



Modelos de *machine learning* aplicados na estimação da evapotranspiração de referência do Planalto Ocidental Paulista

Maurício Bruno Prado da SILVA¹, Valter Cesar DE SOUZA¹, Caroline Pires CREMASCO^{1*},
Marcus Vinícius Contes CALÇA¹, Cícero Manoel DOS SANTOS², Camila Pires CREMASCO¹,
Luís Roberto Almeida GABRIEL FILHO¹, Sergio Augusto RODRIGUES¹, João Francisco ESCOBEDO¹

¹Programa de Pós Graduação em Engenharia Agrícola, Universidade Estadual Paulista, Botucatu, SP, Brasil.

²Universidade Federal do Pará, Belém, PA, Brasil.

*E-mail: caroline.cresmasco@unesp.br

(ORCID: 0000-0001-5817-1409, 0000-0001-5103-9771, 0000-0002-9157-4653, 0000-0002-5685-3980, 0000-0002-6850-9757,
0000-0003-2465-1361, 0000-0002-7269-2806, 0000-0002-2091-2141, 0000-0002-8196-4447)

Submetido em 02/06/2022; Aceito em 01/11/2022; Publicado em 16/11/2022.

RESUMO: A evapotranspiração depende da interação entre variáveis meteorológicas (radiação solar, temperatura do ar, precipitação, umidade relativa do ar e velocidade do vento) e condições fitossanitárias das culturas agrícolas. É complexo construir medidas confiáveis de evapotranspiração devido aos elevados custos para implantação de técnicas micrometeorológicas, além de dificuldades na operação e manutenção dos equipamentos necessários. O propósito desta pesquisa foi modelar a evapotranspiração de referência (ET_o) por meio de técnicas de *machine learning* em dados climáticos de 30 estações meteorológicas automáticas do Planalto Ocidental Paulista, Estado de São Paulo, Brasil, no período de 2013-2017. Uma comparação do desempenho estatístico entre as técnicas utilizadas foi realizada onde constatou-se melhor desempenho do modelo ET_oMPL4 (rRMSE = 0.62%), seguido por ET_oANFIS4 (rRMSE = 0.75%), ET_oSVM4 (rRMSE = 1.19%) e ET_oGRNN4 (rRMSE = 11.05%). Medidas de performance da base de validação evidenciam que os modelos propostos são aptos à estimativa da evapotranspiração de referência com destaque para a técnica MPL. **Palavras-chave:** evapotranspiração; modelagem matemática; aprendizagem de máquina.

Machine learning models applied in the estimation of reference evapotranspiration from the Western Plateau of Paulista

ABSTRACT: Evapotranspiration depends on the interaction between meteorological variables (solar radiation, air temperature, precipitation, relative humidity and wind speed) and phytosanitary conditions of agricultural crops. It is complex to build reliable evapotranspiration measurements due to the high costs of implementing micrometeorological techniques, in addition to difficulties in the operation and maintenance of the necessary equipment. The purpose of this research was to model the reference evapotranspiration through machine learning techniques in climatic data from 30 automatic weather stations in the Planalto Ocidental Paulista, State of São Paulo, Brazil, in the period 2013-2017. A comparison of the statistical performance between the techniques used was carried out, where the best performance of the ET_oMPL4 model (rRMSE = 0.62%), followed by ET_oANFIS4 (rRMSE = 0.75%), ET_oSVM4 (rRMSE = 1.19%) and ET_oGRNN4 (rRMSE = 11.05%). Performance measures of the validation base show that the proposed models are able to estimate the reference evapotranspiration, with emphasis on the MPL technique.

Keywords: evapotranspiration; modeling; machine learning.

1. INTRODUÇÃO

A evapotranspiração (ET) é uma característica bastante importante para a gestão eficiente da irrigação, sendo que a estimação de medidas precisa deste fenômeno é essencial para a gestão de recursos hídricos, planejamento da irrigação e produção das culturas. Contudo, a ET é um fenômeno multidimensional que depende da interação entre as variáveis meteorológicas (radiação solar, temperatura do ar, precipitação, umidade relativa do ar e velocidade do vento), das condições de solo e fitossanitárias das culturas agrícolas. Já a evapotranspiração de referência (ET_o) independe da cultura, pois considera a grama como uma cultura hipotética de referência e, conseqüentemente, pode ser mensurada

considerando apenas as características climáticas da região (ALLEN et al., 1998; SENTELHAS et al., 2010; SNYDER, 2017).

A complexidade em obter medidas confiáveis da ET_o se dá aos altos custos para implantação de procedimentos micrometeorológicos e lisimétricos, além das dificuldades técnicas para operar e fazer manutenção dos equipamentos. Devido estas dificuldades de se obter medidas diretas da ET_o, métodos indiretos considerando funções matemáticas das condições climáticas locais são bastante utilizados e difundidos na literatura. Atualmente, o método padrão recomendado pela *Food and Agriculture Organization* (FAO) para estimação de medidas da ET_o é o método proposto por

de Penman-Monteith ($ET_{OFAO-56}$) (ALLEN et al., 1998), o qual requer inúmeras medições meteorológicas confiáveis apenas de variáveis meteorológicas.

Observa-se na literatura muitas aplicações para determinação da ET_o utilizando modelos de regressão ajustados em função de diferentes variáveis meteorológicas em várias regiões brasileiras (PENMAN, 1948; THORNTHWAITE, 1948; HARGREAVES; SAMANI, 1985; BLANEY e CRIDDLE, 1950; MAKKINK, 1957; JENSEN; HAISE, 1963; BENEVIDES; LOPEZ, 1970; PRIESTLEY; TAYLOR, 1972; ALLEN; PRUITT, 1991; SNYDER, 1992).

Atualmente destacam-se também na predição de evapotranspiração de referência (ET_o) a modelagem por Aprendizado de Máquinas (AM) (TANGUNE; ESCOBEDO, 2018), Geostatística (VANDERLINDEN et al., 2008), Regressões Múltiplas (RM) (ALTHOFF et al., 2018) e Sensoriamento Remoto (SR) (FERREIRA SILVA et al., 2018). As técnicas de AM são conhecidas por sua aplicabilidade em diversas áreas e a literatura relata diversos exemplos de sucesso em sua utilização. Essas técnicas são baseadas no comportamento de cérebro humano e indicadas para modelar problemas não lineares. Entre os modelos de AM mais conhecidos e utilizados estão a *Artificial Neural Network* (ANN) e o *Support Vector Machine* (SVM). Entre as ANN mais difundidas na literatura estão: *Adaptive Neuro Fuzzy Inference System* (ANFIS), *Generalized Regression Neural Network* (GRNN) e *Multilayer Perceptron* (MLP), sendo esta última uma das mais utilizadas atualmente. Diversos autores têm relatado o sucesso da utilização dessas técnicas na modelagem de ET_o em função de variáveis climáticas (LANDERAS et al., 2008; KUMAR et al., 2011; TABARI et al., 2012).

Na engenharia Agrícola, técnicas de modelagem matemática com inteligência artificial vêm sendo aplicadas com sucesso, na produção e empresas avícolas (Pereira et al., 2008; Cremasco et al., 2010), na produção bovina (Gabriel Filho et al., 2011, 2016; Maziero et al., 2022), em engenharia de irrigação (Viais Neto et al., 2019a,b; Putti et al., 2017b, 2021, 2022; Boso et al. 2021a,b; Matulovic et al., 2021; Gabriel Filho et al., 2022a,b), na otimização de implementos Agrícolas (Góes et al., 2022), no aumento da vitalidade das plantas (Putti et al., 2014, 2017b), no mercado de produtos Agrícolas (Gabriel Filho et al., 2015; Martínez et al., 2020) e na otimização de sistemas de irrigação (Castro et al., 2022).

O objetivo do trabalho foi modelar a ET_o por meio de técnicas de *Machine Learning* utilizando variáveis meteorológicas e comparar as medidas previstas por estes modelos com as medidas obtidas pelo método padrão proposto pela FAO.

