

MODELAGEM *NEURO-FUZZY* DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA BASEADA NO MÉTODO DE CAMARGO

LUANA POSSARI MAZIERO¹, STEPHANIE LESCHOT FREDERICK²,
CAMILA PIRES CREMASCO², FERNANDO FERRARI PUTTI² E LUÍS ROBERTO
ALMEIDA GABRIEL FILHO³

¹*Departamento de Engenharia Rural, Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Avenida Universitária, 3780, CEP 18610-034, Altos do Paraíso, Botucatu, São Paulo, Brasil, luana.maziero@unesp.br.*

²*Departamento de Engenharia de Biosistemas, Faculdade de Ciências e Engenharia, Universidade Estadual Paulista, Rua Domingos da Costa Lopes, nº 780, Jardim Itaipu, 17602-496, Tupã, São Paulo, Brasil, s.frederick@unesp.br, camila.cremasco@unesp.br, fernando.putti@unesp.br.*

³*Departamento de Gestão, Desenvolvimento e Tecnologia, Faculdade de Ciências e Engenharia, Universidade Estadual Paulista, Rua Domingos da Costa Lopes, nº 780, Jardim Itaipu, 17602-496, Tupã, São Paulo, Brasil, gabriel.filho@unesp.br.*

1 RESUMO

O conhecimento sobre a evapotranspiração é fundamental para determinar o balanço hídrico de uma determinada região, pois pode afetar a política de gestão hídrica da bacia. Nesse contexto, o uso de modelagem matemática com abordagem difusa, como a modelagem *fuzzy*, cuja origem se deu justamente devido ao desafio de se trabalhar com incertezas, pode auxiliar na determinação da evapotranspiração, auxiliando no processo de tomada de decisão. Desta forma, no presente artigo, desenvolveu-se um modelo neuro-fuzzy (baseado em lógica *fuzzy* e redes neurais) para determinar a evapotranspiração de referência pelo método de Camargo. Definiu-se como variáveis de entrada a temperatura e radiação solar, ambas coletadas pelo Instituto Nacional de Meteorologia (INMET) na estação de Tupã, os dados foram considerados pelo período de um ano. Tal sistema, possibilita ao produtor a obtenção instantânea do valor da evapotranspiração de referência, além da classificação qualitativa em classes. A partir dos processos realizados neste trabalho, o método computacional estabelecido, mostrou-se capaz de calcular instantaneamente a evapotranspiração de referência pela equação de Camargo, a partir das variáveis radiação solar e temperatura, relatando que quanto menor os valores de temperatura e radiação solar, menor será o valor da evapotranspiração de referência.

Palavras-chave: lógica fuzzy, redes neurais, irrigação, balanço hídrico.

MAZIERO, L. P.; FREDERICK, S. L.; CREMASCO, C. P.; PUTTI, F. F.;
GABRIEL FILHO, L. R. A.

NEURO-FUZZY MODELING OF REFERENCE EVAPOTRANSPIRATION BASED
ON THE CAMARGO METHOD

2 ABSTRACT

Knowledge about evapotranspiration is essential to determine the water balance of a given region, since it can affect the basin's water management policy. In this context, the use of mathematical modeling with diffuse approach as fuzzy modeling, in which its origin was rightly due to the challenge of working with uncertainties, it can assist in the determination of evapotranspiration, helping in the decision-making process. Thus, in this article, he developed a neuro-fuzzy model (based on fuzzy logic and neural networks) to determine the reference evapotranspiration by the Camargo method. The input variables were temperature and solar radiation, both collected at the National Meteorology Institute (INMET) at the Tupã station, the data were considered for a period of one year. Such a system allows the producer to instantly obtain the reference evapotranspiration value, in addition to the qualitative classification in classes. Based on the processes conducted in this work, the established computational method could instantly calculate the reference evapotranspiration from the Camargo equation, based on solar radiation and temperature variables, reporting that the lower the values of temperature and solar radiation, the lower will be the reference evapotranspiration value.

Keywords: diffuse logic, neural networks, irrigation, water balance.

3 INTRODUÇÃO

A evapotranspiração (*ET*) é definida como o parâmetro no qual são considerados os processos simultâneos de transferência de água para a atmosfera, por meio da transpiração das plantas e evaporação da água nas superfícies (ALLEN *et al.*, 1998). Este parâmetro é comumente medido por milímetro por dia (mm/dia), sendo que um milímetro de evapotranspiração corresponde ao deslocamento de um litro de água para a atmosfera para cada metro quadrado da superfície. As taxas de *ET* são diferentes para cada tipo de ambiente, pois ela é influenciada por diversos fatores, como: tipo de folha, porcentagem de cobertura vegetal do solo, estágio de crescimento da planta, temperatura, umidade, velocidade do vento e radiação solar (ALLEN *et al.*, 1998).

Para a obtenção do balanço hídrico de uma determinada região é fundamental o conhecimento da água perdida por evapotranspiração, e para isso, o cálculo da evapotranspiração de referência (*ET_o*) é utilizado (GURSKI; JERSZURKI; SOUZA, 2018). Segundo Allen *et al.* (1998), a *ET_o* ocorre em uma superfície de referência sem

a imposição de deficiência hídrica. Devido aos custos altos dos equipamentos e a sensibilidade para a determinação da *ET_o*, muitos agricultores não tem acesso a eles e/ou acabam fazendo a gestão de seus sistemas incorretamente. Com isso, existem inúmeros métodos para determinar a *ET_o*, em que são utilizados sensores mais fáceis de manusear e métodos que demandam um número menor de variáveis, como o Método de Camargo (CAMARGO; CAMARGO, 2000).

O modelo apresentado por Camargo é uma simplificação do método de Thornthwaite, utiliza apenas dados de temperatura média e radiação solar e foi desenvolvido por meio de uma equação analítica para o cálculo da evapotranspiração, sendo aplicável a qualquer condição climática com eficiência (CAMARGO, 1971). Assim, o método começou a ser aprimorado na década de 60, período no qual substituiu o de Thornthwaite, e seu diferencial foi a substituição do índice "I" pelo "T", que corresponde à temperatura média anual da região. Além disso, Camargo elaborou uma tabela de simples entendimento para a

obtenção do valor diário da *ET_o*, não sendo necessária a correção devido à latitude com base no índice “T” como no método de Thornthwaite, o que facilitou a estimativa (CAMARGO; CAMARGO, 2000). Baseado em resultados obtidos pelo método de Thornthwaite, na década de 70, Camargo propôs um novo método, baseado em dados de temperatura média do ar e radiação solar extraterrestre, que apresentava eficiência semelhante. Tal metodologia, de acordo com a Empresa Brasileira de Pesquisa Agropecuária (Embrapa) (2010), foi baseada em resultados da *ET_o* estimados para mais de uma centena de localidades (CAMARGO; CAMARGO, 2000).

