

## REDES NEURAIAS ARTIFICIAIS, REGRESSÃO E MÉTODOS EMPÍRICOS PARA A MODELAGEM DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NA CIDADE DE INHAMBANE, MOÇAMBIQUE

BARTOLOMEU FÉLIX TANGUNE<sup>1</sup> E RODRIGO MÁXIMO SÁNCHEZ ROMÁN<sup>2</sup>

<sup>1</sup> Departamento de Engenharia Rural, Escola Superior de Desenvolvimento Rural, Universidade Eduardo Mondlane, Vilankulo, Inhambane, Moçambique. E-mail: tanguneb@gmail.com.

<sup>2</sup> Departamento de Engenharia Rural, Faculdade de Ciências Agronômicas, Universidade Estadual Paulista (UNESP) Campus de Botucatu. Fazenda Experimental Lageado, Avenida Universitária, nº 3780, Altos do Paraíso, CEP: 18610-034, Botucatu – SP. Brasil. E-mail: rodrigo.roman@unesp.br

### 1 RESUMO

Estimativa precisa da evapotranspiração de referência (ET<sub>o</sub>) é importante para dimensionar e fazer manejo de sistemas de irrigação. Métodos de estimativa da ET<sub>o</sub> (11 métodos empíricos, 10 modelos de regressão múltipla: RLM e 10 redes neurais artificiais: RNAs) foram avaliados em relação ao método padrão de Penman Monteith FAO 56, utilizando os seguintes índices: MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*) e R<sup>2</sup>, sendo RMSE utilizado como critério principal de seleção dos métodos. A significância dos métodos foi avaliada com base no teste t utilizando dados de 1985 a 2009. Os dados meteorológicos utilizados (temperatura máxima: T<sub>max</sub>, temperatura mínima: T<sub>min</sub> e temperatura média: T, umidade relativa, velocidade do vento e insolação) são da estação meteorológica convencional da cidade de Inhambane, Moçambique. Os resultados mostraram que o modelo RLM4 apresentou melhor desempenho (MBE = 0,01 mm.d<sup>-1</sup>; RMSE = 0,15 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,99). Na falta da radiação solar global, os modelos RLM6 (MBE = -0,01 mm.d<sup>-1</sup>; RMSE = 0,23 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,97) e RLM10 (MBE = 0,01 mm.d<sup>-1</sup>; RMSE = 0,23 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,97) podem ser utilizados e exigem a medição da T, T<sub>max</sub> e T<sub>min</sub>, respectivamente. Esses modelos não foram estatisticamente diferentes do método padrão.

**Palavras-chave:** evapotranspiração, regressão múltipla, redes neurais.

TANGUNE, B. F.; SÁNCHEZ-ROMÁN, R. M.  
ARTIFICIAL NEURAL NETWORKS, REGRESSION AND EMPIRICAL  
METHODS FOR REFERENCE EVAPOTRANSPIRATION MODELING IN  
INHAMBANE CITY, MOZAMBIQUE

### 2 ABSTRACT

Precise estimation of reference evapotranspiration (ET<sub>o</sub>) is important for designing and managing irrigation systems. Methods of ET<sub>o</sub> estimation (11 empirical methods, 10 multiple regression models: RLM and 10 artificial neural networks: RNAs) were evaluated against Penman Monteith FAO 56 method using the following indexes: MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*) and R<sup>2</sup>, and RMSE was used as the main criterion of method selection. The significance of the methods was evaluated on the basis of the t test using data from 1985 to 2009. The meteorological data used (maximum temperature: T<sub>max</sub>, minimum

temperature:  $T_{min}$  and average temperature:  $T$ , relative air humidity, wind speed and solar brightness), from 1985 to 2009, are from the conventional meteorological station of the city of Inhambane, Mozambique. The results showed that the RLM4 model presented better performance ( $MBE = 0.01 \text{ mm.d}^{-1}$ ;  $RMSE = 0.15 \text{ mm.d}^{-1}$ ;  $R^2 = 0.99$ ). In the absence of global solar radiation, RLM6 ( $MBE = -0.01 \text{ mm.d}^{-1}$ ;  $RMSE = 0.23 \text{ mm.d}^{-1}$ ;  $R^2 = 0.97$ ) and RLM10 ( $MBE = 0.01 \text{ mm. d}^{-1}$ ;  $RMSE = 0.23 \text{ mm.d}^{-1}$ ;  $R^2 = 0.97$ ) can be used, which require measurement of  $T$ , and  $T_{max}$  and  $T_{min}$ , respectively. These models were not statistically different from the standard method.

**Keywords:** evapotranspiration, multiple regression, neural networks.

### 3 INTRODUÇÃO

Grande parte da água doce existente no planeta terra é consumida na agricultura, totalizando cerca de 70% do total de água existente (BESHIR, 2017). O consumo de água pode ser racionalizado melhorando a eficiência de irrigação, que por sua vez, depende do conhecimento preciso da evapotranspiração de referência ( $ET_o$ ) que ocorre num determinado lugar (CHATZITHOMAS; ALEXANDRIS, 2015). No sul do continente Africano, onde localiza-se Moçambique, as áreas agrícolas têm aumentado (MAEDA et al., 2011) devido ao crescente aumento populacional. Sendo assim, é crucial o conhecimento preciso da  $ET_o$  para a prática de uma agricultura sustentável.

A  $ET_o$  expressa a quantidade de água perdida numa cultura hipotética com 0,12 m de altura, em pleno crescimento ativo e uniforme, albedo de 23%, resistência da superfície de  $70 \text{ m s}^{-1}$ , com cobertura total e sem estresse hídrico (ALLEN et al., 1998). A  $ET_o$  pode ser obtida com precisão utilizando lisímetros, porém, o custo de sua construção e manutenção é elevado, sendo na prática pouco utilizados. Diante disso, geralmente a  $ET_o$  é estimada a partir de métodos indiretos baseados em dados climáticos. Dentre esses métodos, o método de Penman Monteith FAO 56 (PM FAO-56) é considerado padrão por Allen et al. (1998). Vários estudos têm comprovado que esse método é uma ótima alternativa

para estimar a  $ET_o$  com precisão (BAKHTIARI et al., 2011; CAO et al., 2015). O método de PM FAO-56 tem uma base física e requer o uso de vários elementos meteorológicos, tais como: temperatura máxima e mínima, velocidade do vento a 2 m de altura, umidade relativa do ar e radiação solar (ALLEN et al., 1998). A radiação solar nem sempre se encontra disponível em várias estações meteorológicas, principalmente em países não desenvolvidos como Moçambique. Sendo assim, o uso desse método torna-se limitado. Essa limitação levou os pesquisadores a desenvolverem outras alternativas (métodos empíricos) em função da disponibilidade dos elementos meteorológicos.

