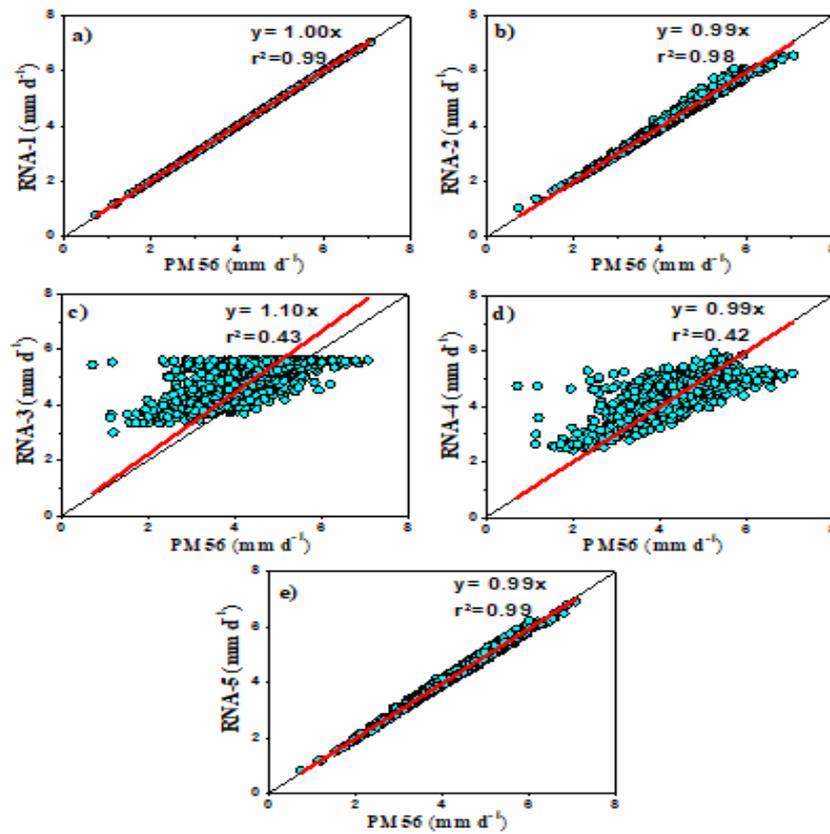


Figura 1. Diagramas de dispersão de ET₀ (mm d⁻¹) com o método PM56 e (a) RNA-1, (b) RNA-2, (c) RNA-3, (d) RNA-4 e (e) RNA-5 no período 2008-2018 para Medicilândia.

