Brazilian Journal of Development

# Aplicação de redes neurais mlp na predição da evapotranspiração de referência

# Application of mlp neural networks in the prediction of reference evapotranspiration

DOI:10.34117/bjdv6n5-110

Recebimento dos originais: 25/04/2020
Aceitação para publicação: 07/05/2020

**Daiana da Silva Santos**
Universidade Federal Rural do Rio de Janeiro, Instituto de Ciências Exatas – Seropédica, RJ, Brasil
daiafis@gmail.com

**Robson Mariano da Silva**
Universidade Federal Rural do Rio de Janeiro, Instituto de Ciências Exatas – Seropédica, RJ, Brasil
robsonms@ufrrj.br

**RESUMO**

Tendo em vista que a evapotranspiração é o principal componente do balanço hídrico em sistemas agrícolas e a variável mais ativa do ciclo hídrológico, este estudo objetivou a aplicação de redes neurais de Perceptrons de Múltiplas Camadas, para estimar os valores diários da evapotranspiração de referênca e posteriormente comparados com os valores da evapotranspiração de referência estimados pelo método de Penman-Monteith, para o município de Teresóplois/RJ. Para tal utilizou-se dados meteorológicos coletados da estação meteorológica do CPETC/INPE entre 2010 e 2015. O desempenho do modelo foi avaliado através do erro médio absoluto (MAE), erro médio quadrático (MSE), erro médio percentual absoluto (MAPE), raiz do erro médio quadrático (RMSE) e índice de concordância (D). Os resultados mostram que o modelo proposto apresentou ótimo desempenho na reprodução dos valores da evapotranspiração de referência, apresentando uma precisão de 97.42% quando comparado com os valores obtidos pelo método de Penman-Monteih.

**Palavra-chave:** Redes Neurais, Evapotranspiração, Predição, Penman-Monteith.

**ABSTRACT**

Bearing in mind that evapotranspiration is the main component of the water balance in agricultural systems and the most active variable in the water cycle, this study aimed at the application of Multiple Layer Perceptron neural networks to estimate the daily values of reference evapotranspiration and later compared with the reference evapotranspiration values estimated by the Penman-Monteith method, for the municipality of Teresóplois / RJ. For this purpose, meteorological data collected from the CPETC / INPE meteorological station between 2010 and 2015 were used. The performance of the model was evaluated through the mean absolute error (MAE), mean square error (MSE), mean absolute percentage error (MAPE), root of the mean square error (RMSE) and agreement index (D). The results show

Brazilian Journal of Development

that the proposed model presented an excellent performance in the reproduction of the reference evapotranspiration values, presenting an accuracy of 97.42% when compared with the values obtained by the Penman-Monteih method.

**Keyword:** Neural Networks, Evapotranspiration, Prediction, Penman-Monteith.

## 1 INTRODUÇÃO

A evapotranspiração (ET) é considerada o principal componente do balanço hídrico em sistemas agrícolas, sendo a variável mais ativa no ciclo hidrológico (Dong e Daí, 2016). Além de ter um papel importante no campo de gestão de recursos hídricos, é um fenômeno complexo e não-linear (Raziei e Pereira, 2013). A evapotranspiração de referência (ETo) é medida por técnicas e princípios físicos relativamente complexos sendo a maneira mais direta e precisa de se estimar o balanço hídrico no solo é com a utilização de lisímetros. No entanto, devido as limitações associadas ao método, a adoção de modelos matemáticos é uma alternativa prática à estimação da ETo (Back, 2007). Dentre esses métodos podemos citar Penman-Monteith, Hargreaves-Samani, Jenen-Haise, Linacre, Hamon, Benavides-Lopes, entre outros.