Existem vários tipos de métodos empíricos, porém, trabalhos apresentados na literatura vêm destacando os baseados na temperatura (por exemplo: método de Hargreaves Samani: HS, Blaney Criddle Original: BCO, Thornthwaite: TW) e na radiação solar (por exemplo: método de Priestly Taylor: PT, Makkink: Mak; Turc). Em Malawi, Ngongondo et al. (2013) mostraram que os métodos de PT e de HS subestimaram a  $ET_o$ . Em Vilankulo, Moçambique, o método de HS também subestimou a  $ET_o$  (TANGUNE e CHIMENE, 2019). Contudo, resultados opostos do método de HS foram encontrados por Patel et al. (2015). Shiri et al. (2014) relataram a superioridade do método de HS em comparação aos métodos

de Mak, Turc e de PT. Maeda et al. (2010) reportaram que o método de HS apresentou resultado melhor que os métodos de TW e de BCO. Tangune e Chimene (2019) observaram que o método HS (RMSE =  $-1,32 \text{ mm.d}^{-1}$ ) apresentou uma precisão inferior ao método de Mak (RMSE =  $0,28 \text{ mm.d}^{-1}$ ). Já Liu et al. (2017) constataram que o método de BCO superou o desempenho do método de temperatura de McCloud e foi inferior ao método de HS. Essas pesquisas revelam que os métodos empíricos podem variar no seu desempenho de local para local.

A discrepância de desempenho entre os diversos métodos empíricos dentro da complexidade da ETo torna necessário o uso de técnicas mais avançadas, como o Aprendizado de Máquina (*Machine Learning*), mais especificamente as Redes Neurais Artificiais (RNAs). Segundo Tabari et al. (2012), as RNAs são ferramentas computacionais apropriadas para modelar processos complexos. Estudos realizados por diversos autores têm mostrado que as RNAs produzem resultados melhores que os métodos empíricos (LANDERAS et al., 2008; TANGUNE e ESCOBEDO, 2018). Contudo, o seu treinamento pode ser demorado, o uso de algoritmos requer processadores mais rápidos, além de um grande volume de dados. Isso, por vezes torna inaplicável o seu uso. Com isso, Tabari et al. (2012) relataram que recentemente métodos/modelos estatísticos rápidos, simples e poderosos têm sido utilizados com sucesso para modelar diversos processos hidrológicos, por exemplo: os modelos de regressão foram utilizados com sucesso para modelar a evaporação (TABARI et al., 2010a; TABARI et al., 2012).

Diante do exposto, o presente trabalho teve os seguintes objetivos: avaliar o desempenho de seis métodos empíricos baseados na temperatura e cinco baseados na radiação solar; dez modelos de regressão

linear múltipla; dez modelos de RNAs e comparar o desempenho de todos os métodos. Todos os métodos foram avaliados em relação ao método de PM FAO-56 utilizando dados da estação meteorológica convencional da cidade de Inhambane, Moçambique. Não foi encontrado estudo similar no local de estudo, justificando a relevância da presente pesquisa.

## 4 MATERIAL E MÉTODOS

### 4.1 Caracterização da cidade de Inhambane

A cidade de Inhambane está localizada na faixa costeira da província de Inhambane, sul de Moçambique. Em termos de coordenadas geográficas, apresenta uma altitude de 14 m, latitude de  $23,87^\circ \text{ S}$  e longitude de  $35,38^\circ \text{ E}$ . O clima da cidade de Inhambane é tropical úmido na faixa costeira e tropical seco no interior. Segundo MICOA (2012), a cidade de Inhambane apresenta um período úmido entre os meses de novembro a abril, e seco entre os meses de maio a outubro. A precipitação total anual é de 936 mm, com temperatura média anual de  $24^\circ \text{C}$  e velocidade do vento de  $6,4 \text{ km.h}^{-1}$ . Conforme os dados utilizados na presente pesquisa, no período de 1985 a 2009, a evapotranspiração total anual é de 117,8 mm e a umidade relativa média mensal é de 76,4%.

### 4.2 Coleta e processamento dos dados

Os dados meteorológicos utilizados são da estação meteorológica convencional da cidade de Inhambane (temperatura média: T, temperatura máxima: Tmax, temperatura mínima: Tmin, brilho solar: n, umidade relativa do ar: UR e velocidade do vento:  $U_2$ ), os quais foram disponibilizados pelo Instituto Nacional de Meteorologia de Moçambique. Os dados em questão

correspondem às médias mensais do período de 1985 a 2009. Os dados de  $U_2$  e de  $n$  apresentavam algumas falhas, as quais foram posteriormente preenchidas. Para a  $U_2$  adotou-se uma velocidade de  $2 \text{ m s}^{-1}$  para preencher as falhas, conforme Allen et al. (1998), enquanto para o  $n$ , o valor em falta no mês  $i$  foi considerado igual à média dos valores existentes do mês  $i$ .

Após o preenchimento de falhas, estimou-se a  $ET_o$  a partir de 11 métodos empíricos (Tabela 1), dez modelos de regressão linear múltipla (RLM) e dez modelos de RNAs. Todos os métodos foram avaliados em relação ao método de PM FAO-56. Os métodos empíricos foram compostos por seis métodos baseados na temperatura e cinco na radiação solar. Nos métodos baseados na radiação solar ( $R_s$ ) e

em alguns modelos de RLM e de RNAs em que eram necessários valores de  $R_s$ , os mesmos foram estimados a partir da Equação 1, recomendada por Allen et al. (1998). Na ausência de parâmetros de calibração local da Equação 1 ( $a$  e  $b$ ), os seguintes valores podem ser adotados:  $a = 0,25$  e  $b = 0,50$ , conforme Allen et al. (1998).

$$R_s = \left( a + b \frac{n}{N} \right) R_a \quad (1)$$

Em que:  $R_s$  é radiação solar global ( $\text{MJ.m}^{-2}.\text{d}^{-1}$ );  $R_a$  é radiação extraterrestre ( $\text{MJ.m}^{-2}.\text{d}^{-1}$ );  $n$  é brilho solar ( $n$ );  $N$  é fotoperíodo;  $a$  e  $b$  são constantes da equação de Ångström.