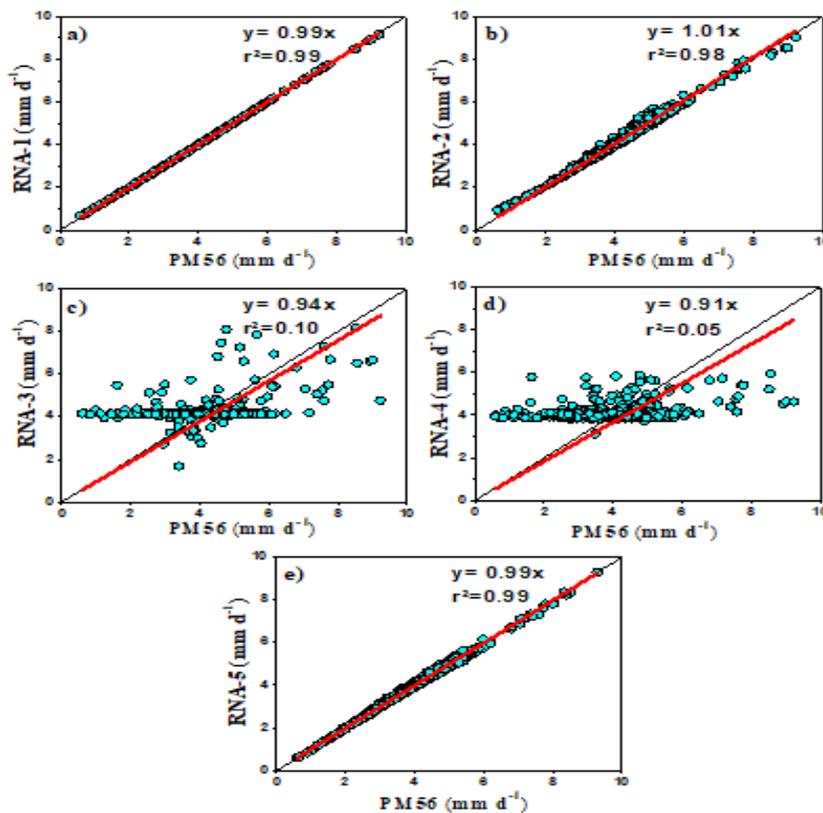


Figura 2. Diagramas de dispersão de ET₀ (mm d⁻¹) com o método PM56 e (a) RNA-1, (b) RNA-2, (c) RNA-3, (d) RNA-4 e (e) RNA-5 no período 2008-2018 para Pacajá.

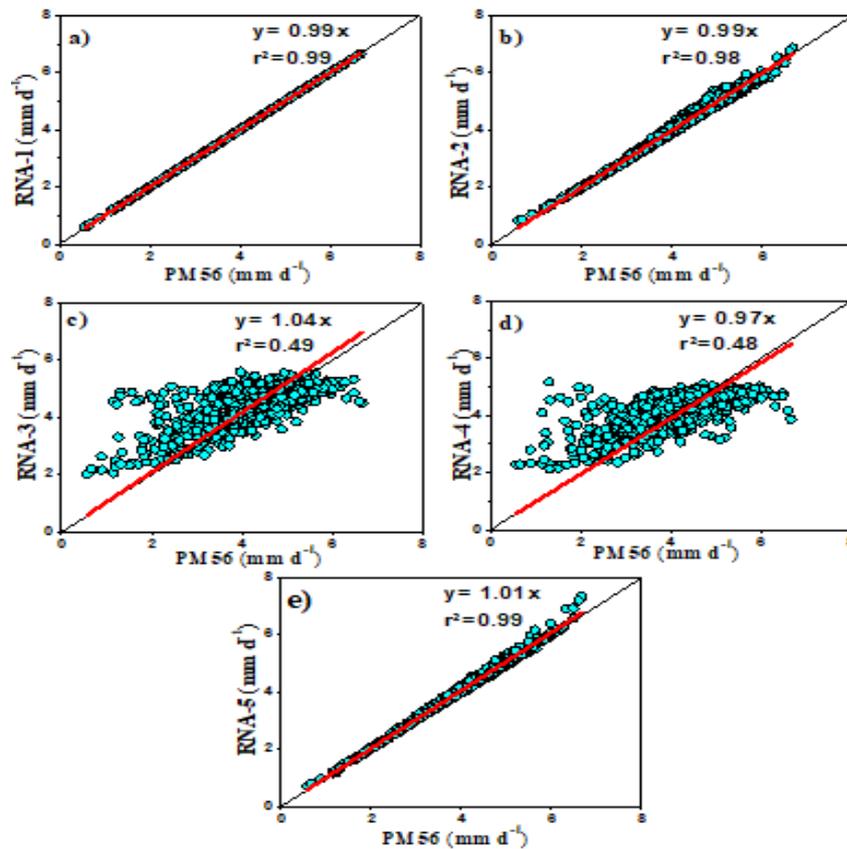


Figura 3. Diagramas de dispersão de ET_0 (mm d^{-1}) com o método PM56 e (a) RNA-1, (b) RNA-2, (c) RNA-3, (d) RNA-4 e (e) RNA-5 no período 2008-2018 para Placas.