2. MATERIAL E MÉTODOS

Os dados meteorológicos necessários para a modelagem da ET_o foram obtidos através de 30 estações meteorológicas automáticas (EMA's) da região do Planalto Ocidental Paulista, medidos nos anos de 2013 a 2017. Foram gerados modelos para estimação de ET_o por meio de quatro diferentes técnicas de *Machine Learning* (MA): MLP, ANFIS e GRNN e SVM. Valores ausentes foram detectados no banco de dados, a recomposição destes dados foi realizada através da técnica multivariada de Componentes Principais (PCA) para preenchimento de dados faltantes na série histórica utilizada, através do algoritmo EM para PCA (JOSSE; HUSSON, 2012).

2.1. Região de estudo

A região de estudo foi o Planalto Ocidental Paulista, localizado a noroeste do Estado de São Paulo. Essa região é composta pela integração de duas regiões intermediárias do Estado de São Paulo: São José do Rio Preto e Ribeirão Preto (latitude $19^{\circ}32' - 21^{\circ}57'S$, longitude $46^{\circ}38' - 51^{\circ}28'O$ e altitude 335.00 – 1026.00 m). Com clima do tipo Aw, tropical (megatérmico), apresentando um verão chuvoso e inverno seco (KÖPPEN, 1928), a região do Planalto Ocidental Paulista possui uma área de aproximadamente 53492.00 km² e é composta por 164 municípios (representando 25.43% do total de municípios do Estado de São Paulo). Com uma população de aproximadamente 4.188.425 de habitantes que representa 9.29% da população do Estado, segundo o Instituto Brasileiro de Geografia e Estatística no censo de 2018 (IBGE, 2018).

2.2. Base de dados

A base de dados das variáveis meteorológicas monitorada na região de estudo é composta por diversas variáveis.

Tabela 1. Informações geográficas das EMA's: localidade, latitude, longitude, altitude (Alt) e classificação climática (Clss).

Localidade	Latitude	Longitude	Alt	Clss
	(°)	(°)	(m)	
Campina Verde*	19°32'S	49°32'W	555,2	Aw
Paranaíba**	19°41'S	51°10'W	424,0	Aw
Populina	19°52'46"S	50°28'13"W	394,0	Aw
Sacramento*	19°53'S	47°26'W	912,0	Csa
Conceição das Alagoas*	19°59'S	48°09'W	568,0	Aw
Paranapuã	20°01'29"S	50°33'57"W	436,1	Aw
Jales	20°09'S	50°35'W	457,0	Aw
Ituverava	20°21'S	47°46'W	600,0	Aw
Ilha Solteira	20°25'24"S	51°21'13.1"W	337,0	Aw
Marinópolis	20°26'48"S	50°48'26.1"W	370,0	Aw
Pereira Barreto I	20°31'42"S	51°14'58"W	426,0	Aw
Barretos	20°33'S	48°32'W	533,0	Aw
Franca	20°34'S	47°22'W	1026,0	Aw
Itapura	20°38'28"S	51°28'29.9"W	335,0	Aw
Pereira Barreto II	20°40'23"S	51°2'2.1"W	357,0	Aw
Sud Mennucci	20°43'42"S	50°57'30"W	350,0	Aw
Passos*	20°44'S	46°38'W	784,0	Cwa
Monte Azul Paulista	20°54'26"S	48°38'29"W	611,0	Aw
Brodowsky	20°59'03"S	47°39'33"W	863,0	Cwa
José Bonifácio	21°02'S	49°41'W	405,0	Aw
Ariranha	21°07'S	48°50'W	525,0	Aw
Sertãozinho	21°08'16"S	47° 59' 24" W	579,0	Aw
Cássia dos Coqueiros	21°16'58"S	47°10'11"W	890,0	Cwb
Valparaíso	21°19'S	50°55'W	374,0	Aw
Pradópolis	21°20'S	48°06'W	544,0	Aw
São Simão	21°28'44"S	47° 33' 3" W	620,0	Aw
Lins	21°39'S	49°44'W	459,0	Aw
Tambaú	21°42'18"S	47° 16' 26" W	698,0	Aw
Ibitinga	21°51'S	48°48'W	492,0	Aw
São Carlos	21°57'S	47°52'W	863,0	Cwa

*Estado de Minas Gerais, **Estado de Mato Grosso do Sul.

Tais variáveis são dadas por: irradiação solar global (H , MJ m⁻² dia⁻¹); temperaturas máxima e mínima do ar (T_{max} e T_{min} , °C), umidade relativa do ar (UR, %), velocidade do vento (U_2 , m s⁻¹) medida a 10 metros de altura da superfície, convertida posteriormente para 2 metros de altura conforme metodologia descrita por Allen et al. (1998) e a irradiação

solar global no topo da atmosfera (Ho, MJ m⁻² hora⁻¹), obtida pela metodologia descrita por Iqbal (1983).

As informações geográficas (localidade, latitude, longitude, altitude e distância do mar), classificação climática das 30 estações meteorológicas que fornecem informações para os municípios da região de estudo são apresentadas na Tabela 1.

Para seu processamento a tecnologia de gerenciamento de banco de dados MySQL 5.7 (*Relational Database Management System*) da Oracle em sua versão de código aberto (licença GNU), atuando como um servidor local (ORACLE CORPORATION, 2019). Com isso, foi possível realizar a transformação da base de dados de partição horária para diária e checar a presença de eventuais valores espúrios.

2.3. Componentes Principais

A técnica de Análise de Componentes Principais (PCA) foi utilizada para a reconstrução da base de dados com intuito de preencher as observações faltantes. Considerando matrizes formadas por medições diárias de cada variável de 5 anos (colunas) nas 30 estações meteorológicas (linhas), tem-se um banco de dados de alta dimensão, dado que o um número de elementos amostrais (linhas) é inferior ao número de variáveis (colunas). Um algoritmo capaz de realizar a imputação dos dados faltantes neste cenário é o EM para PCA, que foi utilizado neste trabalho (JOSSE et al., 2009; JOSSE; HUSSON, 2012; JOSSE; HUSSON, 2016), disponível no pacote *missMDA* do ambiente computacional R-Gui (R CORE TEAM, 2018).

2.4. Modelo de referência de Penman-Monteith

O modelo de Penman-Monteith (PM) é utilizado como padrão para o cálculo da evapotranspiração de referência ($ET_{OFAO-56}$), considerando o boletim número 56 em 1998 da FAO – Food and Agricultural Organization (ALLEN et al., 1998). A Equação 1 apresenta a equação utilizada para o cálculo das medidas de $ET_{OFAO-56}$:

$$ET_{OFAO-56} = \frac{0.408\Delta(R_n - G) + \left(\gamma \frac{900}{T_m + 273}\right) u_2 (e_s - e_a)}{\Delta + [\gamma(1 + 0.34U_2)]} \quad (01)$$

em que: saldo de radiação (R_n , MJ m⁻² dia⁻¹), fluxo de calor no solo (G , MJ m⁻² dia⁻¹), velocidade do vento (U_2 , m s⁻¹), pressão de saturação de vapor d'água do ar (e_s , kPa), pressão atual de vapor d'água do ar (e_a , KPa), temperatura média do ar (T_m , °C), inclinação da curva de pressão de vapor saturado (Δ , kPa °C⁻¹) e coeficiente psicrométrico (γ , kPa °C⁻¹). Para obtenção do saldo de radiação (R_n), foi considerada a metodologia do balanço de radiação sugerida no Boletim FAO-56. O fluxo de calor do solo (G), quando considerado em partição diária, é praticamente igual a zero. Os valores medidos da velocidade do vento (U_2), considerada no modelo $ET_{OFAO-56}$ é obtida de anemômetros instalados a 2 m de altura da superfície do solo. Do contrário, os valores medidos de U_2 em alturas superiores são convertidos para 2 m de altura da superfície (ALLEN et al., 1998).

2.5. Machine Learning

Machine Learning (ML) é uma técnica computacional que realiza extração de informações de um conjunto de dados, por meio da interação da inteligência artificial com a estatística, através do princípio de inferência denominada de

indução que resultará em uma aprendizagem supervisionada (LORENA et al., 2011). Para o processamento da base de dados, considerando todas as EMA's e as medições diárias das variáveis meteorológicas, para obtenção de estimativas da ET_o foi utilizado o *software* MatLab (*MATRIX LABORATORY*) para as técnicas *Multilayer Perceptron* (MLP), *Adaptive Neuro-Fuzzy Inference System* (ANFIS) e *Generalized Regression Neural Network* (GRNN). Para a técnica *Support Vector Machine* (SVM) foi utilizado o aplicativo WEKA, *Waikato Environment for Knowledge Analysis*.