**Tabela 1.** Métodos empíricos de estimativa da ETo.

Métodos	Referência	Equação
Penman Monteith FAO 56 (PM FAO-56)	Allen et al. (1998)	$ET_o = \frac{0,408\Delta(Rn - G) + \gamma \frac{900U_2(es - ea)}{T + 273}}{\Delta + \gamma(1 + 0,34U_2)}$
Hargreaves e Samani (HS)	Hargreaves e Samani (1985)	$ET_o = \frac{0,023Ra(Tmax - Tmin)^{0,5}(T + 17,8)}{2,45}$
Blaney Criddle Original (BCO)	Blaney Criddle Original (1950)	$ET_o = p(0,457T + 8,13)$
Schendel (Sch)	Schendel (1967)	$ET_o = 16 \frac{T}{UR}$
Mc Cloud (McC)	Mc Cloud (1995)	$ET_o = 0,245 * 1,07^{1,8T}$
Mc Guinness- Bordne (McG)	Mc Guinness- Bordne (1972)	$ET_o = 0,408Ra \frac{T + 5}{68}$
Kharrufa (KHA)	Kharrufa (1985)	$ET_o = 0,34pT^{1,3}$
Abtew (AB)	Abtew (1966)	$ET_o = \frac{0,53}{\lambda} Rs$
Makkin (Mak)	Makkin (1957)	$ET_o = 0,408Rs \frac{0,61Rs\Delta}{(\Delta + \gamma)} - 0,12$
Irmak (Irm)	Irmak et al. (2003)	$ET_o = 0,149Rs + 0,079T - 0,611$
Jensen e Haise (JH)	Jensen e Haise (1963)	$ET_o = 0,408Rs(0,0252T + 0,078)$
Jones e Ritchie (JR)	Jones e Ritchie (1990)	$ET_o = \alpha_1 0,00387Rs(0,6Tmax + 0,4Tmin + 29)$ <i>Se Tmax &lt; 0,5; <math>\alpha_1 = 0,01EXP(0,18(Tmax + 20))</math></i> <i>Se <math>0,5 \leq Tmax &lt; 35</math>; <math>\alpha_1 = 1,1</math></i> <i>Se Tmax <math>\geq 35</math>; <math>\alpha_1 = 1,1 + 0,05(Tmax - 35)</math></i>

Em que: ETo é evapotranspiração de referência (mm.d<sup>-1</sup>); Rn é saldo da radiação (MJ.m<sup>-2</sup>.d<sup>-1</sup>); radiação solar global (MJ.m<sup>-2</sup>.d<sup>-1</sup>); G é densidade de fluxo de calor para o solo (MJ.m<sup>-2</sup>.d<sup>-1</sup>);  $\gamma$  é constante psicométrico (kPa.°C<sup>-1</sup>); T é temperatura média do ar (°C); Tmax é temperatura máxima (°C); Tmin é temperatura mínima (°C); U<sub>2</sub> é velocidade do vento a 2 metros de altura (m s<sup>-1</sup>); e<sub>s</sub> é pressão de saturação a temperatura de bulbo seco (kPa); e<sub>a</sub> é pressão real ou atual de vapor d'água (kPa);  $\Delta$  é declividade da curva da pressão de saturação de vapor (kPa.°C<sup>-1</sup>); UR é

umidade relativa do ar (%); N é fotoperíodo (h);  $\lambda$  é calor latente de vaporização (MJ.m<sup>-2</sup>.d<sup>-1</sup>).

#### 4.2.1 Modelos de regressão linear múltipla (RLM)

A RLM é uma ferramenta estatística utilizada para expressar a relação quantitativa existente entre a variável resposta e a variável ou variáveis explicativa(s). A equação de RLM pode ser descrita com base na Equação 2. Os modelos de RLM utilizados foram

compostos pelas variáveis de entrada apresentadas na Tabela 2.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (2)$$

Em que: Y é variável resposta,  $\beta_0 - \beta_n$  são parâmetros que expressam a relação linear da Equação;  $X_1 - X_n$  são variáveis independentes.

**Tabela 2.** Variáveis de entrada utilizadas na RLM.

Número de modelos	Variáveis de entrada	Modelos de RLM
01	T	RLM1
02	Tmx e Tmin	RLM2
03	T e n	RLM3
04	Te Rs	RLM4
05	T e UR	RLM5
06	T e Ra	RLM6
07	T e U <sub>2</sub>	RLM7
08	T, U <sub>2</sub> e UR	RLM8
09	Tmx, Tmin e n	RLM9
10	Tmx, Tmin, T e Ra	RLM10

#### 4.2.2 Modelos de RNAs

As variáveis de entrada utilizadas nas RNAs são as mesmas apresentadas na Tabela 2. A estimativa da ETO utilizando as RNAs foi feita no programa computacional WEKA (*Weikato Environment of Knowledge Analysis*), (HALL et al., 2009). Segundo Witten et al. (2011), o WEKA é utilizado para pré-processamento dos dados, classificação, regressão, regras de associação e visualização. Nesse programa, 75% dos dados foram utilizados para o treinamento da rede e 25% para a validação. Segundo Da Silva et al. (2010), o subconjunto de treinamento é composto aleatoriamente com cerca de 60 a 90% das amostras do conjunto total.

A rede utilizada é denominada Percetron de Múltiplas Camadas (MLP), com algoritmo *backpropagation*, função sigmoideal (Eq. 3), *learning rate* = 0,3, *momentum* = 0,2, *training time* = 500 e camadas ocultas iguais a “a” (“a” = parâmetro padrão do WEKA). A MLP é composta por três camadas: de entrada, intermediária e de saída. Na camada de entrada são inseridas as variáveis apresentadas na Tabela 2; na camada intermediária, às variáveis de entrada são

atribuídos pesos e depois são passadas para a camada de saída quando o valor de ETO gerado é próximo do valor obtido pelo método de PM FAO-56. Segundo Haykin (1998), a MLP é a mais utilizada; ela pode ser representada com base na Equação 4.

$$f(x) = [1 + EXP(-x)]^{-1} \quad (3)$$

$$Y_i = \sum_{i=j}^N W_{i,j} X_{i,j} + \theta_i \quad (4)$$

Em que:  $Y_i$  é saída da rede;  $W_{i,j}$  é peso da ligação direta do neurónio j para neurónio i (na camada oculta);  $X_{i,j}$  é sinal de entrada a partir do neurónio de ordem j (para a camada de entrada);  $\theta_i$  são bias do neurónio i.