Atualmente existem inúmeros métodos para determinar a evapotranspiração, e trabalhos recentes vêm buscando indicar o modelo que melhor se ajusta para determinadas regiões, como no trabalho de Cunha *et al.* (2021), em que os autores recomendam o modelo de De Jong e Stewart para o estado de Minas Gerais. Adicionalmente, diversos trabalhos podem ser ressaltados em estudos quantitativos de variáveis meteorológicas e/ou energias renováveis na engenharia agrícola, mais especificamente com energia solar (GABRIEL FILHO *et al.*, 2012), radiação solar (2021b), velocidade do vento (NAZARÉ *et al.*, 2020; GABRIEL FILHO *et al.*, 2011b) e sistemas híbridos solar e eólica (GABRIEL FILHO *et al.*, 2016; SERAPHIM *et al.*, 2014).

Modelos baseados em inteligência artificial vêm apresentando grande aplicabilidade na determinação da evapotranspiração (SANIKHANI *et al.*, 2019; TIKHAMARINE *et al.*, 2020; GRANATA *et al.*, 2020). Também tem se destacado o uso de modelos nos quais são aplicados os conceitos redes neurais (MALIK, KUMAR e KISI., 2018; ASHRAFZADEH *et al.*, 2020) e *neuro-fuzzy* (SHIRI, 2019; ADNAN *et al.*, 2019).

A teoria dos conjuntos *fuzzy* foi iniciada por Lotfi Asker Zadeh em 1965,

tendo origem no desafio de se trabalhar com incertezas. Os conceitos difusos, aproximam a modelagem matemática ao raciocínio humano através de conjuntos *fuzzy*, que utilizam variáveis numéricas e linguísticas para descrever os fenômenos estudados. Assim, é possível descrever termos subjetivos, como “aproximadamente” e “em torno de” matematicamente (ZADEH, 1965).

Diversos trabalhos vêm mostrando aplicações de sistemas *fuzzy* na área de irrigação, na modelagem matemática da produtividade da laranja e trigo com água de reuso (PUTTI *et al.* 2017b, 2021; BOSO *et al.* 2021a, 2021b), nas variáveis biométricas das culturas de alface, tomate e rabanete a partir de diferentes lâminas de irrigação (MATULOVIC *et al.* 2021; VIAIS NETO *et al.* 2019a, 2019b), e na vitalidade de orquídeas (PUTTI *et al.* 2014, 2017a). Na engenharia agrícola, destacam-se trabalhos na produção e empresas avícolas (PEREIRA *et al.*, 2008; CREMASCO *et al.*, 2010), na produção bovina (GABRIEL FILHO *et al.*, 2011a, 2016), na otimização de implementos agrícolas (GÓES *et al.*, 2021), e no mercado de produtos agrícolas (GABRIEL FILHO *et al.*, 2015; MARTÍNEZ *et al.*, 2020).

Modelos baseados em redes neurais, aplicando dados meteorológicos, tal como o desenvolvido por Nazaré *et al.* (2020), buscam empregar o aprendizado de máquina a fim de obter menores erros, diminuindo as incertezas do modelo.

O objetivo deste trabalho foi elaborar um modelo matemático para a estimativa de evapotranspiração, por meio do método de Camargo, utilizando um sistema de inferência adaptativo *neuro-fuzzy* (ANFIS), que emprega lógica *fuzzy* e redes neurais na sua concepção. Desta maneira, quando o produtor rural informar a temperatura e radiação solar do período ao modelo, e irá obter instantaneamente a evapotranspiração de referência, podendo assim, planejar com maior eficiência projetos de irrigação.

4 MATERIAL E MÉTODOS

De acordo com Back (2008), a evapotranspiração de referência (ET_o) calculada pelo método de Camargo é realizada por meio da Equação 1:

$$ET_o = Ra \cdot T \cdot K \cdot Nd \quad (1)$$

Em que, Ra é a radiação solar na superfície externa da atmosfera (mm). T é a temperatura média obtida pela média entre a temperatura máxima e mínima ($^{\circ}\text{C}$), Nd é o número de dias do período; e K é o fator de ajuste que varia de acordo com a temperatura média local, conforme a Tabela 1.

Tabela 1. Valor de K em relação à temperatura média local (T).

| T | K |
|-------------------------|--------------------------------|
| < 23 $^{\circ}\text{C}$ | 0,01 $^{\circ}\text{C}^{-1}$ |
| = 24 $^{\circ}\text{C}$ | 0,0105 $^{\circ}\text{C}^{-1}$ |
| = 25 $^{\circ}\text{C}$ | 0,011 $^{\circ}\text{C}^{-1}$ |
| = 26 $^{\circ}\text{C}$ | 0,0115 $^{\circ}\text{C}^{-1}$ |
| > 26 $^{\circ}\text{C}$ | 0,012 $^{\circ}\text{C}^{-1}$ |

Os dados de radiação solar (Ra) e temperatura (T) necessários para o cálculo, foram coletados da estação meteorológica automática do Instituto Nacional de Meteorologia (INMET) - Estação Tupã-A768, localizada no município de Tupã, São Paulo, nas coordenadas geográficas 21 $^{\circ}$ 56' Latitude Sul e 50 $^{\circ}$ 30' de Longitude Oeste com altitude média de 524 metros.

Na coleta de dados, considerou-se o período entre 20 de março de 2018 (início do outono) a 20 de março de 2019 (fim do verão), sendo que tais dados são registrados pela estação a cada hora, resultando, portanto, em 24h x 366 dias = 8784 dados. Considerou o fato de os sensores da estação meteorológica terem falhado no registro de algumas informações horárias que não foram disponibilizadas, realizou-se uma estimativa dos valores faltantes por meio do cálculo da média entre o valor anterior e posterior registrado, sendo que acima de três informações faltantes consecutivas, os dados foram retirados da análise. O período em que os dados não foram registrados constam na

Tabela 2, totalizando 102 informações não registradas, ou seja, uma perda de 1,20%.