A partir de inúmeros estudos realizados nas últimas décadas, a equação combinada de Peanman-Monteith, modificada por Allen *et al*. (1998), é o melhor modelo para representar fatores fisiológicos envolvidos no processo de evapotranspiração, sendo recomendado como padrão pela *Food and Agriculture Organization of the United Nations*. A principal desvantagem deste modelo é o grande número de variáveis meteorológicas necessárias (temperaturas média, máxima, mínima, umidade relative do ar, velocidade do vento e radiação solar global). Visto que muitas estações meteorológicas não possuem todos os sensores obrigatórios e mesmo quando presentes, apresentam falhas, que provocam dados de baixa qualidade. Observação importante a ser considerada, especialmente para os países em desenvolvimento, onde os conjuntos confiáveis de dados de radiação, umidade relativa e velocidade do vento nem sempre estão disponíveis (Trajkovic e Kolakovic, 2009). Diversos modelos empíricos (Hargreaves-Samani, Jensen-Haise, Linacre, Tanque Classe A e Hamon) que utilizam um menor número de variáveis têm sido comumente aplicados como alternativas ao Peanman-Monteith, entretanto esses modelos podem não apresentar boas estimativas, superestimando ou subestimando a ETo, quando comparados com o método padrão. Fato que tem levado a diversos pesquisadores a desenvolverem aplicações estruturadas em Inteligência Computacional (IC), como as Redes Neurais Artificiais (Alves, Rolim e Aparecido, 2017), Máquinas de Vetores de Suporte (Yao *et al*., 2017), Algoritmos Genéticos (Celeste e Chaves, 2014; Parasuraman, Elsohorbagy e Carey, 2010) e Lógica Fuzzy (Abbas, Al-Rekabi e Hassan,

2017; Mamak *et al*., 2017), para aplicações na gestão de recursos hídricos, especialmente na predição da evapotranspiração.

Diante disso, esse trabalho tem como objetivo utilizar redes neurais de Perceptrons de Múltiplas Camadas (RN-MLP) na predição da evapotranspiração de referência (ETo) para o município de Teresópolis-RJ/Brasil.

## 2 MATERIAIS E MÉTODOS

O conjunto de dados utilizados nesse trabalho, foi obtido junto a estação meteorológica PCD31954 (Latitude: -22.40°, Longitude: -42.79°), no município de Teresópolis – RJ (Figura 1), de responsabilidade do Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE). No período de 01/01/2005 a 31/12/2015, tendo como variáveis diárias as temperaturas média, máxima, mínima do ar (°C), umidade relativa do ar (%), velocidade do vento a 10 metros de altura (m/s) e a radiação solar global acumulada (MJ/m$^2$).

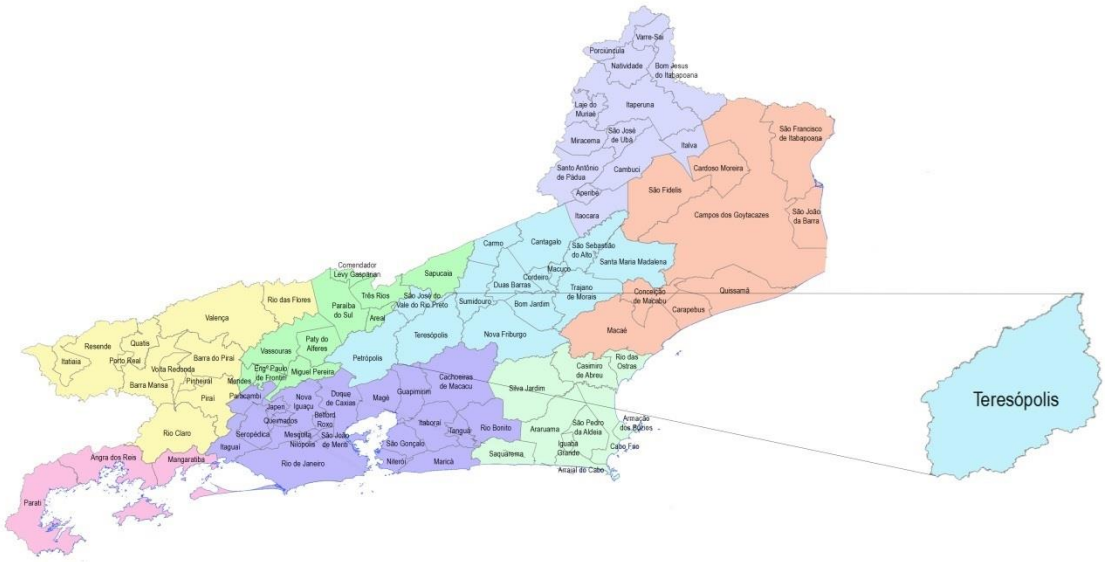



Figura 1- Localização geográfica da região de Teresópolis – RJ/Brasil.