#### 4.3 Avaliação dos métodos

O desempenho de todos os métodos foi avaliado em relação ao método de PM FAO-56 utilizando os seguintes índices estatísticos: MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*) e R<sup>2</sup> (coeficiente de determinação). A significância de cada método foi analisada com base no teste t a 5% de nível de confiança. MBE > 0 indica superestimativa e o inverso, subestimativa. RMSE indica a

precisão do método e  $R^2$  indica o ajuste matemático. A seguir, é apresentada a referência para as melhores estimativas:  $MBE \cong 0$ ;  $RMSE \cong 0$  e  $R^2 \cong 1$ . As Equações 5, 6 e 7 foram utilizadas para calcular os índices MBE, RMSE e  $R^2$ , respectivamente.

$$MBE = \frac{1}{N} \sum_{i=1}^N (ET_{O_{Est}} - ET_{O_{PMF56}}) \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (ET_{O_{Est}} - ET_{O_{PMF56}})^2}{N}} \quad (6)$$

$$R^2 = \frac{\sum_{i=1}^N (ET_{O_{PMF56}} - \overline{ET_{O_{PMF56}}})(ET_{O_{Est}} - \overline{ET_{O_{Est}}})}{\sqrt{\sum_{i=1}^N (ET_{O_{PMF56}} - \overline{ET_{O_{PMF56}}})^2 \sum_{i=1}^N (ET_{O_{Est}} - \overline{ET_{O_{Est}}})^2}}$$

$$0 \leq R^2 \leq 1 \quad (7)$$

Em que:  $ET_{O_{Est}}$  são valores estimados pelos métodos/modelos (mm.d<sup>-1</sup>

<sup>1</sup>);  $ET_{O_{PMF56}}$  é valor obtido pelo método de PM FAO-56 (mm.d<sup>-1</sup>); N é número de observações;  $\overline{ET_{O_{PMF56}}}$  é média da ETo estimada pelo método de PM FAO-56 (mm.d<sup>-1</sup>);  $\overline{ET_{O_{Est}}}$  é média da ETo estimada pelos métodos avaliados (mm.d<sup>-1</sup>).

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Métodos empíricos de estimativa da ETo

A Tabela 3 mostra o desempenho dos métodos empíricos de ETo na cidade de Inhambane. Todos os métodos apresentaram uma correlação significativa com o método de PM FAO-56 ( $p < 0,05$ ), com valores de  $R^2$  variando de 0,66 a 0,98. As letras a e b representam os coeficientes linear e angular da reta de regressão, respectivamente.

**Tabela 3.** Desempenho estatístico dos métodos empíricos. Período de 1985 a 2009.

Tipo	Métodos	MBE (mm.d <sup>-1</sup> )	RMSE (mm.d <sup>-1</sup> )	a	b	R <sup>2</sup>	Teste t
Métodos de temperatura	HS	-0,83	0,97	0,62	0,70	0,88	-8,89*
	BCO	0,52	0,83	2,83	0,51	0,94	6,12*
	Sch	0,32	0,92	3,20	0,39	0,66	3,83*
	McC	1,92	2,09	4,60	0,44	0,67	22,78*
	McG	1,11	1,20	-0,03	1,24	0,96	9,21*
	KHA	1,12	1,22	1,90	0,84	0,86	11,19*
---	---	---	---	---	---	---	---
Métodos de radiação solar	AB	-0,46	0,69	1,43	0,60	0,98	-5,23*
	Mak	0,05	0,42	1,51	0,69	0,98	0,60 <sup>NS</sup>
	Irm	-0,50	0,78	1,69	0,54	0,98	-5,88*
	JH	0,87	0,92	0,47	1,08	0,96	7,86*
	JR	-0,16	0,37	0,96	0,76	0,98	-1,66 <sup>NS</sup>

**Nota:** \* = Significativo a 5% de nível de confiança e NS = Não significativo.

Entre os métodos de temperatura, observou-se que todos os métodos superestimaram a ETo obtida pelo método de PM FAO-56 ( $MBE > 0$ ), sendo observado o inverso no método de HS. Pior resultado de MBE foi observado no método de McC (1,92 mm.d<sup>-1</sup>) e melhor no método de Sch (0,32 mm.d<sup>-1</sup>), porém, o índice MBE

não é conclusivo na seleção de métodos. Diante disso, vários autores selecionaram métodos de estimativa da ETo com base no índice RMSE (TABARI et al., 2012; LIU et al., 2017).

Os resultados do teste t mostraram que existem diferenças estatisticamente significativas entre os valores de ETo