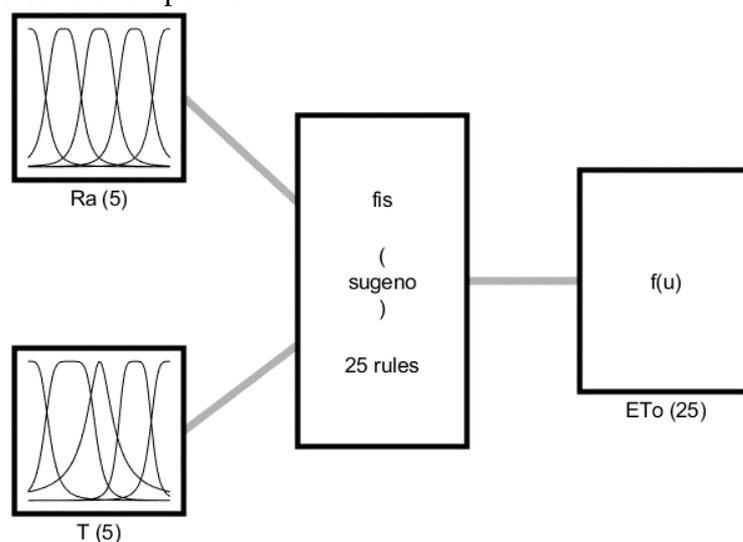
Tabela 2. Período superior a três informações consecutivas não disponibilizadas pelo INMET.

| Dia | Período |
|------------|----------------|
| 21/05/2018 | 3h às 12h |
| 21/06/2018 | 15h às 0h |
| 23/11/2018 | 0h às 4h |
| 08/12/2018 | 6h às 9h |
| 09/12/2018 | 4h às 10h |
| 11/12/2018 | 3h às 6h |
| 19/01/2019 | 5h às 10h |
| 07/02/2019 | 7h às 10h |
| 14/02/2019 | 1h às 7h |
| 21/02/2019 | 15h às 20h |
| 22/02/2019 | 0h às 7h |
| 23/02/2019 | 6h às 10h |
| 02/03/2019 | 17h às 21h |
| 04/03/2019 | 0h às 3h |
| 04/03/2019 | 5h às 11h |
| 13/03/2019 | 16h às 21h |
| 15/03/2019 | 15h às 18h |

A partir dos dados coletados, realizou-se uma análise de regressão linear múltipla com o objetivo de verificar a correlação e significância das variáveis de entrada em relação a variável de saída, sendo também possível obter mapas de contorno e

superfície tridimensional do comportamento das variáveis.

O desenvolvimento do sistema *neuro-fuzzy* para o cálculo automático da Evapotranspiração de Referência pela equação de Camargo é representado na Figura 1.

Figura 1. Sistema *neuro-fuzzy* para a obtenção da Evapotranspiração de Referência a partir da radiação solar e temperatura.

As variáveis de entrada do sistema foram radiação solar (Ra) e temperatura (T), sendo que para cada uma delas foram definidos cinco conjuntos fuzzy com

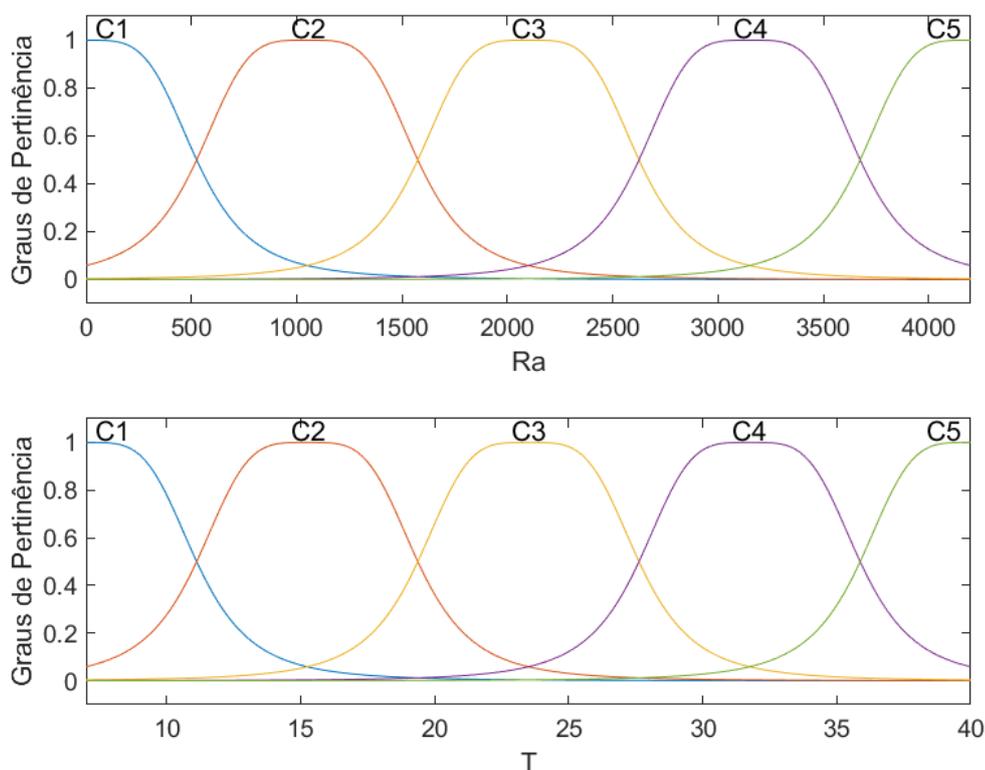
Figura 2. Funções de pertinência inicialmente definidas para as variáveis de entrada Radiação Solar (Ra) e Temperatura (T).

. A variável de saída refere-se ao valor da evapotranspiração calculada pelo

funções de pertinência do tipo sino generalizada, denominados “C1”, “C2”, “C3”, “C4” e “C5”. Os limites inicialmente definidos para cada conjunto estão representados na

método de Camargo (definida pela Equação 1). Como foram definidos 5 conjuntos *fuzzy* para cada uma das 2 variáveis de entrada, adotou-se 25 (5×5) regras para o estabelecimento do sistema.

Figura 2. Funções de pertinência inicialmente definidas para as variáveis de entrada Radiação Solar (Ra) e Temperatura (T).



A base de regras do sistema *fuzzy* foi obtida considerando todas as combinações possíveis entre os conjuntos *fuzzy* das variáveis de entrada, sendo $5 \times 5 = 25$ regras.

A utilização dos conjuntos *fuzzy*, permite que um elemento possa ter pertinência parcial em diversos conjuntos, devido à transição gradual das variáveis. Assim, a utilização da *Adaptive Network-*

based Fuzzy Inference System (ANFIS) é pertinente a este trabalho, uma vez que se refere a uma rede adaptativa multicamada de aprendizado supervisionado. A resposta do sistema é calculada para os parâmetros fornecidos, obtendo-se uma relação próxima entre saídas e entradas, já que o algoritmo de treinamento ajusta os parâmetros nos nós das estruturas do modelo (SPACCA, 2019).