Brazilian Journal of Development

A evapotranspiração de referência foi estimada pelo método de Penman-Monteith Eq. (1).

$$ETo = \left( \frac{0.48 * \Delta \left( R_n - G \right) + \gamma * \left( \frac{900}{T + 273} \right) * U2 * \left( es - e \right)}{\Delta + \gamma * \left( 1 + 0.34 * U2 \right)} \right) \quad (1)$$

Onde, ETo é a evapotranspiração de referência, $R_n$ saldo da radiação diário (MJ/m$^2$), $G$ fluxo de calor no solo (MJ/m$^2$), $T$ temperatura do ar, $U2$ velocidade do vento (m/s), $\gamma$ constante psicrométrica (0.0062 kPa/°C), $es$ é a pressão de saturação de vapor de água (kPa), $es - e$, é o deficit de pressão de saturação de vapor de água (KPa) e $\Delta$ é a declividade da curva de pressão de vapor em relação á temperatura (kPa/°C), calculada pela Eq. (2)

$$\Delta = \frac{0.48 * es}{\left( T + 273 \right)^2} \quad (2)$$

As redes Neurais Artificiais (RNAs) são sistemas paralelos e distribuídos, constituídos de unidades simples (neurônios ou nós), que calculam determinadas funções matemáticas (principalmente não-lineares) e apresentam capacidade de generalização, auto-organização e processamento temporal. De maneira análoga ao sistema nervoso de um ser humano, onde os neurônios são dispostos em uma ou mais camadas interligadas por conexões, geralmentemente unidirecionais, denominadas sinapses. A estas conexões associam-se valores, denominados pesos sinápticos, responsáveis pela ponderação das entradas de cada neurônio como forma de armazenamento do conhecimento de um determinado modelo (Haykin, 2001).

Uma RNA possui a característica de aprender por meio de exemplos, extraindo conhecimento de um determinado conjunto de dados. O conhecimento é adquirido a partir do processo pelo qual os hiperplanos livres de uma rede neural são ajustados por meio de uma forma continuada de estímulo pelo ambiente externo, visando minimizar o valor de uma função de erro. Esse processo é definido como aprendizado, que pode ser classificado como supervisionado ou não supervisionado (Haykin, 2001). No contexto do aprendizado supervisionado, apresentamos à rede as entradas disponíveis e a saída desejada, e o algoritmo trabalha no sentido de ajustar os pesos das sinapses por meio do cálculo da diferença entre o

valor da saída desejada $y_{di}(t)$ e o valor predito pela RNA $y_{pi}(t)$ no instante $t$ produzindo desta forma um erro $\delta(t)$ Eq. (3).

$$\delta(t) = y_{di}(t) - y_{pi}(t) \tag{3}$$

A forma genérica para o ajuste dos pesos, por correção de erros, é apresentada na Eq. (4).

$$w_i(t+1) = w_i(t) + \eta e_i(t) x_i(t) \tag{4}$$

onde $\eta$ é a taxa de aprendizagem e $x_i(t)$ é a entrada para o neurônio $i$ no tempo $t$ (Braga *et al.*, 2012).

Na aprendizagem não supervisionada, não se conhecem os valores das saídas desejadas $y_{di}(t)$, logo, a aprendizagem ocorre através da identificação de padrões nas entradas. A escolha da arquitetura de uma RNA, está relacionada com os tipos de problemas a serem abordados e é definida por 4 hiperparâmetros: número de camadas da rede, número de neurônios em cada camada, tipo de conexão entre neurônios e a topologia da rede. Em relação ao número de camadas, existem redes de camada única, que possuem seus neurônios (nós) arranjados em apenas uma camada, sendo restritas para a solução de problemas linearmente separáveis e as redes de múltiplas camadas, formadas pela combinação de várias redes de camada simples (Haykin, 2001). Dentre as redes de múltiplas camadas temos a do tipo *Percptrons* de Multiplas Camadas (*Multilayer Perceptron* – MLP), que apresentam uma ou mais camadas de neurônios intermediários ou ocultos, sendo considerada uma aproximadora universal (Figura 2). De acordo com o teorema da aproximação universal, qualquer função continua pode ser uniformemente aproximada por uma rede com pelo menos uma camada de neurônios ocultos, e com uma função de ativação sigmoide (Haykin, 2001).