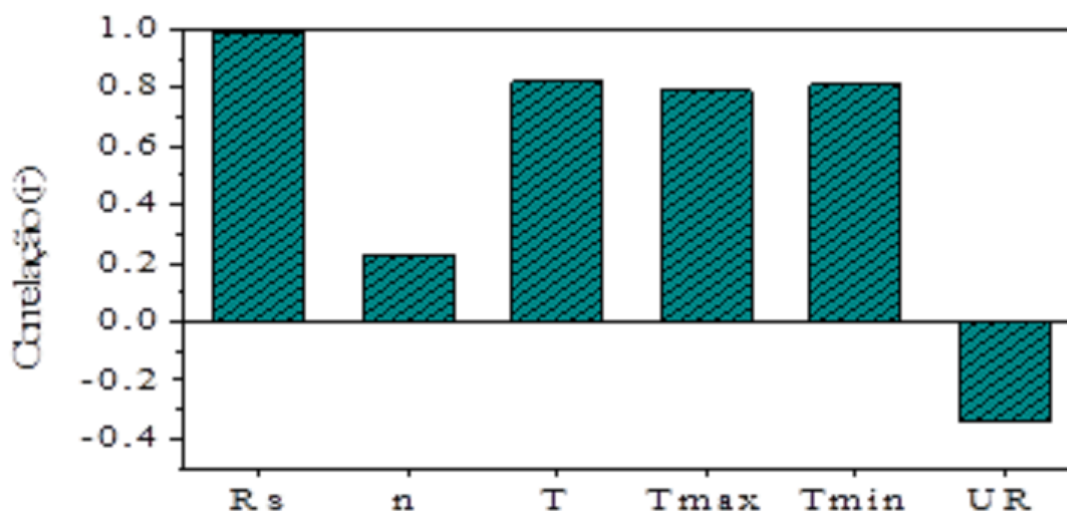
estimados pelos métodos de temperatura e pelo método de PM FAO-56 a 5% de nível de significância (Tabela 3). Contudo, o índice RMSE mostrou melhor resultado (elevada precisão) no método de BCO (RMSE = 0,83 mm.d<sup>-1</sup>) e pior resultado (baixa precisão) no método de McC (RMSE = 2,09 mm.d<sup>-1</sup>). O desempenho obtido no melhor método (MBE = 0,52 mm.d<sup>-1</sup>; RMSE = 0,83 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,94) é superior ao desempenho obtido por Liu et al. (2017): (MBE = 1,24 mm.d<sup>-1</sup>; RMSE = 2,30 mm.d<sup>-1</sup> e R<sup>2</sup> = 0,81); e por Tangune e Escobedo (2018): (MBE = -1,02 mm.d<sup>-1</sup>; RMSE = 1,17 mm.d<sup>-1</sup> e R<sup>2</sup> = 0,73). Isto revela que o ajuste local do método de BCO recomendado por Doorembos e Pruitt (1975) provavelmente não seja necessário nesta pesquisa, pois fica evidenciado que os parâmetros do método de BCO se adequaram ao clima da cidade de Inhambane (tropical úmido). Por outro lado, os índices MBE e RMSE encontrados estão próximos de zero e o índice R<sup>2</sup> está próximo de um. Já o método de McC relatado como pior, também foi relatado como pior por Liu et al. (2017) avaliando 16 métodos de ETo, corroborando com a presente pesquisa.

Nos métodos de radiação solar, verificou-se subestimativa da ETo nos métodos de AB, Irm e de JR, enquanto nos métodos de Mak e de JH foi verificado o oposto (Tabela 3). Ainda na Tabela 3, observou-se que os métodos de Mak e de JR não apresentaram estimativas de ETo estatisticamente diferentes do método de PM FAO-56 pelo teste t, significando que ambos métodos podem ser utilizados em substituição ao método de PM FAO-56. Todavia, os valores de RMSE classificaram o método de JR como melhor, ou seja, mais

preciso (RMSE = 0,37 mm.d<sup>-1</sup>) e o oposto foi observado no método de JH (RMSE = 0,92 mm.d<sup>-1</sup>). A precisão encontrada no método de JR é inferior à encontrada por Tabari et al. (2012). No entanto, o método de JR se adequa melhor ao clima da cidade Inhambane. No que refere ao método de JH, embora tenha sido o pior método, vários autores reportaram baixa precisão em relação ao presente trabalho em condições de clima seco (TABARI et al., 2010b; VALIPOUR et al., 2017), as quais são recomendadas como ideais por Jensen Haise (1963). Esse comportamento mostra que o método de JH pode produzir bons resultados em condições úmidas. A variação do desempenho dos métodos empíricos mostra a necessidade de uma seleção cuidadosa, sob risco de comprometer a produtividade agrícola. Ressalta-se que o método de JR subestimou a ETo em 0,16 mm.d<sup>-1</sup> e o método de JH superestimou em 0,87 mm.d<sup>-1</sup>.

Em geral, observou-se que os métodos baseados na radiação solar apresentaram desempenho melhor que os métodos baseados na temperatura, com destaque ao método de JR (Tabela 3). Ademais, os métodos de radiação apresentaram melhores ajustes matemáticos e com valores de MBE relativamente mais baixos. Isso mostra que a Rs, que foi uma das variáveis utilizadas nos métodos de radiação é mais influente na ETo. Essa constatação é reforçada com base na Figura 1, em que a Rs apresentou maior correlação com a ETo estimada pelo método de PM FAO-56 que as demais variáveis. As variáveis de entrada utilizadas em cada método estão apresentadas na Tabela 1.



**Figura 1.** Correlação das variáveis de entrada com a ETo

## 5.2 Estimativa da ETo a partir da RLM

A Tabela 4 mostra o desempenho estatístico dos modelos de RLM e as equações geradas em cada modelo para o cálculo da ETo na cidade de Inhambane,

utilizando dados mensais de 1985 a 2009. Todos os modelos apresentaram uma correlação estatisticamente significativa com o método de PM FAO-56 ( $p < 0,05$ ), com valores de  $R^2$  variando de 0,68 a 0,99.

**Tabela 4.** Desempenho estatístico de modelos de RLM.

Modelos	MBE (mm.d <sup>-1</sup> )	RMSE (mm.d <sup>-1</sup> )	R <sup>2</sup>	Teste t	Equações de ETo geradas
RLM1	-0,01	0,73	0,68	-0,14 <sup>NS</sup>	-5,6 + 0,429T
RLM2	-0,01	0,73	0,68	-0,07 <sup>NS</sup>	-5,17 + 0,183Tmax + 0,239Tmin
RLM3	-1,31	1,50	0,69	-13,58*	-7,04 + 0,421T + 0,195n
RLM4	0,01	0,15	0,99	0,10 <sup>NS</sup>	-3,28 + 0,078T + 0,310Rs
RLM5	0,001	0,70	0,70	0,05 <sup>NS</sup>	-0,78 + 0,411T - 0,057UR
RLM6	-0,01	0,23	0,97	-0,01 <sup>NS</sup>	-2,44 + 0,089T + 0,152Ra
RLM7	-0,002	0,73	0,68	-0,02 <sup>NS</sup>	-5,71 + 0,426T + 0,112U <sub>2</sub>
RLM8	-0,001	0,70	0,71	-0,05 <sup>NS</sup>	-0,81 + 0,406T + 0,130U <sub>2</sub> - 0,058UR
RLM9	-0,01	0,71	0,69	-0,05 <sup>NS</sup>	-6,05 + 0,116Tmax + 0,282Tmin + 0,232n
RLM10	0,01	0,23	0,97	0,08 <sup>NS</sup>	-3,29 + 0,108Tmax - 0,008Tmin + 0,154Ra