De acordo com Haznedar e Kalinli (2018), um modelo ANFIS composto por duas entradas com duas funções de pertinência cada uma, uma saída e o modelo

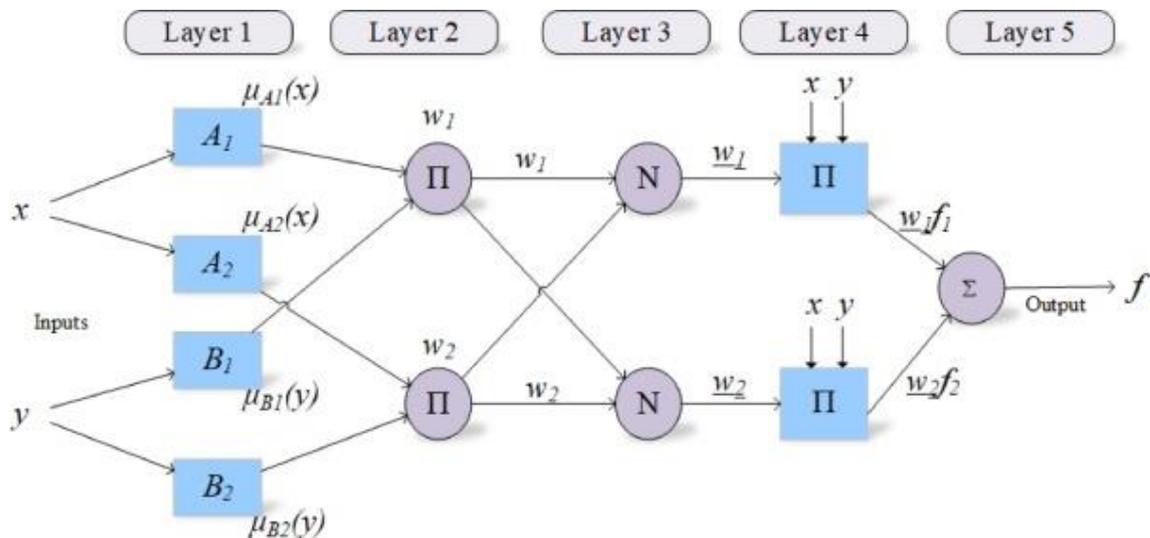
de inferência Takagi – Sugeno, o qual foi utilizado neste trabalho, tem sua estrutura definida conforme a

$$\text{“Se } x \text{ é } A_i \text{ e } y \text{ é } B_i, \text{ então } f_i = p_i x + q_i y + r_i\text{”} \quad (2)$$

Onde, x e y são as variáveis fuzzy; A_i e B_i referem-se aos conjuntos fuzzy; f_i é a combinação linear das variáveis de entrada e

a constante; e p_i , q_i e r_i são os parâmetros consequentes da regra.

Figura 3. Estrutura de um modelo ANFIS conforme Haznedar e Kalinli (2018).



Fonte: Haznedar e Kalinli (2018).

Verifica-se que a estrutura de um sistema ANFIS é composta por cinco camadas, descritas a seguir.

Camada 1: esta camada possui nós adaptativos e parâmetros antecedentes, visto que estes podem ser ajustados durante o

processo de aprendizado (HAZNEDAR; KALINLI, 2018). Nesta camada ocorre o processo de *fuzzificação*, no qual as funções de pertinência são associadas a um conjunto fuzzy com determinado grau de pertinência, tendo sua saída definida pela Equação 3:

$$\text{“Se } x \text{ é } A_i \text{ e } y \text{ é } B_i, \text{ então } f_i = p_i x + q_i y + r_i\text{”} \quad (3)$$

Onde i é o número de variáveis de entrada, j é o número de regras de combinação e μ é o grau de pertinência associado ao conjunto fuzzy.

Camada 2: as células nessa camada são não adaptativas e sua contagem é igual à contagem de regras, assim Haznedar e Kalinli (2018) a definem como a camada das regras, já que as regras são acionadas com

determinado grau de pertinência, tendo a força de disparo definida pela Equação 4:

$$w_i = \mu A_i(x) \cdot \mu B_i(y) \quad (4)$$

Onde w_i é a força do disparo da regra, A_i e B_i referem-se aos conjuntos *fuzzy*, μ é o grau de pertinência e x e y são as variáveis *fuzzy*.

Camada 3: de acordo com Mathur, Glesk e Buis (2016), essa camada também não possui nós adaptativos, já que é responsável por realizar a normalização, em que é aplicada uma média ponderada das forças de disparo das regras, calculada pela Equação 5:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2} \quad (5)$$

Onde \bar{w} refere-se à normalização, sendo i o número de variáveis de entrada.

Camada 4: esta é a camada de *defuzzificação*, cujos nós são adaptativos e sua saída é o produto da força de disparo normalizada e um polinômio de primeira ordem, representada pela Equação 6:

$$\bar{w}_i \cdot f_i = \bar{w}_i \cdot (p_i x + q_i y + r_i); \quad i = 1, 2 \quad (6)$$

Onde \bar{w}_i representa a normalização e p_i , q_i e r_i representam o conjunto de parâmetros de cada regra (MATHUR; GLESK; BUIS, 2016).

Camada 5: denominada de camada de soma por Haznedar e Kalinli (2018), possui um único nó não adaptativo com a função de realizar a soma de todas as saídas da camada anterior para produzir a saída global do sistema ANFIS, dado pela Equação 7:

$$f = \sum \bar{w}_i \cdot f_i = \frac{\sum w_i f_i}{\sum w_i}, \quad i = 1, 2 \quad (7)$$

Onde \bar{w}_i a normalização e f_i a combinação linear das variáveis de entrada e a constante.

Ao percorrer esta estrutura, o modelo sofre ajustes nos nós adaptativos, utilizando os valores de saída obtidos, para que o erro entre a saída do modelo e a saída real seja mínimo (HAZNEDAR; KALINLI, 2018). O responsável pela realização desses ajustes é o algoritmo de aprendizado, que neste trabalho foi utilizado o algoritmo híbrido, que corresponde à combinação da técnica do *backpropagation*, para os ajustes dos nós antecedentes, e estimativa dos mínimos quadrados, para os parâmetros consequentes das funções de saída (AL-DUNAINAWI; ABBOD; JIZANY, 2017).

Os estudos numéricos e experimentais deste trabalho foram desenvolvidos utilizando o software Matlab®, que foi utilizado para a implementação dos modelos propostos, por meio do pacote *Fuzzy Logic Toolbox*.