Na Tabela 2 são apresentados os resultados estatísticos de rRMSE, rMBE e MAPE em porcentagem dos modelos de RNA usando diferentes combinações de entrada para estimar a ET_0 juntamente com a exatidão calculada através do índice de concordância d . Os valores de rMBE variaram de -0,04 a 13,96%, rRMSE de 0,10 a 24,57%, MAPE de 0,09 a 24,37% e “ d ” variando de 0,35 a 1. Pode-se observar que na ausência ou presença de algumas das variáveis de entrada nos conjuntos de entrada afeta significativamente o desempenho dos modelos.

O modelo baseado na equação de Mahringer RNA-4 levou as temperaturas máximas, medias e mínimas do ar, umidade relativa do ar e temperatura do orvalho. A RNA-4 apresentou o pior desempenho para Pacajá com alto valor de rRMSE (24,57%) comparado com os outros locais e MAPE de 24,37%, já para as cidades de Medicilândia e Placas a RNA-4 obteve um melhor desempenho em relação a RNA-3 com rRMSE de 14,88% e 16,61% para Medicilândia e Placas, respectivamente, e baixos valores de rMBE (1,74% e 0,23% para Medicilândia e Placas respectivamente). A RNA-3 obteve o pior desempenho para Medicilândia e Placas com altos índices de rRMSE (21,27% e 17,91%), MAPE (21,01% e 17,70%) e rMBE (13,96% e 7,48%). A RNA-3 usa velocidade do vento e a saturação de

vapor, que conforme os índices estatísticos não apresentaram incremento apreciável no desempenho do modelo para as duas cidades, a RNA-3 obteve melhores índices em relação a RNA-4 para Pacajá.

Os modelos que utilizam como dado de entrada valores de radiação junto com temperatura obtiveram os melhores resultados. O que pode ser explicado no trabalho realizado por Filho et al., (2015), onde sugerem que para treinar uma rede neural é necessário ter pelo menos essas variáveis climáticas. O desempenho da RNA-2 que é um modelo baseado na temperatura do ar e radiação solar obteve bons índices para todas as três cidades obtendo o índice 1 de concordância de Willmott, se tornando melhor que a RNA-3 e RNA-4 na estimativa da ET_0 , comparando os resultados da RNA-2 com a RNA-5, a precisão da RNA-5 foi significativamente melhorada com a adição da umidade relativa e velocidade do vento com baixos valores de MAPE (2,05%, 1,92% e 1,89% para Medicilândia, Placas e Pacajá, respectivamente) e baixo valor de rRMSE (2,34%, 2,32% e 2,73 para Medicilândia, Placas e Pacajá, respectivamente) se tornando o segundo melhor modelo para estimativa da ET_0 para as cidades.

Tabela 2. Comparação das performances das RNAs com a estimacão da ET_0 pelo método PM56.

Modelo	Medicilândia				Pacajá				Placas			
	rMBE(%)	rRMSE(%)	MAPE(%)	d	rMBE(%)	rRMSE(%)	MAPE(%)	d	rMBE(%)	rRMSE(%)	MAPE(%)	d
RNA-1	0,05	0,14	0,13	1	-0,06	0,21	0,19	1	-0,04	0,10	0,09	1
RNA-2	-0,66	2,75	2,32	1	1,41	3,33	2,74	1	-0,20	2,78	2,40	1
RNA-3	13,96	21,27	21,01	0,69	-0,38	23,71	24,32	0,44	7,48	17,91	17,70	0,78
RNA-4	1,74	14,88	13,20	0,82	-3,09	24,57	24,37	0,35	0,23	16,61	15,70	0,78
RNA-5	-0,92	2,34	2,05	1	-0,28	2,32	1,92	1	1,50	2,73	1,89	1

A RNA-1 que é um modelo baseado em radiação solar apresentou os melhores índices dentre todas as redes com valor perfeito de “d” de Willmott igual 1 para todas as cidades e aumento da exatidão de rRMSE, rMBE e MAPE também foi exibido para Medicilândia, Placas e Pacajá. Muitos pesquisadores trabalharam com métodos de estimativa de ET_0 baseado apenas em variáveis de temperatura ou temperatura e radiação solar como os de Priestley & Taylor e Turc. Jain et al., (2008) utilizaram RNA para estimar ET_0 a partir de dados climáticos limitados, os resultados do estudo mostraram que a técnica de RNA pode ser usada com sucesso para estimar ET_0 a partir de dados climáticos.