2.5.1. Multilayer Perceptron

A técnica é classificada como uma rede neural do tipo *feedforward*, conhecida por possuir alimentação a frente ou única direção de camadas múltiplas (HAYKIN, 1998). O algoritmo realiza o treinamento da técnica MLP de maneira supervisionada e em duas fases, como ilustrado na Figura 1.

Na primeira fase as informações das variáveis de entrada e os pesos iniciais se propagam e ao final desse processo há comparação das informações iniciais e de saída; na segunda fase, ocorre o processo inverso e as informações de saída são comparadas com as iniciais (LAM et al., 2008; SILVA et al., 2017).




Figura 1. Ilustração de uma rede MLP, adaptado de Kumar et al. (2011).

Figure 1. Illustration of an MLP network, adapted from Kumar et al. (2011).

2.5.2. Adaptive Neuro-Fuzzy Inference System

A lógica de processamento consiste em utilizar a forma de interpretação da Lógica *Fuzzy* e as características de aprendizado da rede neural compondo um sistema híbrido. A Figura 2 apresenta a estrutura da ANFIS para duas variáveis de entrada, uma saída e duas regras.




Figura 2. Ilustração de uma rede ANFIS, adaptado de Jang (1993).

Figure 2. Illustration of an ANFIS network, adapted from Jang (1993).

Os nós adaptativos representados por quadrados, os fixos por círculos e são divididos em interações entre cinco camadas que acontecem em dois processos: fuzzificação e defuzzificação (ZADEH, 1968; TAKAGI; SUGENO, 1985).

2.5.3. Generalized Regression Neural Network

A rede GRNN é uma versão recente e otimizada da rede *Radial Basis Function* (RBF), não requer um treinamento iterativo. Consiste de duas camadas, padrão e somadora, além da camada de entrada e saída, como ilustrado na Figura 3.




Figura 3. Ilustração de uma rede GRNN, adaptado de Khatib e Elmenreich (2015).

Figure 3. Illustration of a GRNN network, adapted from Khatib and Elmenreich (2015).

Nesta estrutura o número de neurônio da camada padrão é igual ao número de amostras da camada de entrada. A camada padrão é conectada a camada somadora que funcionam juntas para normalizar os valores de saída.

2.5.4. Support Vector Machine

A técnica é derivada da teoria de aprendizagem estatística e foi primeiramente introduzida por Vapnik em 1995 (TABARI et al., 2012). A técnica procura, por meio do princípio da minimização do risco estrutural, minimizar um limite superior de erro de generalização em vez de minimizar o erro de treinamento local (VAPNIK, 1995; VAPNIK, 1998; CHEN et al., 2015). A solução de problemas de regressão usando a SVM pode ser dada por meio de um algoritmo iterativo, chamado de *Sequential Minimal Optimization* (SMO) (SMOLA; SCHÖLKOPF, 1998).

2.6. Validação dos modelos

Antes da validação dos modelos de ML, foram realizados diversos ensaios para determinação dos parâmetros de cada técnica que se adequasse a um melhor desempenho estatístico. No caso da técnica MLP, foi verificado que após diversos ensaios realizados, a minimização de erros mostrou-se mais eficiente com 25 neurônios (25 N). Para o modelo ANFIS, o *radii* igual a 0.5 mostrou-se mais adequado à geração de modelos com a utilização de função do tipo gaussiana e número de épocas fixado em 200 interações. No modelo GRNN o valor do parâmetro *spread* mais adequado obtido foi de 0.05. E em SVM os parâmetros de ajuste (C, γ e ϵ) da configuração básica do algoritmo SMO resultaram nos seguintes resultados: C = {500}, γ = {0.02} e ϵ = {0.001}.

Para avaliação do desempenho dos modelos *Machine Learning* para ETo, comparou-se os valores previstos destes modelos com as medidas da evapotranspiração de referência da FAO (ETo_{FAO-56}), foram utilizados em conjunto os seguintes indicadores estatísticos: coeficiente de determinação (R²), coeficiente de correlação (r), *Mean Bias Error* (MBE) e *Root Mean Square Error* (RMSE).

3. RESULTADOS

3.1. Análise exploratória dos dados climáticos

Estatísticas descritivas são apresentadas na Tabela 2 e apresentam a média, desvio padrão (SD), mínimo (min), máximo (Max) e coeficiente de variação (CV) dos dados, após a imputação dos dados faltantes pela PCA, das variáveis meteorológicas: temperatura máxima (Tmax), temperatura mínima (Tmin), irradiação solar global no topo da atmosfera (Ho), irradiação solar global (H), umidade relativa (UR) e velocidade do vento (U₂).

Tabela 2. Estatística descritiva da base dados climáticos.
Table 2. Descriptive statistics of the climatic data base.

Variáveis climáticas	Média	SD	Min	Max	CV
Tmax	30,42	3,82	10,40	43,90	12,56
Tmin	17,60	3,82	-1,00	30,20	21,69
Ho	33,82	6,01	23,69	41,26	17,76
H	17,42	5,62	0,00	35,51	32,29
UR	67,36	11,17	19,00	100,00	16,59
U ₂	1,42	0,64	0,00	9,07	45,37

Média, SD=desvio padrão, Min=valor mínimo, Max=valor máximo e CV=coeficiente de variação (em %). Tmax=Temperatura máxima (°C), Tmin=Temperatura mínima (°C), Ho= irradiação solar global no topo da atmosfera (MJ. m⁻² dia⁻¹), H= irradiação solar global (MJ. m⁻² dia⁻¹), UR=umidade relativa (%) e U₂= velocidade do vento (m.s⁻¹).

Analisando os resultados obtidos nesta Tabela 2, nota-se que as variáveis climáticas Ho, H e UR apresentam os maiores valores de desvio padrão (SD).

3.2. Validação dos modelos de ML

A Figura 4 (a-p) mostra a associação entre os valores estimados de ETo pelos modelos de ML (MLP, ANFIS, GRNN e SVM) com os valores de ETo_{FAO-56}, as retas obtidas por regressão linear e os coeficientes de correlação (r) para as quatro combinações. A inserção progressiva de uma nova variável climática a cada combinação modifica a estimativa de ETo, alterando as correlações e a dispersão dos valores da base de validação.

Os valores obtidos pelos indicadores estatísticos de desempenho de cada uma das quatro combinações utilizadas de variáveis de entradas para cada tipo de modelo podem ser observados na Tabela 3. Observa-se através dos indicadores estatísticos apresentados na Tabela 3 que as técnicas MLP, ANFIS e SVM proporcionaram resultados próximos entre as combinações conforme a inserção progressiva das variáveis. Exceto no caso da técnica GRNN. Os modelos de MLP possuem melhor desempenho do que os demais modelos de ML. E isso se mantém a cada inserção de uma nova variável. Entretanto, na quarta combinação, após a inserção da variável climática vento (U₂), e o modelo MLP4 (rRMSE = 0.62%) obtém desempenho estatístico um pouco superior a ANFIS4 (rRMSE = 0.75%).

A Tabela 4 mostra uma comparação do indicativo estatístico RMSE (mm dia⁻¹) obtido na validação da ETo entre os valores obtidos por PM e os estimados pelos modelos ML, específicos para a localidade estudada e suas parametrizações, com os de outros pesquisadores que divulgaram trabalhos semelhantes em outras localidades do mundo.

Tabela 3. Arquitetura e desempenho estatístico dos modelos de AM: MLP, ANFIS, GRNN e SVM.
Table 3. Architecture and statistical performance of AM models: MLP, ANFIS, GRNN and SVM.