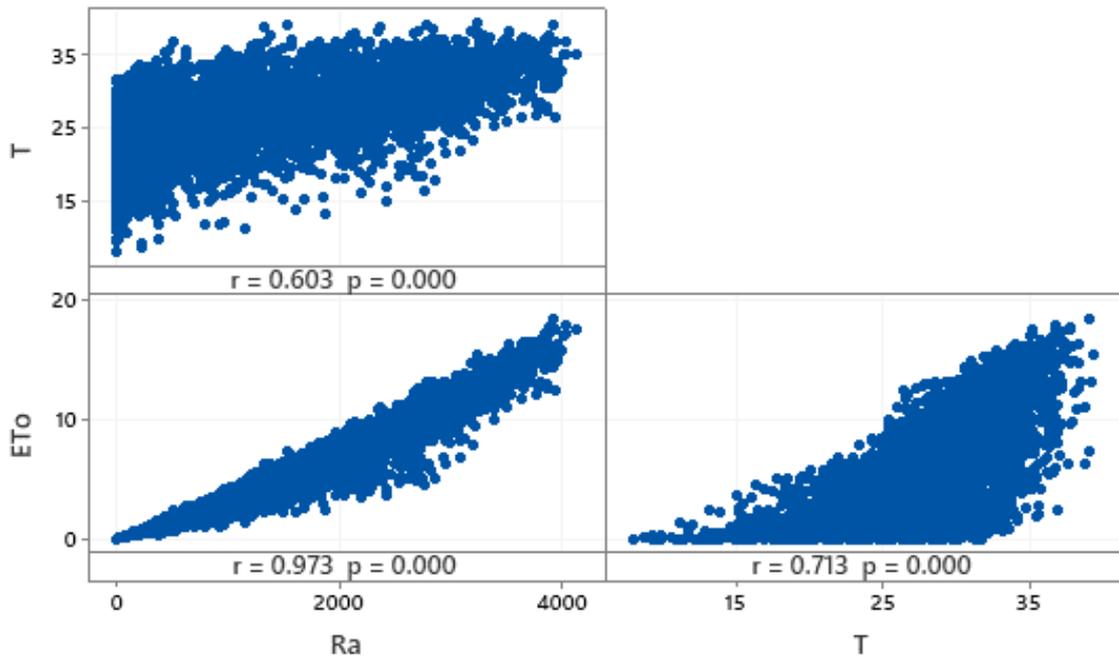
5 RESULTADOS E DISCUSSÃO

A partir da obtenção dos dados válidos para a modelagem, procedeu-se a análise de regressão, sendo que esta consiste em técnicas estatísticas que modelam matematicamente os dados, gerando uma função que os represente e relacione as variáveis. Na regressão múltipla, empregada neste trabalho, é modelado mais de uma variável de entrada.

Os valores de entrada e saída apresentaram correlação positiva quando relacionados, sendo que a relação entre as duas variáveis de entrada (T e Ra), mostrou-se significativa, com média explicação dos dados (60%). Quando se trata da variável resposta (ETo), seu relacionamento com as variáveis de entrada foi significativo, com *p*-valor igual a 0, apresentando poder explicativo de 97% quando relacionada à variável radiação solar (Ra) e 71% quando

relacionada à temperatura (T), como pode ser verificado na Figura 4.

Figura 4. Regressão Linear Múltipla para as variáveis Radiação Solar (Ra), Temperatura (T) e Evapotranspiração de Referência (ETo).



O modelo de regressão linear múltiplo apresentou 97,24% de ajuste da

$$ETo = -4,3192 + 0,003363 Ra + 0,16550 T \quad (8)$$

Em que: *ETo* é a evapotranspiração de referência (mm), *Ra* é a radiação solar ($\text{MJ m}^{-2} \text{dia}^{-1}$) e *T* é a temperatura ($^{\circ}\text{C}$).

equação aos dados do modelo e está representado na Equação 8.

A análise de variância mostrou que as variáveis *T* e *Ra* são significativas ao modelo (ambas com $p\text{-valor} < 0,05$), além de evidenciar a grande variabilidade dos dados em torno da média.

Tabela 3. Análise de variância da análise de regressão linear múltipla do conjunto de dados.

| Fonte | Grau de Liberdade | Soma dos Quadrados | Quadrado Médio | Valor F | Valor-P |
|------------------|-------------------|--------------------|----------------|----------|---------|
| Regressão | 2 | 87981 | 43990,6 | 83242,21 | 0,000 |
| Ra | 1 | 41993 | 41993,1 | 79462,46 | 0,000 |
| T | 1 | 2255 | 2255,5 | 4268,00 | 0,000 |
| Resíduos | 4728 | 2499 | 0,5 | | |
| Total | 4730 | 90480 | | | |

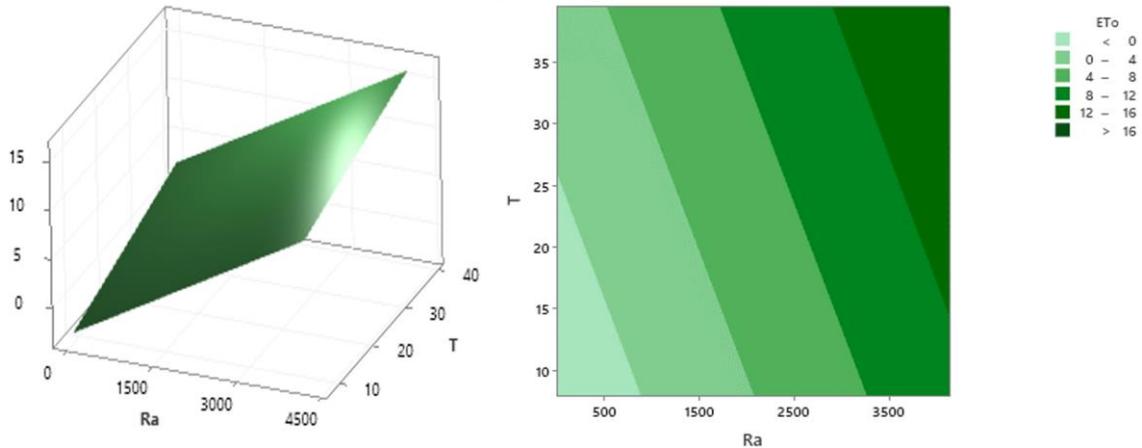
Ra é a radiação solar ($\text{MJ m}^{-2} \text{dia}^{-1}$) e *T* é a temperatura ($^{\circ}\text{C}$).

Considerando a importância das variáveis de entrada testadas para a descrição do modelo de evapotranspiração, obteve-se um mapa de superfície e de contorno, que podem ser visualizados na Figura 5. Tais mapas, mostram inúmeras

combinações das variáveis de entrada do modelo (radiação solar e temperatura), sendo possível verificar de maneira mais didática, o comportamento da variável dependente (*ETo*) em função das variáveis de entrada (*Ra* e *T*), evidenciando que

quanto menor for os valores de T e Ra, menor será o valor da evapotranspiração.