**Nota:** \* = Significativo a 5% de nível de confiança e NS = Não significativo.

Todos os modelos tiveram a tendência de não subestimar e nem superestimar a ETo do método de PM FAO-56 ( $MBE \cong 0$ ), diferentemente do modelo RLM3 ( $MBE = -1,31$  mm.d<sup>-1</sup>), o qual

subestimou (Tabela 4). Somente o modelo RLM3 apresentou estimativas da ETo estatisticamente diferentes dos valores obtidos pelo método de PM FAO-56 a 5% de nível de significância pelo teste t. Os

valores de RMSE da Tabela 4 mostram que o modelo RLM4 apresentou maior precisão ( $RMSE = 0,15 \text{ mm.d}^{-1}$ ), sendo classificado como melhor. Na impossibilidade de medir ou estimar a  $R_s$ , os modelos RLM6 e RLM10 podem ser utilizados como alternativa, pois apresentaram uma precisão ( $RMSE = 0,23 \text{ mm.d}^{-1}$ ) mais próxima ao modelo RLM4. Por outro lado, o modelo RLM6 requer a medição da  $T$  e o modelo RLM10 requer a medição da  $T_{max}$  e  $T_{min}$  que são elementos meteorológicos de fácil medição. O modelo RLM3 teve a pior precisão,  $RMSE = 1,5 \text{ mm.d}^{-1}$ , concordando com o comportamento observado através do índice MBE. Ressalta-se que na equação do modelo RLM10, a variável  $T$  foi excluída porque apresentou alta correlação com as demais variáveis explicativas.

Olhando para as equações de regressão (Tabela 4), verifica-se claramente que as variáveis  $T$  e  $R_s$  foram as mais influentes na estimativa da  $ET_o$ , pois os seus coeficientes angulares são maiores que

os coeficientes das demais variáveis. Por conseguinte, a combinação dessas duas variáveis no modelo RLM4 justifica o fato de ter sido melhor modelo. Ademais, observou-se na Figura 1 que a  $T$  e a  $R_s$  apresentaram alta correlação com os valores de  $ET_o$  do método de PM FAO-56. Tabari et al. (2012), fazendo uma combinação de  $T$  e  $R_s$  nos modelos de RLM, observaram uma precisão de  $0,48 \text{ mm.d}^{-1}$ . Essa precisão é inferior à encontrada na presente pesquisa, significando que a RLM respondeu melhor neste trabalho.

### 5.3 Estimativa da $ET_o$ com base nas RNAs

Os resultados estatísticos dos modelos de RNAs utilizados estão apresentados na Tabela 5. Todos os modelos tiveram uma correlação significativa com o método de PM FAO-56 ( $p < 0,05$ ), com valores de  $R^2$  variando de 0,72 (RNA9) a 0,99 (RNA4).

**Tabela 5.** Desempenho estatístico das RNAs.

Modelos	Variáveis de entrada	MBE ( $\text{mm.d}^{-1}$ )	RMSE ( $\text{mm.d}^{-1}$ )	a	b	$R^2$	Teste t
RNA1	T	0,11	0,66	1,83	0,65	0,76	0,60 <sup>NS</sup>
RNA2	$T_{mx}$ e $T_{min}$	0,20	0,72	2,22	0,58	0,76	1,12 <sup>NS</sup>
RNA3	T e n	-0,02	0,64	1,46	0,69	0,76	-0,13 <sup>NS</sup>
RNA4	Te $R_s$	-0,26	0,29	-0,39	1,09	0,99	-1,21 <sup>NS</sup>
RNA5	T e UR	0,19	0,61	1,58	0,71	0,81	1,00 <sup>NS</sup>
RNA6	T e $R_a$	0,37	0,46	1,16	0,84	0,98	1,88 <sup>NS</sup>
RNA7	T e $U_2$	0,09	0,65	1,68	0,67	0,76	0,47 <sup>NS</sup>
RNA8	T, $U_2$ e UR	0,03	0,61	1,66	0,66	0,79	0,14 <sup>NS</sup>
RNA9	$T_{mx}$ , $T_{min}$ e n	0,07	0,67	1,56	0,69	0,72	0,37 <sup>NS</sup>
RNA10	$T_{mx}$ , $T_{min}$ , T e $R_a$	0,45	0,54	1,30	0,82	0,96	2,29*

**Nota:** \* = Significativo a 5% de nível de confiança e NS = Não significativo.

Diferentemente dos modelos RNA3 e RNA4, os demais modelos superestimaram a  $ET_o$  (Tabela 5). O índice RMSE mostrou que o modelo RNA4 foi o melhor (alta precisão,  $RMSE = 0,29 \text{ mm.d}^{-1}$

<sup>1</sup>) e o modelo RNA2 foi o pior (baixa precisão,  $RMSE = 0,72 \text{ mm.d}^{-1}$ ) (Tabela 5). À semelhança da presente pesquisa, Traore et al. (2016), estudando o desempenho de quatro tipos de redes neurais na estimativa

da ETo, observaram piores resultados quando utilizaram a Tmax e Tmin como variáveis de entrada. Todavia, quando combinaram a temperatura com a Rs ou Ra, o desempenho melhorou, sendo isto verificado na Tabela 5. Ademais, Yassin et al. (2016) observaram que as redes neurais tendem a produzir melhores resultados quando a Rs é combinada com outras variáveis meteorológicas. Esses autores obtiveram uma precisão de 0,19 mm.d<sup>-1</sup>, a qual supera a precisão do melhor modelo desta pesquisa, modelo RNA4. A maior precisão encontrada por Yassin et al. (2016) é justificada pelo fato dos autores terem combinado a Rs com mais variáveis de entrada (Rs combinado com oito variáveis), enquanto que, na presente pesquisa, a Rs foi combinada apenas com T (Tabela 5). Vyas e Subbaiah (2016) obtiveram uma precisão inferior ao modelo RNA4 (RMSE = 0,38 mm.d<sup>-1</sup>), utilizando também T e Rs como variáveis de entrada. Utilizando as mesmas variáveis (T e Rs), Tangune e Escobedo (2018) estudando a ETo em 22 cidades do estado de São Paulo, encontraram em algumas cidades, uma precisão inferior a do modelo RNA4, e noutras cidades superior.

Ainda em relação ao número de variáveis de entrada na rede, Tangune e Escobedo (2018) observaram que, em geral, o desempenho da rede aumenta com o aumento do número de variáveis de entrada.