Modelos	Arquitetura	rRMSE	RMSE	rMBE	MBE
MLP1	Tmax, Tmin, H ₀	16,64	0,73	0,19	0,01
MLP2	Tmax, Tmin, H ₀ , H	13,49	0,59	0,20	0,01
MLP3	Tmax, Tmin, H ₀ , Rn, UR	12,43	0,55	0,17	0,01
MLP4	Tmax, Tmin, H ₀ , Rn, UR, U ₂	0,62	0,03	0,00	0,00
ANFIS1	Tmax, Tmin, H ₀	16,81	0,74	0,12	0,01
ANFIS2	Tmax, Tmin, H ₀ , H	13,52	0,60	0,14	0,01
ANFIS3	Tmax, Tmin, H ₀ , Rn, UR	12,60	0,56	0,15	0,01
ANFIS4	Tmax, Tmin, H ₀ , H, UR, U ₂	0,75	0,03	0,00	0,00
GRNN1	Tmax, Tmin, H ₀	21,82	0,96	-0,13	-0,01
GRNN2	Tmax, Tmin, H ₀ , H	18,30	0,81	-0,09	0,00
GRNN3	Tmax, Tmin, H ₀ , Rn, UR	16,69	0,74	-0,12	-0,01
GRNN4	Tmax, Tmin, H ₀ , H, UR, U ₂	11,05	0,49	-0,46	-0,02
SVM1	Tmax, Tmin, H ₀	17,46	0,77	-0,42	-0,02
SVM2	Tmax, Tmin, H ₀ , H	13,83	0,61	-1,12	-0,05
SVM3	Tmax, Tmin, H ₀ , Rn, UR	12,89	0,57	-0,99	-0,04
SVM4	Tmax, Tmin, H ₀ , Rn, UR, U ₂	1,19	0,05	0,07	0,00

rRMSE=Raiz do Erro Quadrático Médio Relativo (%), RMSE = Raiz do Erro Quadrático Médio (mm dia⁻¹), rMBE = Erro Médio por Viés Relativo (%), MBE = Erro Médio por Viés (mm dia⁻¹). Tmax=Temp. máx., Tmin=Temp. mín., H₀=irradiação solar global no topo da atmosfera, H=irradiação solar global, UR=umidade relativa e U₂=veloc. do vento.

Tabela 4. Indicativo estatístico para técnicas de ML na região de estudo e em outras localidades do mundo.
Table 4. Statistical indicator for ML techniques in the study region and elsewhere in the world.

Autores	Modelo	Local	RMSE (mm dia ⁻¹)
Kisi (2007)	MLP	3 (Estados Unidos)	0,17 - 0,57
Kisi e Ozturk (2007)	MLP	3 (Estados Unidos)	0,31 - 0,35
Zanetti et al. (2007) ^{1,3}	MLP	2 (Brasil)	0,59 - 0,79
Landeras et al. (2008)	MLP	4 (Espanha)	0,24 - 0,53
Martí e Gasque (2010)	MLP	30 (Espanha)	0,32 - 0,66
Traore et al. (2010)	MLP	Bobo Diulasso (Burkina Faso)	0,05 - 0,44
Cobaner (2011)	MLP	Santa Mônica (Estados Unidos)	0,45 - 1,36
Martí e Gonzáles-Altozano (2011)	MLP	30 (Espanha)	0,34 - 0,68
Adeloye et al. (2012)	MLP	Edimburgo (Escócia)	0,00 - 0,03
Huo et al. (2012)	MLP	3 (China)	0,07 - 0,65
Laaboudi et al. (2012)	MLP	Adrar (Argélia)	0,27
Mallikarjuna et al. (2013)	MLP	5 (Índia)	0,18 - 0,27
Adamala et al. (2014)	MLP	17 (Índia)	0,07 - 0,30
Deo e Sahin (2015)	MLP	8 (Austrália)	0,07
Kisi e Demir (2016)	MLP	Antália (Turquia)	0,07 - 0,51
Yassin et al. (2016)	MLP	19 (Arábia Saudita)	0,21 - 3,19
Landeras et al. (2017)	MLP	4 (Gana)	0,49 - 0,84
Tangune e Escobedo (2018) ³	MLP	22 (Brasil)	0,07 - 0,77
Presente estudo	MLP4	Região de estudo	0,03
Kisi e Ozturk (2007)	ANFIS	2 (Estados Unidos)	0,20 - 0,26
Cobaner (2011)	ANFIS	Santa Mônica (Estados Unidos)	0,16 - 1,33
Shiri et al. (2012)	ANFIS	4 (Espanha)	0,32 - 1,07
Tabari et al. (2012)	ANFIS	Hamedan (Irã)	0,06 - 0,08
Ladlani et al. (2014)	ANFIS	Dar el Beida (Argélia)	0,45 - 0,85
Shiri et al. (2014)	ANFIS	29 (Irã)	0,56 - 0,59
Petkovic et al. (2015)	ANFIS	12 (Sérvia)	0,26 - 0,44
Presente estudo	ANFIS4	Região de estudo	0,03
Kisi (2006)	GRNN	2 (Estados Unidos)	0,24 - 0,41
Ladlani et al. (2012)	GRNN	Dar el Beida (Argélia)	0,52 - 0,90
Feng et al. (2017)	GRNN	2 (China)	0,08 - 0,38
Presente estudo	GRNN4	Região de estudo	0,49
Kisi e Çimen (2009)	SVM	3 (Estados Unidos)	0,11 - 0,54
Tabari et al. (2012)	SVM	Hamedan (Irã)	0,02 - 0,07
Shiri et al. (2014)	SVM	29 (Irã)	0,53 - 0,61
Gocic et al. (2015)	SVM	12 (Sérvia)	0,23 - 0,30
Manikumari e Vinodhini (2016)	SVM	Annamalai Nagar (Índia)	0,19
Tangune e Escobedo (2018) ³	SVM	22 (Brasil)	0,05 - 0,85
Wen et al. (2015)	SVM	Ejina (China)	0,26 - 0,54
Karimi et al. (2017)	SVM	8 (Coréia do Sul)	0,29 - 0,50
Fan et al. (2018)	SVM	8 (China)	0,11 - 0,87
Althoff et al. (2018) ¹	SVM	5 (Brasil)	0,29 - 0,92
Presente estudo	SVM4	Região de estudo	0,05

Estados brasileiros: 1Minas Gerais, 2Rio de Janeiro e 3São Paulo no Brasil. Local = número de estações e localidade, RMSE = Raiz do Erro Quadrático Médio (mm dia⁻¹).

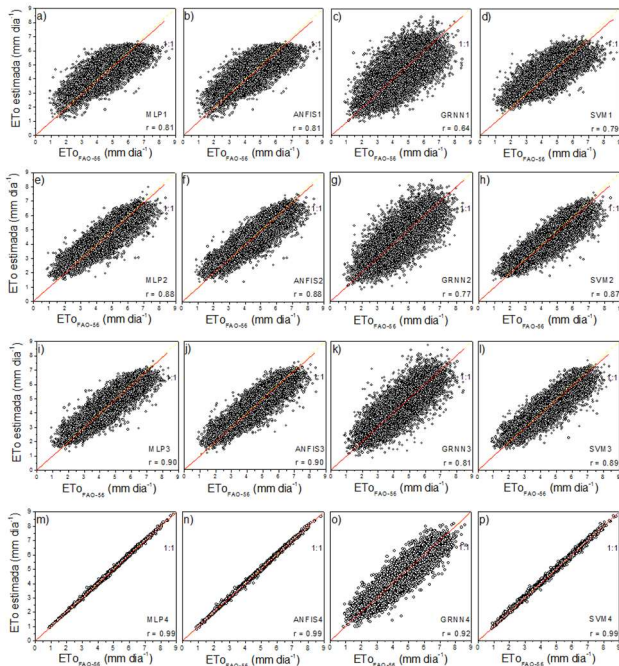


Figura 4 (a - p). Correlações entre os valores estimados de Eto pelos modelos de ML e os valores de EToFAO-56. Modelos: a) MLP1, b) ANFIS1, c) GRNN1, d) SVM1, e) MLP2, f) ANFIS2, g) GRNN2, h) SVM2, i) MLP3, j) ANFIS3, k) GRNN3, l) SVM3, m) MLP4, n) ANFIS4, o) GRNN4, p) SVM4.

Figure 4 (a - p). Correlations between the estimated values of Eto by the ML models and the values of EToFAO-56. Models: a) MLP1, b) ANFIS1, c) GRNN1, d) SVM1, e) MLP2, f) ANFIS2, g) GRNN2, h) SVM2, i) MLP3, j) ANFIS3, k) GRNN3, l) SVM3, m) MLP4, n) ANFIS4, o) GRNN4, p) SVM4.