As redes MLP têm sido aplicadas com sucesso para resolver diversos problemas através do seu treinamento de forma supervisionada com a utilização do algoritmo de retropropagação do erro (*backpropagation*), o qual apresenta duas fases distintas. Na primeira fase, ocorre a propagação do sinal funcional (*feedforward*) mantendo-se os pesos fixos de modo a gerar um

valor de saída a partir das entradas fornecidas à rede. Na segunda fase, as saídas são comparadas com os valores desejados, gerando um sinal de erro, que se propaga da saída para a entrada, ajustando-se os pesos de modo a minimizar o erro. Assim, a forma de calcular o erro depende da camada em que se encontra o neurônio, como mostra a Eq. (5).

$$\delta_l = \begin{cases} f_a' e_l, & se\ n_l \in C_{sai} \\ f_a' \sum w_{lk} \delta_k, & se\ n_l \in C_{int} \end{cases} \tag{5}$$

onde $n_l$ é o $l$-ésimo neurônio $C_{sai}$ representa a camada de saída, $C_{int}$ representa uma camada intermediária, $f_a'$ é a derivada parcial da função de ativação do neurônio e $e_l$ é o erro quadrático cometido pelo neurônio de saída quando sua resposta é comparada à desejada, que é definido pela Eq. (6).

$$e = \frac{1}{2} \sum_{q=1}^{k} \left( y_p - \hat{y}_q \right)^2 \tag{6}$$

onde $\hat{y}_q$ é a saída produzida pelo neurônio e $y_p$ é a saída desejada.

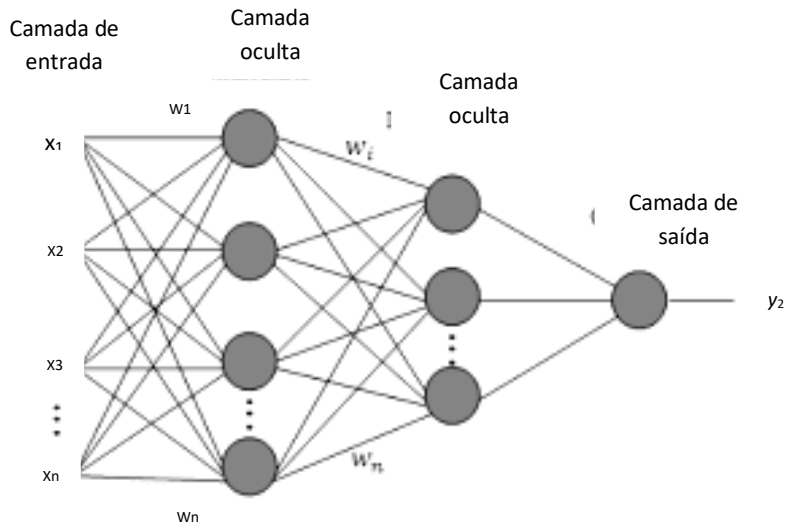



Figura 2- Arquitetura de uma rede tipo MLP com duas camadas oculta.

Brazilian Journal of Development

Visando não saturar os neurônios da rede MLP, os dados de entradas foram normalizados no interval (0,1), através da Eq. (7).

$$x_j^{norm} = \frac{x_j - x_j^{\min}}{x_j^{\max} - x_j^{\min}} \tag{7}$$

onde $x_j^{norm}$ é a variável normalizada, $x_j$ variável original, $x_j^{\max}$ maior valor entre as variáveis e $x_j^{\min}$ o menor valor da variável original.

O modelo computacional RN-MLP proposto nesse trabalho utilizou como variáveis de entrada as medidas diárias das temperaturas média, máxima, mínima do ar, umidade relativa do ar, velocidade do vento a 10 metros de altura e a radiação solar global acumulada diária e como variável de saída a ETo estimada pelo método de Penman-Monteith.