Além desses autores, vários outros autores apresentaram a mesma constatação (ABDULLAH et al., 2015; YASSIN et al., 2016). Esse comportamento é verificado na Tabela 5, quando o modelo RNA1 é comparado com os demais modelos, com exceção quando se faz a comparação em relação ao modelo RNA2 (pior modelo desta pesquisa). Embora o modelo RNA2 tenha sido o pior, possivelmente a sua precisão pode ser melhorada ajustando os parâmetros do WEKA e/ou mudando o tamanho do banco de dados no treinamento da rede.

Na ausência da Rs, o modelo RNA6 (RMSE = 0,46 mm.d<sup>-1</sup>) pode ser utilizado como alternativa, pois apresentou uma precisão mais próxima ao modelo RNA4, além de exigir somente a medição da T, que é uma variável fácil de medir. Ressalta-se que os resultados do teste t mostraram que somente o modelo RNA10 é estatisticamente diferente do método de PM FAO-56 a 5% de nível de confiança.

#### 5.4 Comparação de todos os métodos

Conforme já relatado, a seleção dos métodos baseou-se principalmente no índice RMSE. Na Tabela 6 é apresentada a classificação de todos os métodos com base nos valores de RMSE.

**Tabela 6.** Seleção dos métodos através do índice RMSE.

Posição ( <sup>a</sup> )	Modelos	RMSE (mm.d <sup>-1</sup> )	Posição ( <sup>a</sup> )	Modelos	RMSE (mm.d <sup>-1</sup> )
1	RLM4	0,15	14	RLM5 e RLM8	0,70
2	RLM6 e RLM10	0,23	15	RLM9	0,71
3	RNA4	0,29	16	RNA2	0,72
4	JR	0,37	17	RLM1, RLM2 e RLM7	0,73
5	Mak	0,42	18	Irm	0,78
6	RNA6	0,46	19	BCO	0,83
7	RNA10	0,54	20	Sch e JH	0,92
8	RNA5 e RNA8	0,61	21	HS	0,97
9	RNA3	0,64	22	McG	1,20
10	RNA7	0,65	23	KHA	1,22
11	RNA1	0,66	24	RLM3	1,50
12	RNA9	0,67	25	McC	2,09
13	AB	0,69	--	--	---

Embora a literatura venha relatando que as RNAs produzem resultados confiáveis na estimativa da ETo (CHAUHAN; SHIRIVASTAVA, 2012), observou-se na Tabela 6 que a precisão das redes pode ser inferior em relação a alguns métodos empíricos e modelos de RLM, sendo assim, o uso das RNAs deve ser feito de forma criteriosa. O modelo RLM4 mostrou-se ser mais eficiente na estimativa da ETo (RMSE = 0,15 mm.d<sup>-1</sup>) quando comparado aos demais métodos. Todos os métodos de temperatura, praticamente, apresentam-se de menor eficiência de estimativa da ETo na cidade de Inhambane. Na falta dos dados de Rs, os modelos RLM6 e RLM10 podem ser utilizados, conforme evidências apontadas pelos resultados da presente pesquisa.

## 6 CONCLUSÃO

Os resultados encontrados mostraram que dentre os métodos avaliados (11 métodos empíricos, dez modelos de regressão múltipla: RLM e dez redes neurais artificiais: RNAs), o modelo de

RLM4 apresentou melhor resultado para a estimativa da ETo na cidade de Inhambane (MBE = 0,01 mm.d<sup>-1</sup>; RMSE = 0,15 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,99), o qual exige a medição da temperatura média (T) e da radiação solar global (Rs). Na falta da Rs, os modelos RLM6 (MBE = -0,01 mm.d<sup>-1</sup>; RMSE = 0,23 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,97) e RML 10 (MBE = 0,01 mm.d<sup>-1</sup>; RMSE = 0,23 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,97) podem ser utilizados como alternativa. O modelo RLM4 exige a medição da T e o modelo RLM10 exige dados de temperatura máxima e mínima, os quais são de fácil medição. Todos esses modelos não foram estatisticamente diferentes do método de Penman Monteith FAO 56 na estimativa da ETo pelo teste t a 5%.

Em geral, os métodos empíricos baseados na temperatura apresentaram os piores resultados. Os métodos empíricos de radiação solar podem estimar a ETo melhor em relação a alguns modelos de RLM e RNAs, com destaque ao método de Jones e Ritchie (MBE = -0,16 mm.d<sup>-1</sup>; RMSE = 0,37 mm.d<sup>-1</sup>; R<sup>2</sup> = 0,98), o qual ocupou a 3ª posição.

## 7 REFERÊNCIAS

ABDULLAH, S. S.; MALEK, M. A.; ABDULLAH, N. S.; KISI, O.; YAP, K. S. Extreme learning machines: A new approach for prediction of reference evapotranspiration. **Journal of Hydrology**, v. 527, p. 184-195, 2015.

ABTEW, W. Evapotranspiration measurements and modeling for three wetland systems in South Florida. **Journal of the American Water Resources Association**, v. 127, n. 3, p. 140-147, 1966.

BAKHTIARI, B.; GHAREMAN, N.; LIAGHAT, A.M.; HOOGENBOOM, G. Evaluation of reference evapotranspiration models for a semiarid environment using lysimeter measurements. **Journal of Agricultural Science Technology**, v. 13, p. 223–237, 2011.

BESHIR, S. Review on Estimation of Crop Water Requirement, Irrigation Frequency and Water Use Efficiency of Cabbage Production. **Journal of Geoscience and Environment Protection**, v. 5, n. 7, p. 59-69, 2017.

BLANEY, H. F.; CRIDDLE, W.O. **Determining water requirements in irrigated areas from climatological and irrigation data**. Washington: USDA Soil Conservation Service, 1950. 48 p. (Technical Paper n. 96).

CAO, J. F.; LI, Y. Z.; ZHONG, X. L.; ZHAO, Y. M. Comparison of four combination methods for reference crop evapotranspiration. **Chinese Journal of Agrometeorology**, v. 36, n. 4, p. 428-436, 2015.

CHAUHAN, S.; SHRIVASTAVA, R. K. Estimating reference evapotranspiration using neural computing technique. **Journal of Indian Water Resources Society**, v. 32, n. 1-2, 2012.

CHATZITHOMAS, C. D.; ALEXANDRIS, S. G. Solar radiation and relative humidity based, empirical method, to estimate hourly reference evapotranspiration. **Agricultural Water Management**, v. 152, p. 188-197, 2015.