4. DISCUSSÃO

Ao utilizar os modelos de ML, a introdução de variáveis melhora o desempenho com ganho nos valores do coeficiente de correção r (Figura 4) e aumento no intervalo de variação dos modelos da quarta combinação em relação às combinações anteriores e as correlações apresentam retas cada vez mais próximas da reta ideal (1:1). O coeficiente de correlação entre as estimativas do modelo ANFIS4 ($r = 0,99$) e EToFAO-56 é similar aos valores obtidos por Tabari et al. (2012), com intervalo de variação de $r = 0,98$ a $0,99$ e superior aos valores obtidos por Shiri et al. (2012), com intervalo de variação de $r = 0,92$ a $0,98$.

O coeficiente de correlação para SVM4 ($r = 0,99$) é igual ao obtido por Manikumari; Vinodhini (2016) e similar aos valores obtidos por vários autores, como Kisi; Çimen (2009) com intervalo de variação de $0,97$ a $0,99$; Tabari et al. (2012) com intervalo de variação $0,97$ a $0,99$; Gocic et al. (2015) com intervalo de variação de $0,98$ a $0,99$; Tangune; Escobedo (2018) com intervalo de variação de $r = 0,73$ a $0,99$; e superior aos obtidos por Wen et al. (2015) com intervalo de variação de $r = 0,77$ a $0,99$.

O valor de RMSE para MLP4 obtido neste trabalho (Tabela 4) é similar e está no mesmo intervalo de variação dos valores obtidos em Edimburgo (Escócia), no Estado de São Paulo (Brasil) e inferior aos resultados obtidos nos Estados Unidos, nos Estados de Minas Gerais e Rio de Janeiro (Brasil), na comunidade autônoma do País Basco (Espanha), na comunidade autônoma de Valência (Espanha), em Bobo Diulasso (Burkina Faso), em Santa Mônica (Estados Unidos), na China, em Adrar (Argélia), na Índia, na

Austrália, em Antália (Turquia), na Arábia Saudita, e em Gana.

O valor de RMSE para ANFIS4 é inferior aos resultados obtidos nos Estados Unidos, em Santa Mônica (Estados Unidos), na Espanha, em Hamedã (Irã), Dar el Beida (Argélia) e no Irã, na Sérvia. O valor de RMSE para GRNN4 é inferior aos resultados obtidos em Dar el Beida (Argélia) e superior aos resultados obtidos nos Estados Unidos e na China. O valor de RMSE para SVM4 é similar e está no mesmo intervalo de variação dos valores obtidos em Hamadã (Irã), no Estado de São Paulo (Brasil); e inferior aos valores obtidos nos Estados Unidos, no Irã, em Annamalai Nagar (Índia), em Ejina (China), na Coréia do Sul, na China - e no Estado de Minas Gerais (Brasil).

Deve-se ressaltar que os valores dos indicativos encontrados são para os arranjos propostos, mas outros devem ser testados. Assim como suas parametrizações a fim de verificar a eficiência dos modelos e da importância das variáveis inseridas nas combinações. E avaliando se estas realmente são impactantes para melhoria dos indicadores estatísticos e se são mais significativas. Por fim, dos resultados apresentados, a técnica do tipo MLP é a mais indicada para a estimativa de ETo com as combinações e parametrizações propostas.

Adamala (2014) e Pandorfi et al. (2016) também relatam o bom desempenho da técnica de AM na modelagem de evapotranspiração oriundo de medidas lisimétricas e indica que esta técnica poderia modelar a evapotranspiração melhor que o modelo proposto pela FAO.

De acordo com Althoff et al. (2018), é necessário ter um banco de dados completo (T_{max} , T_{min} , H_o , H , UR e U_2) para uma estimativa precisa de ETo. No entanto, os resultados obtidos com o uso de menos variáveis climáticas indicaram alta capacidade de generalização dos modelos de ML apresentados, sendo viável sua utilização em regiões que carecem de conjuntos de dados meteorológicos, ou mesmo possuem apenas alguns anos de dados. Além disso, a robustez dos métodos de aprendizado de máquina também foi constatada uma vez que o desempenho da validação apresentou métricas melhores do que as equações convencionais difundidas na literatura, como as equações de Priestley-Taylor e Thornthwaite.

Neste trabalho, inferimos que o modelo MLP4 apresentou os melhores resultados pelo fato do modelo ser formado por uma rede neural com camadas ocultas com número indeterminado de neurônios. Tal camada tem tal denominação em virtude da impossibilidade de previsão da saída desejada nas camadas intermediárias. Sendo assim, esta gama de possibilidades pode vir a fazer o modelo ser mais adaptativo que os demais em comparação. Vale ressaltar também que a maioria dos modelos aqui apresentados exigem um grau de complexidade computacional considerável. Todavia, a velocidade de cálculo das máquinas hoje existentes faz com que, nos modelos aqui considerados, não haja uma diferença relevante em tais tempos de processamento computacional.

Sendo assim, o fator primordial que se considerou neste trabalho foram índices praticados amplamente na literatura ($rRMSE$, $RMSE$, $rMBE$, MBE), o que estabelece um método confiável de otimização em busca do melhor modelo. Adicionalmente, uma vez implementados os algoritmos dos modelos aqui estabelecidos, a dificuldade de aplicação dos métodos é muito semelhante, o que novamente, reforça a

adequada estratégia de escolha do método Multilayer Perceptron por apresentar melhor desempenho nos índices estatísticos de erro.

Por fim, ressalta-se a metodologia de estudo utilizando diversas propostas de modelos, o que pode vir a ser uma excelente proposta de análise de dados para quaisquer outros locais de estudo.

5. CONCLUSÕES

Os modelos MLP, ANFIS, GRNN e SVM corroboraram resultados já observados sobre a eficiência dessas técnicas em estimar ETo. Na comparação do desempenho estatístico entre as técnicas utilizadas neste estudo verificou-se melhor desempenho estatístico para EToMLP4 (rRMSE = 0.62%), seguidos por EToANFIS4 (rRMSE = 0.75%), EToSVM4 (rRMSE = 1.19%) e EToGRNN4 (rRMSE = 11.05%). Os valores dos indicadores estatísticos da base de validação de MLP4, ANFIS4 e SVM4 mostram que estes modelos são aptos à estimativa da evapotranspiração de referência com destaque para a técnica MLP.

6. AGRADECIMENTOS

Os autores agradecem a Universidade Estadual Paulista (UNESP) pela concessão do estágio de pós-doutorado ao primeiro autor (Processo 3127/2020); e agradecem o financiamento do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de produtividade em pesquisa concedida (Processo nº 315228/2020-2 (LRAGF)).

7. REFERÊNCIAS

ADAMALA, S.; RAGHUWANSHI, N. S.; MISHRA, A. Evapotranspiration modeling using second-order neural networks. **Journal of Hydrologic Engineering**, v. 19, p. 1131-1140, 2014. [http://dx.doi.org/10.1061/\(ASCE\)HE.1943-5584.0000887](http://dx.doi.org/10.1061/(ASCE)HE.1943-5584.0000887)

ADELOYE, A. J.; RUSTUM, R.; KARIYAMA, I. D. Neural computing modeling of the reference crop evapotranspiration. **Environmental Modelling e Software**, v. 29, p. 61-73, 2012. <http://doi.org/10.1016/j.envsoft.2011.10.012>

ALLEN, R. G.; PEREIRA, L. S.; RAES, D. et al. **Crop evapotranspiration - guidelines for computing crop water requirements**. Rome: Food and Agriculture Organization of the United Nations (FAO), 1998. 50p. (Irrigation and drainage, paper 56)

ALLEN, R. G.; PRUITT, W. O. FAO-24 reference evapotranspiration factors. **Journal of Irrigation and Drainage Engineering**, v. 175, n. 5, p. 758-773, 1991. [http://doi.org/10.1061/\(ASCE\)0733-9437\(1991\)117:5\(758\)](http://doi.org/10.1061/(ASCE)0733-9437(1991)117:5(758))

ALTHOFF, D.; BAZAME, H. C.; FILGUEIRAS, R.; DIAS, S. H. B. Heuristic methods applied in reference evapotranspiration modeling. **Ciência e Agrotecnologia**, v. 42, n. 3, p. 314-324, 2018. <http://doi.org/10.1590/1413-70542018423006818>

BENEVIDES, J. G.; LOPEZ, D. Formula para el caculo de la evapotranspiracion potencial adaptada al tropico (15° N - 15° S). **Agronomia Tropical**, v. 20, n. 5, p. 335-345, 1970.