Figura 5. Superfície e Mapa de Contorno para as variáveis temperatura (T) e radiação solar (Ra) e sua influência sob a Evapotranspiração (ET_o).



Considerando os dados válidos para a elaboração do modelo *neuro-fuzzy*, realizou-se a combinação de todos os valores das variáveis de entrada para o treinamento do algoritmo de aprendizado. Desta forma, para a radiação solar (Ra), variou-se a cada 10 unidades entre o valor mínimo obtido de zero e o máximo de 4.200, enquanto que para a variável temperatura (T), o intervalo foi de uma unidade, sendo o valor mínimo de sete e o máximo de 40. Desta forma, o modelo foi

treinado por meio de 14.315 combinações de radiação solar e temperatura.

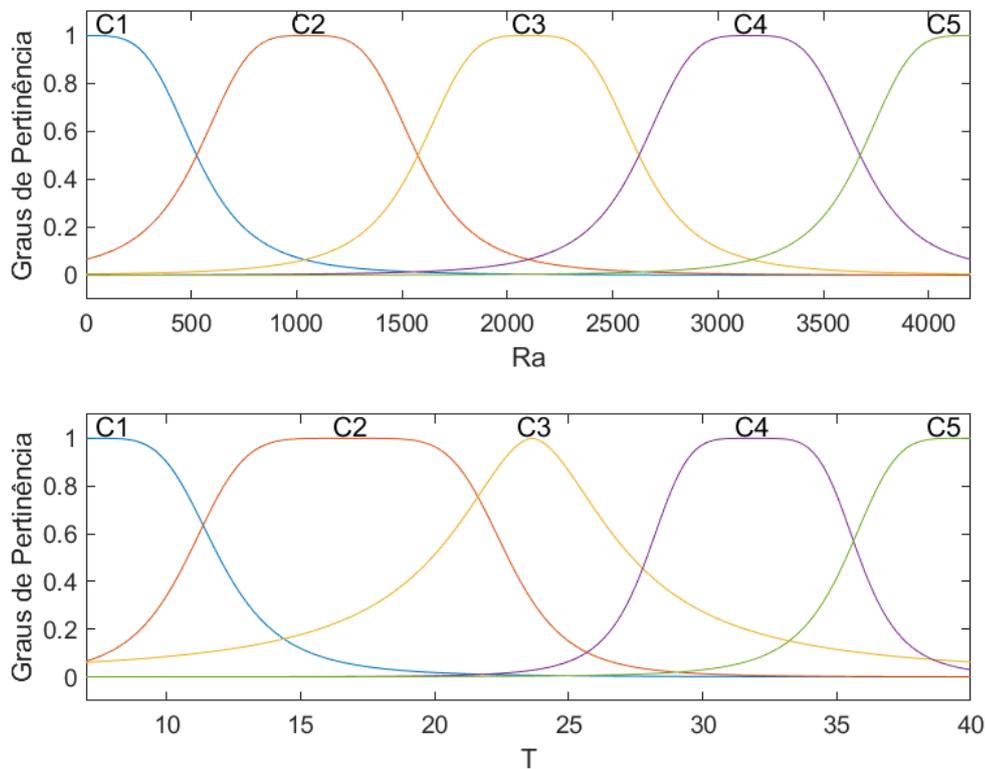
Desta maneira, ao proceder o treinamento do modelo, as funções de pertinência das variáveis de entrada são ajustadas com o objetivo de minimizar o erro de predição (MATHUR; GLESK; BUIS, 2016). Assim, as funções de pertinência das variáveis de entrada anteriormente definidas pela

Figura 2. Funções de pertinência inicialmente definidas para as variáveis de entrada Radiação Solar (Ra) e Temperatura (T).

sofreram ajustes pelo próprio algoritmo de aprendizado, e passaram a ter seus limites definidos pelas funções gaussianas representadas na

Figura 6. Verifica-se que houve mudanças significativas para a variável temperatura (T).

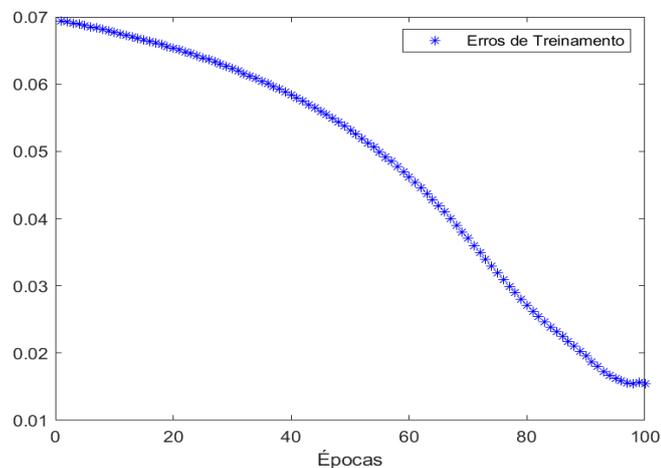
Figura 6. Funções de pertinência para as variáveis de entrada Radiação Solar (Ra) e Temperatura (T).



Ainda de acordo com Mathur, Glesk e Buis (2016), durante o treinamento, ocorrem diversas interações entre os dados de entrada a fim de minimizar o erro, sendo essas interações conhecidas como épocas. Como pode ser visto na Figura 7, neste trabalho estabeleceu-se 100 épocas para o

treinamento do modelo, sendo que o erro preditivo reduz de 0,07 na primeira interação para, aproximadamente, 0,015 a partir da interação 98, indicando que o modelo alcançou o menor erro de treinamento possível.

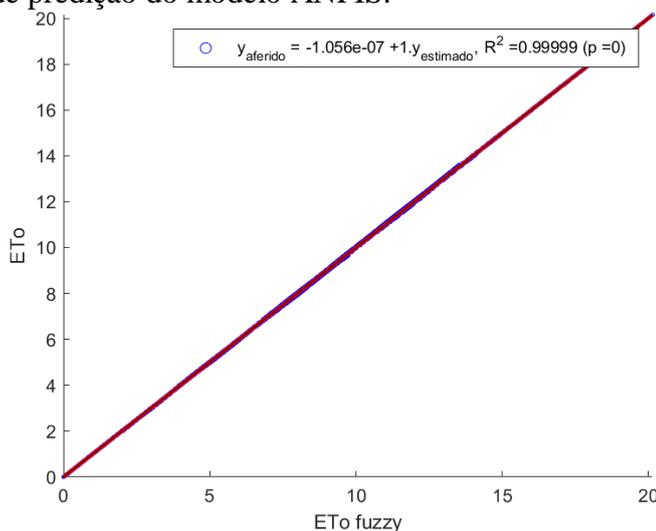
Figura 7. Variações dos erros de treinamento conforme as épocas do modelo *neuro-fuzzy*.