Da SILVA, I. N.; SPATT, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo. 2010. 399 p.

DOOREMBOS, J.; PRUITT, W.O. **Guidelines for predicting crop water requirements**. FAO Irrigation and drainage paper 24, Roma, 1975, 179 p.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMRNA, P.; WITTEN, I. H. **The WEKA Data Mining Software: An Update**; SIGKDD Explorations, v.11, n.1, 2009.

HARGREAVES, G. H.; SAMANI, Z. Reference crop evapotranspiration from temperature. **Journal of Applied Engineering in Agriculture**, v.1, n. 2, p.96-99, 1985.

HAYKIN, S. **Neural network: A Comprehensive Foundation**. 2<sup>nd</sup> ed. Hamilton: Prentice Hall. 1998. 897p.

IRMAK, S.; IRMAK, A.; ALLEN, R. G.; JONES, J. W. Solar and net radiation – based equations to estimate reference evapotranspiration in humid climates. **Journal of Irrigation and Drainage Engineering**, v. 129, n. 5, p. 336-347, 2003.

JENSEN, M. E.; HAISE, H. R. Estimating evapotranspiration from solar radiation. **Journal of the Irrigation and Drainage Division**, v. 89, p.15-41, 1963.

JONES, J. W., RITCHIE, J. T. Crop growth models. Management of farm irrigation systems. In: Hoffman, G.J., Howel, T.A., Solomon, K.H. (Eds.), **ASAE Monograph**, n. 9, p. 63-89, 1990.

KHARRUFA, N. S. Simplified equation for evapotranspiration in arid regions. **Beitrag zur Hydrologie**, v. 5, n. 1, p. 39-47, 1985.

LIU, X.; XU, C.; ZHONG, X.; LI, Y.; YUAN, X.; CAO, J. Comparison of 16 models for reference crop evapotranspiration against weighing lysimeter measurement. **Agricultural water management**, v. 184, p. 145-155, 2017.

MAEDA, E. E.; WILBERG, D. A.; PELLIKKA, P. K. E. Estimating reference evapotranspiration using remote sensing and empirical models in a region with limited ground data availability in Kenya. **Applied Geography**, v. 31, p. 251-258, 2011.

MAKKINK, G. F. Testing the Penman formula by means of lysimeters. **Journal of Institution of Water Engineers**, v. 13, n. 3, p. 277-288, 1957.

MINISTÉRIO PARA A COORDENAÇÃO DA ACÇÃO AMBIENTAL (MICOA). **Projecto de avaliação ambiental estratégica da zona costeira-Moçambique**. Perfil ambiental e mapeamento do uso actual da terra nos distritos da zona costeira de Moçambique. Inhambane. 71 p, 2012.

MC CLOUD, D. E. Water requirements of field crops in Florida as influenced by climate. **Proceeding Soil Science Society of Florida**. v.15, p. 165-172, 1995.

MC GUINNESS, J. L; BORDNE, E. F **A comparison of lysimeter-derived potential evapotranspiration with computed values**. US Department. of Agriculture, Washington, DC, 1972.

LANDERAS, G.; ORTIZ BARREDO, A.; LÓPEZ, J. J.; Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). **Agricultural water management**, v. 95, p. 553-565, 2008.

NGONGONDO, C.; XU, C. Y.; TALLAKSEN, L. M.; ALEMAW. Evaluation of the FAO Penman-Montheith, Priestly-Taylor and Hargreaves models for estimating reference evapotranspiration in southern Malawi. **Hydrology Research**. v. 44, p.706-722, 2013.

PATEL, J.; PATEL, H.; BHATT, C. Modified Hargreaves equation for accurate estimation of evapotranspiration of diverse climate locations in India. **Proceedings of the National Academy Sciences**, v. 85, n. 1, p.161-166, 2015.

SCHENDEL, U. **Vegetation's Wasserverbrauch und Wasserbedarf**. Habilitation, Kiel. 1967. 137 p.

SHIRI, J.; NAZEMI, A. H.; SADRADDINI, A. A.; LANDERAS, G.; KISI, O.; FARD, A. F., MARTI, P. Comparison of heuristic and empirical approaches for estimating reference evapotranspiration from limited inputs in Iran. **Computers and Electronics in Agriculture**, v. 108, p. 230–241, 2014.

TABARI, H. Evaluation of reference crop evapotranspiration equations in various climates. **Water Resource Management**, v. 24, n. 10, p. 2311-2337, 2010b.

TABARI, H.; MAROFI, S.; SABZIPARVAR, A. A. Estimation of daily pan evaporation using artificial neural network and multivariate non-linear regression. **Irrigation Science**, v. 28, p. 399–406, 2010a.

TABARI, H.; KISI, O.; EZANI, A.; TALAEI, P. H. MVS, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. **Journal of hidrology**, 444-445, p. 78-89, 2012.

TANGUNE, B. F.; ESCOBEDO, J. F. Reference evapotranspiration in São Paulo State: Empirical methods and machine learning techniques. **International Journal of Water Resources and Environmental Engineering**, v. 10, n. 4, p. 33-44, 2018.

TANGUNE, B. F.; CHIMENE, C. A. Efficiency of empirical methods for reference evapotranspiration estimation in the district of Vilankulo, Mozambique. **International Journal of Water Resources and Environmental Engineering**, v. 11, n. 4, p. 76-82, 2019.

TRAORE, S.; LUO, Y.; FIPPS, G. Deployment of artificial neural network for short-term forecasting of evapotranspiration using public weather forecast restricted messages. **Agricultural water management**, v. 163, p. 363-379, 2016.

VALIPOUR, M.; SEFIDKOUHI, M. A. G.; RAENI- SARJAZ, M. Selecting the best model to estimate potential evapotranspiration with respect to climate change and magnitudes of extreme events. **Agricultural Water Management**, v. 180, p. 50-60, 2017.

VYAS, K. N.; SUBBAIAH, R. Application of artificial neural network approach for estimating reference evapotranspiration. **Current World Environment**, v. 11, n. 2, p. 637-647, 2016.

YASSIN, M. A.; ALAZBA, A. A.; MATTAR, M. A. Artificial neural network versus gene expression programming for estimating reference evapotranspiration in arid climate. **Agricultural Water Management**, v. 163, p. 110-124, 2016.