BLANEY, H. F.; CRIDDLE, W. D. Determining Water Requirements in Irrigated Areas from Climatological and Irrigation Data. **USDA**. SCSTP-96, 1950. 48P.

BOSO, A. C. M. R.; CREMASCO, C. P.; PUTTI, F. F.; GABRIEL FILHO, L. R. A. Fuzzy modeling of the effects of different irrigation depths on the radish crop. Part I: Productivity analysis. **Engenharia Agrícola**, v. 41, n. 3, p. 311-318, 2021a. <http://doi.org/10.1590/1809-4430-Eng.Agric.v41n3p311-318/2021>

BOSO, A. C. M. R.; CREMASCO, C. P.; PUTTI, F. F.; GABRIEL FILHO, L. R. A. Fuzzy modeling of the effects of different irrigation depths on the radish crop. Part II: Biometric variables analysis. **Engenharia Agrícola**, v. 41, n. 3, p. 319-329, 2021b. <http://doi.org/10.1590/1809-4430-Eng.Agric.v41n3p319-329/2021>

CASTRO, E. R.; SAAD, J. C. C.; GABRIEL FILHO, L. R. A. Artificial intelligence techniques applied to the optimization of micro-irrigation systems by the Zimmermann-Werner method. **Engenharia Agrícola**, v. 42, n. esp, e20210118, 2022. <http://doi.org/10.1590/1809-4430-Eng.Agric.v42nepe20210118/2022>

CHEN, J-L.; LI, G-S.; XIAO, B. B. Assessing the transferability of support vector machine model for estimation of global solar radiation from air temperature. **Energy Conversion and Management**, v. 89, p. 318-329, 2015. <http://dx.doi.org/10.1016/j.enconman.2014.10.004>

COBANER, M. Evapotranspiration estimation by two different neuro-fuzzy inference systems. **Journal of Hydrology**, v. 398, p. 292-302, 2011. <http://dx.doi.org/10.1016/j.jhydrol.2010.12.030>

CREMASCO, C. P.; GABRIEL FILHO, L. R. A.; CATANEO, A. Methodology for determination of fuzzy controller pertinence functions for the energy evaluation of poultry industry companies. **Energia na Agricultura**, v. 25, n. 1, p. 21-39, 2010. <http://doi.org/10.17224/EnergAgric.2010v25n1p21-39>

DEO, R. C.; SAHIN, M. Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia. **Atmospheric Research**, v. 161-162, p. 65-81, 2015. 10.1016/j.atmosres.2015.03.018

FAN, J.; YUE, W.; WU, L.; ZHANG, F.; CAI, H.; WANG, X.; LU, X.; XIANG, Y. Evaluation of SVM, ELM and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of China. **Agricultural and Forest Meteorology**, v. 263, p. 225-241, 2018. 10.1016/j.agrformet.2018.08.019

FENG, Y.; CUI, N.; GONG, D.; ZHANG, Q.; ZHAO, L. Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. **Agricultural Water Management**, v. 193, p. 163-173, 2017. <http://doi.org/10.1016/j.agwat.2017.08.003>

FERREIRA SILVA, C. O.; MANZIONE, R. L.; ALBUQUERQUE FILHO, J. L. Large-Scale spatial modeling of crop coefficient and biomass production in agroecosystems in Southeast Brazil. **Horticulturae**, v. 4, n. 4, e44, 2018. <http://doi.org/10.3390/horticulturae4040044>

GABRIEL FILHO, L. R. A.; CREMASCO, C. P.; PUTTI, F. F.; CHACUR, M. G. M. Application of fuzzy logic for the evaluation of livestock slaughtering. **Engenharia**

- Agrícola**, v. 31, n. 4, p. 813-825, 2011. <http://doi.org/10.1590/S0100-69162011000400019>
- GABRIEL FILHO, L. R. A.; PIGATTO, G. A. S.; LOURENZANI, A. E. B. S. Fuzzy rule-based system for evaluation of uncertainty in cassava chain. **Engenharia Agrícola**, v. 35, n. 2, p. 350-367, 2015. <http://doi.org/10.1590/1809-4430-Eng.Agric.v35n2p350-367/2015>
- GABRIEL FILHO, L. R. A.; PUTTI, F. F.; CREMASCO, C. P.; BORDIN, D.; CHACUR, M. G. M.; GABRIEL, L. R. A. Software to assess beef cattle body mass through the fuzzy body mass index. **Engenharia Agrícola**, v. 36, n. 1, p. 179-193, 2016. <http://doi.org/10.1590/1809-4430-Eng.Agric.v36n1p179-193/2016>
- GABRIEL FILHO, L. R. A.; SILVA JUNIOR, J. F.; CREMASCO, C. P.; SOUZA, A. V.; PUTTI, F. F. Fuzzy modeling of salinity effects on pumpkin (*Cucurbita pepo*) development. **Engenharia Agrícola**, v. 42, n. 1, p. e20200150, 2022a. <http://doi.org/10.1590/1809-4430-Eng.Agric.v42n1e20200150/2022>
- GABRIEL FILHO, L. R. A.; SILVA, A. O.; PUTTI, F. F.; CREMASCO, C. P. Fuzzy modeling of the effect of irrigation depths on beet cultivars. **Engenharia Agrícola**, v. 42, n. 1, p. e20210084, 2022b. <http://doi.org/10.1590/1809-4430-Eng.Agric.v42n1e20210084/2022>
- GOCIC, M.; MOTAMEDI, S. SHAMSHIRBAND, S.; PETKOVIĆ, D.; CH, S.; HASHIM, R.; ARIF, M. Soft computing approaches for forecasting reference evapotranspiration. **Computers and Electronics in Agriculture**, v. 113, p. 164-173, 2015. <http://doi.org/10.1016/j.compag.2015.02.010>
- GÓES, B. C.; GOES, R. J.; CREMASCO, C. P.; GABRIEL FILHO, L. R. A. Fuzzy modeling of vegetable straw cover crop productivity at different nitrogen doses. **Modeling Earth Systems and Environment**, v. 8, p. 939-945, 2022. <http://doi.org/10.1007/s40808-021-01125-4>
- HARGREAVES, G. H.; SAMANI, Z. A. Reference crop evapotranspiration from temperature. **Applied Engineering in Agriculture**, v. 1, n. 2, p. 96-99, 1985.
- HAYKIN, S. **Neural networks: A comprehensive foundation**. 2nd ed. Hamilton: Prentice Hall, 1998. 897p.
- HUO, Z.; FENG, S.; KANG, S.; DAI, X. Artificial neural network models for reference evapotranspiration in an arid area of northwest China. **Journal of Arid Environments**, v. 82, p. 81-90, 2012. <http://dx.doi.org/10.21162/PAKJAS/16.3179>
- IBGE, **Instituto Brasileiro de Geografia e Estatística**. <<http://www.ibge.gov.br/>>. Acessado em 2022.
- IQBAL, M. **An introduction to solar radiation**. New York: Academic Press, 1983. 390p.
- JANG, J. S. ANFIS: Adaptive network based fuzzy inference system. **IEEE Transactions on systems, man, and cybernetics**, v. 23, n. 3, p. 665-685, 1993. <http://doi.org/10.1109/21.256541>
- JENSEN, M. E.; HAISE, H. R. Estimating evapotranspiration from solar radiation. **Proceeding of the Journal of Irrigation and Drainage Division: American Society of Civil Engineers**, v. 89, n. 1, p. 15-41, 1963.
- JOSSE, J.; HUSSON, F. Handling missing values in exploratory multivariate data analysis methods. **Journal de la Société Française de Statistique**, v. 153, n. 2, p. 79-99, 2012.
- JOSSE, J.; HUSSON, F. missMDA: A Package for handling missing values in multivariate data analysis. **Journal of Statistical Software**, v. 70, p. 1-31, 2016. <http://doi.org/10.18637/jss.v070.i01>
- JOSSE, J.; HUSSON, F.; PAGÈS, J. Gestion des données manquantes en Analyse en Composantes Principales. **Journal de la Société Française de Statistique**, v. 150, n. 2, p. 28-51, 2009.
- KARIMI, S.; KISI, O.; KIM, S.; NAZEMI, A. H.; SHIRI, J. Modelling daily reference evapotranspiration in humid locations of South Korea using local and cross-station data management scenarios. **International Journal of Climatology**, v. 37, p. 3228-3246, 2017. <http://doi.org/10.1002/joc.4911>
- KHATIB, T.; ELMENREICH, W. A Model for hourly solar radiation data generation from daily solar radiation data using a generalized regression artificial neural network. **International Journal of Photoenergy**, v. 2015, p. 1-13, 2015. <http://doi.org/10.1155/2015/968024>
- KISI, O. Evapotranspiration modelling from climatic data using a neural computing technique. **Hydrological Processes**, v. 21, p. 1925-1934, 2007. <http://doi.org/10.1002/hyp.7062>
- KISI, O. Generalized regression neural networks for evapotranspiration modelling. **Hydrological Sciences Journal**, v. 51, p. 1092-1105, 2006. <http://doi.org/10.1623/hysj.51.6.1092>
- KISI, O.; OZTURK, O. Adaptive Neurofuzzy computing technique for evapotranspiration estimation. **Journal of Irrigation and Drainage Engineering**, v. 133, n. 4, p. 368-379, 2007. [http://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(368\)](http://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(368))
- KISI, O.; CIMEN, M. Evapotranspiration modelling using support vector machines. **Hydrological Sciences—Journal—des Sciences Hydrologiques**, v. 54, n. 5, p. 918-928, 2009. <http://doi.org/10.1623/hysj.54.5.918>
- KISI, O.; DEMIR, V. Evapotranspiration estimation using six different multi-layer Perceptron Algorithms. **Irrigation e Drainage Systems Engineering**, v. 5, n. 2, p. 1-6, 2016. [10.4172/2168-9768.1000164](http://doi.org/10.4172/2168-9768.1000164)
- KÖPPEN, W.; GEIGER, R. **Klimate der Erde**. Gotha: Verlag Justus Perthes. **Wall-map 150cmx200cm**, 1928.
- KUMAR, M.; RAGHUWANSHI, N. S.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: a review. **Irrigation Science**, v. 29, n. 4, p. 11-25, 2011. <http://doi.org/10.1007/s00271-010-0230-8>
- LAABOUDI, A.; MOUHOUCHE, B. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. **International Journal of Biometeorology**, v. 56, p. 831-841, 2012. <http://doi.org/10.1007/s00484-011-0485-7>
- LADLANI, I.; HOUICHI, L.; DJEMILI, L.; et al. Modeling daily reference evapotranspiration (ET_o) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. **Meteorology and Atmospheric Physics**, v. 118, pp. 163-178, 2012. [10.1007/s00703-012-0205-9](http://doi.org/10.1007/s00703-012-0205-9)