Ao se obter a equação de predição do modelo (Figura 8), verifica-se que o ajuste dos dados ao modelo (R^2) foi de 99%, apresentando desempenho superior à predição realizada por meio da regressão linear múltipla, a qual apresentou R^2 de

97,24%. Portanto, é preferível a utilização do modelo ANFIS para a determinação da Evapotranspiração de Referência (ET_o) pela equação de Camargo devido à maior precisão no cálculo e possibilidade de obtenção de resultados de forma instantânea.

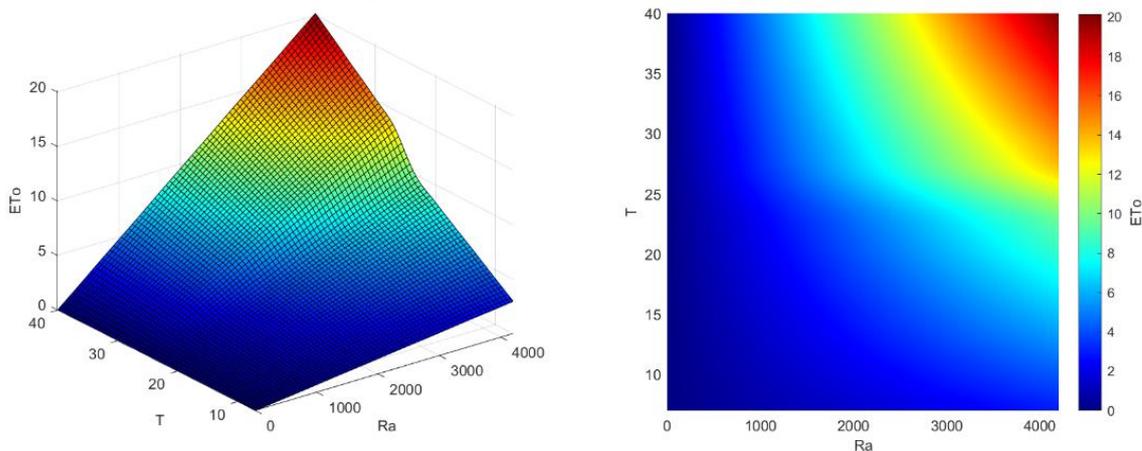
Figura 8. Equação de predição do modelo ANFIS.



A partir dos resultados obtidos com a elaboração do modelo para o cálculo da evapotranspiração de referência por meio da equação de Camargo, elaborou-se superfície e mapa de contorno (Figura 9), tornando

possível a visualização do comportamento da variável resposta (Evapotranspiração de Referência) em função das modificações das variáveis de entrada (R_a e T) mais compreensível.

Figura 9. Superfície e mapa de contorno obtidos a partir da elaboração do modelo *neuro-fuzzy* para o cálculo da evapotranspiração de referência.



A partir das figuras anteriores, percebe-se que quanto menor os valores de temperatura e radiação solar, menor será o

valor da evapotranspiração de referência, sendo zero o menor valor obtido e 20 mm o maior valor para os valores de temperatura e

radiação solar mais elevados. Ressalta-se que este comportamento da resposta do modelo era esperado, uma vez que a radiação solar é a principal fonte de energia para a Terra, sendo um dos fatores determinantes do clima e, conseqüentemente, um parâmetro que influencia a temperatura (GOMEZ *et al.*, 2018).

6 CONCLUSÕES

Por meio deste estudo, verifica-se que as variáveis de entrada (Ra, T), para cálculo de evapotranspiração pelo método de Camargo, são fundamentais para o ajuste do modelo de regressão múltipla e também para a modelagem por meio do método de inferência *neuro-fuzzy* (ANFIS).

Desta maneira, o método computacional estabelecido neste trabalho mostrou-se capaz de calcular

instantaneamente a evapotranspiração de referência por meio da equação de Camargo, a partir da inserção das variáveis radiação solar e temperatura, relativas à localidade do plantio que se deseja monitorar. Tal método, baseado em sistema *neuro-fuzzy*, permite o produtor saber o valor da evapotranspiração de referência, que após ser multiplicada pelo coeficiente de cultivo da cultura requerida, possibilita determinar a real necessidade hídrica da planta para a adoção de práticas de manejo mais adequadas para a otimização de recursos.

7 AGRADECIMENTOS

Os autores agradecem Conselho Nacional de Pesquisa (CNPq), pela concessão da Bolsa de Produtividade (Processos #315228/2020-2 (LRAGF) e #303923/2018-0 (FFP)), e de iniciação científica (Processo: #54055/2019 (SLF)).

8 REFERÊNCIAS

- ADNAN, R. M.; MALIK, A.; KUMAR, A.; PARMAR, K. S.; KISI, O. Pan evaporation modeling by three different neuro-fuzzy intelligent systems using climatic inputs. *Arabian Journal of Geosciences, Heidelberg*, v. 12, n. 19, p. 1-14, 2019.
- AL-DUNAINAWI, Y.; ABBOD, M. F.; JIZANY, A. A new MIMO ANFIS-PSO based NARMA-L2 controller for nonlinear dynamic systems. *Engineering Applications of Artificial Intelligence, Oxford*, v. 62, n. 6, p. 265-275, 2017.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop Evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. FAO, Rome, v. 300, n. 9, p. D05109, 1998.
- ASHRAFZADEH, A.; MALIK, A.; JOTHIPRAKASH, V.; GHORBANI, M. A.; BIAZAR, S. M. Estimation of daily pan evaporation using neural networks and meta-heuristic approaches. *ISH Journal of Hydraulic Engineering, Abingdon*, v. 26, n. 4, p. 421-429, 2020.
- BACK, A. J. Desempenho de métodos empíricos baseados na temperatura do ar para a estimativa da evapotranspiração de referência em Urussanga, SC. *Irriga, Botucatu*, v. 13, n. 4, p. 449-466, 2008.

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*, Jaboticabal, v. 41, n.3, p. 311-318, 2021a.

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*, Jaboticabal, v. 41, n. 3, p. 319-329, 2021b.

CAMARGO, A. P. Balanço hídrico no Estado de São Paulo. 3. ed., Campinas: IAC, 1971. 24 p.

CAMARGO, A. P.; CAMARGO, M. B. P. Uma revisão analítica da evapotranspiração potencial. *Bragantia*, Campinas, v. 59, n. 2, p. 125-137, 2000.

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*, Botucatu, v. 25, n. 1, p. 21-39, 2010.