Observa-se que, para uma estimativa precisa de ET_0 usando uma RNA, os dados de temperatura e radiação são os insumos mais importantes, corroborando com resultados obtidos por Lucas et al., (2018) que utilizaram uma RNA para estimar a evapotranspiração de

referência em função das temperaturas máxima e mínima do ar para a cidade de Salinas-MG. Onde obteve boa correlação entre os valores estimados pelo método padrão e pela RNA, onde mostrou-se uma excelente alternativa para a determinação da ET_0 , proporcionando a diminuição dos custos de aquisição de dados climáticos.

CONCLUSÕES

Através das redes neurais artificiais é possível obter resultados confiáveis na estimativa da ET_0 , quando comparado ao método Penman-Monteith

O desempenho de modelos de RNAs que contenham como entrada a temperatura e radiação solar proporcionam melhores resultados que outras combinações.

AGRADECIMENTOS

Os autores agradecem oao INMET pela disponibilidade de dados, ao CNPq pela concessão da bolsa de iniciação científica PIBIC/INTERIOR.

REFERÊNCIAS BIBLIOGRÁFICAS

ALLEN, R. G. et al. Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO - Food and Agriculture Organization of the United Nations, 1998.

ANTONOPOULOS, V. Z.; ANTONOPOULOS, A. V. Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. Computers and Electronics in Agriculture, v. 132, p. 86–96, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.compag.2016.11.011>>.

FILHO, A. I. et al. INFLUÊNCIA DAS VARIÁVEIS CLIMÁTICAS SOBRE A EVAPOTRANSPIRAÇÃO. Gaia Scientia, v. 9, n. 1, p. 62–66, 2015.

JAIN, S. .; NAYAK, P. .; SUDHEER, K. . Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. Hydrol Process, v. 22, p. 2225–2234, 2008.

KUMAR, M.; RAGHUWANSHI, N. S.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: A review. *Irrigation Science*, v. 29, n. 1, p. 11–25, 2011.

LAABOUDI, A.; MOUHOUCHE, B.; DRAOUI, B. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. *International Journal of Biometeorology* (2012) 56: 831. <https://doi.org/10.1007/s00484-011-0485-7>

LÓPEZ-URREA, R. et al. Testing evapotranspiration equations using lysimeter observations in a semiarid climate. *Agricultural Water Management*, v. 85, n. 1–2, p. 15–26, 2006. Disponível em: <<https://doi.org/10.1016/j.agwat.2006.03.014>>.

LUCAS, P. O. et al. USING ARTIFICIAL NEURAL NETWORK TO ESTIMATE REFERENCE EVAPOTRANSPIRATION. *GLOBAL SCIENCE AND TECHNOLOGY*, v. 11, n. 3, 28 nov. 2018. Disponível em: <<https://rv.ifgoiano.edu.br/periodicos/index.php/gst/article/view/1057/632>>. Acesso em: 2 maio. 2019.

MAHRINGER, W. Verdunstungsstudien am neusiedler See. *Archiv für Meteorologie, Geophysik und Bioklimatologie, Serie B*, v. 18, n. 1, p. 1–20, 1970.

PRIESTLEY, C. H. B.; TAYLOR, R. J. On the assessment of surface heat flux and Evaporation using large scale parameters. *Monthly Weather Review*. *Monthly weather review*, v. 100, n. 2, p. 81–92, 1972. Disponível em: <[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)>.

TURC, L. Estimation of irrigation water requirements: potential evapotranspiration: a simple climatic formula evolved up to date. *Ann. Agron*, v. 12, n. 1, p. 13–49, 1961.

VALIANTZAS, J. D. Simple ET_0 forms of Penman's equation without wind and/or humidity data. II: Comparisons with reduced set-FAO and other methodologies. *Journal of irrigation and drainage engineering*, v. 139, n. 1, p. 9–19, 2012.