- LADLANI, I.; HOUICHI, L.; DJEMILI, L.; HEDDAM, S.; BELOUZ, K. Estimation of daily reference evapotranspiration (Eto) in the north of Algeria using adaptive neuro-Fuzzy Inference System (ANFIS) and Multiple Linear Regression (MLR) Models: A Comparative Study. **Arabian Journal for Science and Engineering**, v. 118, n. 3-4, p. 163-178, 2012. [10.1007/s00703-012-0205-9](https://doi.org/10.1007/s00703-012-0205-9)
- LAM, J. C.; WAN, K. K. W.; YANG, L. Solar radiation modeling using ANNs for different climates in China. **Energy Conversion Management**, v. 49, p. 1080-1090, 2008. <http://dx.doi.org/10.1016/j.enconman.2007.09.021>
- LANDERAS, G.; BEKOE, E.; AMPOFO, J.; LOGAH, F.; DIOP, M.; CISSE, M.; SHIRI, J. New alternatives for reference evapotranspiration estimation in West Africa using limited weather data and ancillary data supply strategies. **Theoretical and Applied Climatology**, v. 132, p. 701-716, 2018. <http://doi.org/10.1007/s00704-017-2120-y>
- 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. <http://dx.doi.org/10.1016/j.agwat.2007.12.011>
- LORENA, A. C.; JACINTHO, L. F. O.; SIQUEIRA, M. F.; De GIOVANNI, R.; LOHMANN, L. G.; CARVALHO, A. C. P. L. F.; YAMAMOTO, M. Comparing machine learning classifiers in potential distribution modelling. **Expert Systems with Applications**, v. 38, p. 5268-5275, 2011. <http://doi.org/10.1016/j.eswa.2010.10.031>
- MAKKINK, G. F. Testing the Penman formula by means of lysimeters. **Journal of the Institution of Water Engineers**, v. 11, n. 3, p. 277-288, 1957.
- MALLIKARJUNA, P.; JYOTHY, S. A.; REDDY, K. C. S. Daily reference evapotranspiration estimation using linear regression and ANN Models. **Journal of The Institution of Engineers**, v. 97, n. 4, p. 215-221, 2013. [10.1007/s40030-013-0030-2](https://doi.org/10.1007/s40030-013-0030-2)
- MANIKUMARI, N.; VINODHINI, G. Regression Models for Predicting Reference Evapotranspiration. **International Journal of Engineering Trends and Technology**, v. 38, n. 3, p. 134-139, 2016. <http://doi.org/10.14445/22315381/IJETT-V38P224>
- MARTÍ, P.; GASQUE, M. Ancillary data supply strategies for improvement of temperaturebased ETo ANN models. **Agricultural Water Management**, v. 97, p. 939-955, 2010. <http://doi.org/10.1016/j.agwat.2010.02.002>
- MARTÍ, P.; GONZÁLEZ-ALTOZANO, M. Reference evapotranspiration estimation without local climatic data. **Irrigation Science**, v. 29, p. 479-495, 2011. <http://doi.org/10.1007/s00271-010-0243-3>
- MARTÍNEZ, M. P.; CREMASCO, C. P.; GABRIEL FILHO, L. R. A.; BRAGA JUNIOR, S. S.; BEDNASKI, A. V.; QUEVEDO-SILVA, F.; CORREA, C. M.; SILVA, D.; PADGETT, R. C. M. L. Fuzzy inference system to study the behavior of the green consumer facing the perception of greenwashing. **Journal of Cleaner Production**, v. 242, p. e116064, 2020. <http://doi.org/10.1016/j.jclepro.2019.03.060>
- MATULOVIC, M.; PUTTI, F. F.; CREMASCO, C. P.; GABRIEL FILHO, L. R. A. Technology 4.0 with 0.0 costs: fuzzy model of lettuce productivity with magnetized water. **Acta Scientiarum Agronomy**, v. 43, n. 1, p. e51384, 2021. <http://doi.org/10.4025/actasciagron.v43i1.51384>
- MAZIERO, L. P.; CHACUR, M. G. M.; CREMASCO, C. P.; PUTTI, F. F.; GABRIEL FILHO, L. R. A. Fuzzy system for assessing bovine fertility according to semen characteristics. **Livestock Science**, v. 256, p. e104821, 2022. <http://doi.org/10.1016/j.livsci.2022.104821>
- ORACLE CORPORATION. **Chapter 1 General Information. MySQL 5.7 Reference Manual**. 2019. Disponível em: <http://dev.mysql.com/doc/refman/5.7/en/introduction.html>. Acesso em: 08 abr. 2019.
- PANDORFI, H.; BEZERRA, A. C.; ATARASSI, R. T.; VIEIRA, F. M. C.; BARBOSA FILHO, J. A. D.; GUISELINI, C. Artificial neural networks employment in the prediction of evapotranspiration of greenhouse-grown sweet pepper. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 6, p. 507-512, 2016. <http://doi.org/10.1590/1807-1929/agriambi.v20n6p507-512>
- PENMAN, H. L. Natural evaporation from open water, bare soil, and grass. **Proceedings of the Royal Society**, v. 193, n. 1, p. 120-146, 1948. <http://doi.org/10.1098/rspa.1948.0037>
- PEREIRA, D. F.; BIGHI, C. A.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P. C. Sistema fuzzy para estimativa do bem-estar de matrizes pesadas. **Engenharia Agrícola**, v. 28, n. 4, p. 624-633, 2008. <http://doi.org/10.1590/S0100-69162008000400002>
- PETKOVIC, D.; GOCIC, M.; TRAJKOVIC, S.; SHAMSHIRBAND, S.; MOTAMEDI, S.; HASHIM, R.; BONAKDARI, H. Determination of the most influential weather parameters on reference evapotranspiration by adaptive neuro-fuzzy methodology. **Computers and Electronics in Agriculture**, v. 114, p. 277-284, 2015. <http://doi.org/10.1016/j.compag.2015.04.012>
- 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. [http://doi.org/10.1175/1520-0493\(1972\)100<0081:OTAOSH>2.3.CO;2](http://doi.org/10.1175/1520-0493(1972)100<0081:OTAOSH>2.3.CO;2)
- PUTTI, F. F.; CREMASCO, C. P.; SILVA JUNIOR, J. F.; GABRIEL FILHO, L. R. A. Fuzzy modeling of salinity effects on radish yield under reuse water irrigation. **Engenharia Agrícola**, v. 42, n. 1, p. e215144, 2022. <http://doi.org/10.1590/1809-4430-Eng.Agric.v42n1e215144/2022>
- PUTTI, F. F.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P.; BONINI NETO, A.; BONINI, C. S. B.; REIS, A. R. A Fuzzy mathematical model to estimate the effects of global warming on the vitality of *Laelia purpurata* orchids. **Mathematical Biosciences**, v. 288, p. 124-129, 2017. <http://doi.org/10.1016/j.mbs.2017.03.005>
- PUTTI, F. F.; GABRIEL FILHO, L. R. A.; SILVA, A. O.; LUDWIG, R.; CREMASCO, C. P. Fuzzy logic to evaluate vitality of *Catasetum fimbriatum* species (Orchidaceae). **Irriga**, v. 19, n. 3, p. 405-413, 2014. <http://doi.org/10.15809/irriga.2014v19n3p405>