CUNHA, A. C.; GABRIEL FILHO, L. R. A.; TANAKA, A. A.; GOES, B. C.; PUTTI, F. F. Influence Of The Estimated Global Solar Radiation On The Reference Evapotranspiration Obtained Through The Penman-Monteith Fao 56 Method. *Agricultural Water Management*, Amsterdam, v. 243, n. 1, p. 106491, 2021a.

CUNHA, A. C.; GABRIEL FILHO, L. R. A.; TANAKA, A. A.; PUTTI, F. F. Performance and estimation of solar radiation models in state of Minas Gerais, Brazil. *Modeling Earth Systems and Environment*, Heidelberg, v. 7, p. 603-622, 2021b.

EMBRAPA. Evapotranspiração – Uma Revisão sobre os Métodos Empíricos. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2010.

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*, Jaboticabal, v. 31, n. 4, p. 813-825, 2011a.

GABRIEL FILHO, L. R. A.; CREMASCO, C. P.; SERAPHIM, O. J.; CANEPPELE, F. L. Caracterização analítica e geométrica da metodologia geral de determinação de distribuições de Weibull para o regime eólico e suas aplicações. *Engenharia Agrícola*, Jaboticabal, v. 31, n. 1, p. 56-66, 2011b.

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*, Jaboticabal, v. 35, n. 2, p. 350-367, 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*, Jaboticabal, v. 36, n. 1, p. 179-193, 2016.

GABRIEL FILHO, L. R. A.; SERAPHIM, O. J.; CANEPPELE, F. L.; CREMASCO, C. P.; PUTTI, F. F. Variable analysis in wind photovoltaic hybrid systems in rural energization. *IEEE Latin America Transactions*, Piscataway, v. 14, n. 12, p. 4757-4761, 2016.

GABRIEL FILHO, L. R. A.; VIAIS NETO, D. S.; CREMASCO, C. P.; SERAPHIM, O. J.; CANEPPELE, F. L. Mathematical analysis of maximum power generated by photovoltaic systems and fitting curves for standard test conditions. *Engenharia Agrícola*, Jaboticabal, v. 32, n. 4, p. 650-662, 2012.

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*, Heidelberg, v. 7, 2021.

GOMEZ, J. M. R. CARLESSO, F., VIEIRA, L. E.; DA SILVA, L. A irradiância solar: conceitos básicos. *Revista Brasileira de Ensino de Física*, São Paulo, v. 40, n. 3, p. 3312, 2018.

GRANATA, F.; GARGANO, R.; MARINIS, G. Artificial intelligence based approaches to evaluate actual evapotranspiration in wetlands. *Science of The Total Environment*, Amsterdam, v. 703, p. 135653, 2020.

GURSKI, B. C.; JERSZURKI, D.; SOUZA, J. L. M. Alternative Methods of Reference Evapotranspiration for Brazilian Climate Types. *Revista Brasileira de Meteorologia*, São Paulo, v. 33, n. 3, p. 567-578, 2018.

HAZNEDAR, B.; KALINLI, A. Training ANFIS structure using simulated annealing algorithm for dynamic systems identification. *Neurocomputing*, Amsterdam, v. 302, n. 8, p. 66-74, 2018.

MALIK, A.; KUMAR, A.; KISI, O. Daily pan evaporation estimation using heuristic methods with gamma test. *Journal of Irrigation and Drainage Engineering*, Reston, v. 144, n. 9, p. 04018023, 2018.

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*, Amsterdam, v. 242, n. 1, p. 116064, 2020.

MATHUR, N.; GLESK, I.; BUIS, A. Comparison of adaptive neuro-fuzzy inference system (ANFIS) and Gaussian processes for machine learning (GPML) algorithms for the prediction of skin temperature in lower limb prostheses. *Medical Engineering and Physics*, London, v. 38, n. 10, p. 1083-1089, 2016.

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*, Maringá, v. 43, n. 1, p. 51384, 2021.

- NAZARÉ, G.; CASTRO, R.; GABRIEL FILHO, L. R. A. Wind power forecast using neural networks: Tuning with optimization techniques and error analysis. *Wind Energy*, Oxford, v. 23, n. 3, p. 810-824, 2020.
- 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*, Jaboticabal, v. 28, n. 4, p. 624-633, 2008.
- 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*, Philadelphia, v. 288, n. 6, 124-129, 2017a.
- 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 (Orchidacea). *Irriga*, Botucatu, v. 19, n. 3, p. 405-413, 2014.
- 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*, Jaboticabal, v. 37, n. 6, p. 1103-1115, 2017b.
- 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*, Jaboticabal, v. 41, n. 2, p. 204-214, 2021.
- SANIKHANI, H.; KISI, O.; MAROUFPOOR, E.; YASEEN, Z. M. Temperature-based modeling of reference evapotranspiration using several artificial intelligence models: application of different modeling scenarios. *Theoretical and Applied Climatology*, Wien, v. 135, n. 1, p. 449-462, 2019.
- SEDIYAMA, G. C. A versão/proposta para o conceito de evapotranspiração de referência. *Campina Grande: SBA*, 1995.
- SERAPHIM, O. J.; SIQUEIRA, J. A. C.; PUTTI, F. F.; GABRIEL FILHO, L. R. A.; CREMASCO, C. P.; DALVIN, R. S. Energetic Exploitation from a Hybrid PV-wind Power Micro-generation Rural Electrification. *Energy Procedia*, Amsterdam, v. 57, p. 1475-1484, 2014.
- SHIRI, J. Evaluation of a neuro-fuzzy technique in estimating pan evaporation values in low-altitude locations. *Meteorological Applications*, Oxford, v. 26, n. 2, p. 204-212, 2019.
- SILVA, R. A. C. Inteligência artificial aplicada à ambientes de Engenharia de Software: Uma visão geral. Viçosa: UFV, 2005.
- SPACCA, J. L. C. Usando o sistema de inferência neuro fuzzy - ANFIS para o cálculo da cinemática inversa de um manipulador de 5 DOF, 2019. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha Solteira, 2019.

TIKHAMARINE, Y.; MALIK, A.; SOUAG-GAMANE, D.; KISI, O. Artificial intelligence models versus empirical equations for modeling monthly reference evapotranspiration. *Environmental Science and Pollution Research, Heidelberg*, v. 27, n. 5, p. 30001-30019, 2020.

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, Jaboticabal*, v. 39, n. 3, p. 294-304, 2019a.

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, Jaboticabal*, v. 39, n. 3, p. 305-314, 2019b.

ZADEH, L. A. Fuzzy sets. *Information Control, Maryland Heights*, v. 8, n. 3, p. 338-353, 1965.