- PUTTI, F. F.; KUMMER, A. C. B.; GRASSI FILHO, H.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P. Fuzzy modeling on wheat productivity under different doses of sludge and sewage effluent. **Engenharia Agrícola**, v. 37, n. 6, p. 1103-1115, 2017. <http://doi.org/10.1590/1809-4430-eng.agric.v37n6p1103-1115/2017>
- PUTTI, F. F.; LANZA, M. H.; GRASSI FILHO, H.; CREMASCO, C. P.; SOUZA, A. V.; GABRIEL FILHO, L. R. A. Fuzzy modeling in orange production under different doses of sewage sludge and wastewater. **Engenharia Agrícola**, v. 41, n. 2, p. 204-214, 2021. <http://doi.org/10.1590/1809-4430-eng.agric.v41n2p204-214/2021>
- R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria. URL <http://www.R-project.org/2018>.
- SENTELHAS, P. C.; GILLESPIE, T. J.; SANTOS, E. A. Evaluation of FAO Penman-Monteith and alternative methods for estimating reference evapotranspiration with missing data in Southern Ontario, Canada. **Agricultural Water Management**, v. 97, p. 635-644, 2010. <http://doi.org/10.1016/j.agwat.2009.12.001>
- SHIRI, J.; KISI, O.; LANDERAS, G. et al. Daily reference evapotranspiration modeling by using genetic programming approach in the Basque Country (Northern Spain). **Journal of Hydrology**, v. 414-415, p. 302-316, 2012. <http://doi.org/10.1016/j.jhydrol.2011.11.004>
- 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. <http://doi.org/10.1016/j.compag.2014.08.007>
- SILVA, M. B. P.; ESCOBEDO, J. F.; ROSSI, T. J.; SANTOS, C. M.; SILVA, S. H. M. G. Performance of the Angstrom-Prescott Model (A-P) and SVM and ANN techniques to estimate the daily global solar irradiation in Botucatu/SP/Brazil. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 160, p. 11-23, 2017. <http://doi.org/10.1016/j.jastp.2017.04.001>
- SMOLA, A. J.; SCHÖLKOPF, B. "A tutorial on support vector regression". **Royal Holloway College, London**, U. K., Neuro COLT Tech. Rep. TR 1998-030, 1998.
- SNYDER, R. Climate change impacts on water use in horticulture. **Horticulturae**, v. 3, n. 27, p. 1-9, 2017. <http://doi.org/10.3390/horticulturae3020027>
- SNYDER, R. L. Equation for evaporation pan to evapotranspiration conversions. **Journal of Irrigation and Drainage Engineering**, v. 118, n. 6, p. 977-980, 1992. [http://doi.org/10.1061/\(ASCE\)0733-9437\(1992\)118:6\(977\)](http://doi.org/10.1061/(ASCE)0733-9437(1992)118:6(977))
- TABARI, H.; KISI, O.; EZANI, A.; TALAEI, P. H. SVM, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. **Journal of Hydrology**, v. 444-445, p. 78-89, 2012. <http://dx.doi.org/10.1016/j.jhydrol.2012.04.007>
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions System, Man, Cybernetics**, v. 15, p. 116-132, 1985. <http://doi.org/10.1109/TSMC.1985.6313399>
- 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. <http://doi.org/10.5897/IJWREE2018.0772>
- THORNTHWAITE, C. W. An approach toward a rational classification of climate. **Geographical Review**, v. 55-94, p. 38, 1948. <http://doi.org/10.2307/210739>
- TRAORE, S.; WANG, Y.; KERH, T. Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. **Agricultural Water Management**, v. 97, p. 707-714, 2010. <http://dx.doi.org/10.1016/j.agwat.2010.01.002>
- VANDERLINDEN, K.; GIRÁLDEZ, J. V.; MEIRVENNE, M. V. Spatial Estimation of Reference Evapotranspiration in Andalusia, Spain. **Journal of Hydrometeorology**, v. 9, n. 2, p. 242-255, 2008. <http://doi.org/10.1175/2007JHM880.1>
- VAPNIK V, N. **Statistical learning theory**. New York: Wiley, 1998. 736p.
- VAPNIK, V. N. **The nature of Statistical learning theory**. New York: Springer-Verlag, 1995. 334p.
- VIAIS NETO, D. S.; CREMASCO, C. P.; BORDIN, D.; PUTTI, F. F.; SILVA JUNIOR, J. F.; GABRIEL FILHO, L. R. A. Fuzzy modeling of the effects of irrigation and water salinity in harvest point of tomato crop. Part I: description of the method. **Engenharia Agrícola**, v. 39, n. 3, p. 294-304, 2019a. <http://doi.org/10.1590/1809-4430-eng.agric.v39n3p294-304/2019>
- VIAIS NETO, D. S.; CREMASCO, C. P.; BORDIN, D.; PUTTI, F. F.; SILVA JUNIOR, J. F.; GABRIEL FILHO, L. R. A. Fuzzy modeling of the effects of irrigation and water salinity in harvest point of tomato crop. Part II: application and interpretation. **Engenharia Agrícola**, v. 39, n. 3, p. 305-314, 2019b. <http://doi.org/10.1590/1809-4430-eng.agric.v39n3p305-314/2019>
- WEN, X.; SI, J.; HE, Z.; WU, J.; SHAO, H.; YU, H. Support-Vector-Machine-Based models for modeling daily reference evapotranspiration with limited climatic data in extreme arid regions. **Water Resources Management**, v. 29, p. 3195-2309, 2015. <http://doi.org/10.1007/s11269-015-0990-2>
- YASSIN, M. A.; ALAZBA, A. A.; MATTAR, M. A. Artificial neural networks versus gene expression programming for estimating reference evapotranspiration in arid climate. **Agricultural Water Management**, v. 163, p. 110-124, 2016. <http://doi.org/10.1016/j.agwat.2015.09.009>
- ZADEH, L. A. Fuzzy algorithms. **Information and Control**, v. 12, p. 94-102, 1968. [http://doi.org/10.1016/S0019-9958\(68\)90211-8](http://doi.org/10.1016/S0019-9958(68)90211-8)
- ZANETTI, S. S.; SOUSA, E. F.; OLIVEIRA, V. P.; ALMEIDA, F. T.; BERNARDO, S. Estimating evapotranspiration using artificial neural network and minimum climatological data. **Journal of Irrigation and Drainage Engineering**, v. 133, n. 2, pp. 83-89, 2007. [http://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:2\(83\)](http://doi.org/10.1061/(ASCE)0733-9437(2007)133:2(83))