Para avaliar o desempenho do modelo RN-MLP com os resultados apresentados pelo Penman-Monteith na estimativa da ETo (ETo_PMT), foram utilizadas as métricas estatísticas: erro médio absoluto (MAE) Eq. (8), erro médio quadrático (MSE) Eq. (9), erro médio percentual absoluto (MAPE) Eq. (10), raiz do erro médio quadrático (RMSE) Eq. (11) e índice de concordância (D) Eq. (12). (Fonseca *et al*., 2012).

$$MAE = \frac{1}{n}\sum_{i=1}^{n}\left|X_i - Y_i\right| \tag{8}$$

$$MSE = \frac{1}{n}\sum_{i=1}^{n}\left(X_i - Y_i\right)^2 \tag{9}$$

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left(\frac{\left(X_i - Y_i\right)}{X_i}\right)*100 \tag{10}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}\left(X_i - Y_i\right)^2} \tag{11}$$

$$D = 1 - \frac{\sum_{i=1}^{n}\left(X_i - Y_i\right)^2}{\sum_{i=1}^{n}\left(\left|Y_i - \bar{X}_i\right| + \left|X_i - \bar{X}_i\right|\right)^2} \tag{12}$$

onde $n$ representa o número de amostras, $X_i$ o valor observado, $\bar{X}_i$ a média dos valores observados e $Y_i$ o valor predito pelo modelo.

O conjunto de dados foi dividido em dois subconjuntos, um com 70% dos dados sendo usados na fase de treinamento e o restante na fase de teste.

O modelo computacional proposto foi implementado utilizando o *software* R e o pacotes *Metrics* e *Neuralnet*. A relação dos parâmetros utilizados no modelo RN-MLP está sumarizada na tabela 1. Os quais foram obtidos de forma empírica.

Tabela 1- Parâmetros utilizados no modelo RN-MLP

| Parâmetros | Valor |
|---|---|
| N° de variáveis de entrada | 6 |
| N° de camadas ocultas | 2 |
| N° de neurônios na primeira camada | 6 |
| N° de neurônios na segunda camada | 4 |
| N° máximo de épocas | 2000 |
| Função de ativação | logistic |
| Algoritmo de treinamento | backpropagation |
| Métrica usada no erro de treinamento | SSE |
| Inicialização dos pesos | Aleatoriamente com valores [0,1] |
| Critério de parada | 0.001 |
| Taxa de aprendizado | 0.01 |

Brazilian Journal of Development

## 3 RESULTADOS

Na tabela 2 apresentamos a análise exploratória do conjunto de dados. Nas tabelas (3 e 4) estão representados respectivamente, os valores da ETo obtidos com a utilização do método de Penman-Monteith (ETo_PMT) e o de redes neurais MLP (ETo_RN-MLP) e o desempenho do modelo RN-MLP na predição da ETo diária no conjunto de teste.

Tabela 2 – Análise exploratória do conjunto de dados utilizados no estudo.

| | Radiação(MJ/m²) | Temp. Média(°C) | Temp. Max(°C) | Temp. Min(°C) | Umidade(%) | Vel. Vento(m/s) |
|---|---|---|---|---|---|---|
| média | 12.29 | 22.87 | 26.51 | 14.76 | 70.12 | 4.89 |
| mediana | 12.80 | 22.88 | 26.50 | 15.50 | 70.50 | 4.55 |
| [Max-Min] | 41.10 - 0.10 | 34.00 - 11.33 | 36.00 - 14.67 | 22.50 - 6.00 | 98.00 - 30.00 | 12.60 - 1.05 |

Observa-se que a temperatura média verificada no período de observação foi superior a 22°C e a amplitude entre a temperatura máxima verificada no período observado foi inferior a 21.5°C. Quando comparado com o valor mínimo verificado no período, a diferença obtida é entorno de 17°C. Indicando uma amplitude térmica de 4.5°C no período no município de Teresópolis. No que tange ao valor da ETo estimada pelo modelo de Penman-Monteith, pode se verificar na tabela 3, que a diferença entre os valores de máximo e de mínimo está em torno de 8.50, indicando uma grande amplitude dos valores dessa variável. Com relação à radiação global acumulada diária, constatamos que a média no perído estudado foi superior a 12 ($MJ/m^2$). Analisando a variável umidade, verifica-se que a amplitude é superior a 60%, valor esse que indica uma boa capacidade de retenção de água pelo ar.

Tabela 3 – Comparação dos valores da ETo diária obtida pelo método de Penman-Monteith (PMT) e os valores preditos por meio do modelo RN-MLP no conjunto de teste.

| | ETo_PMT | ETo_RN-MLP |
|---|---|---|
| [média ± sd] | 3.77±1.69 | 3.78±1.68 |
| [mediana ± iiq] | 3.54±2.36 | 3.53±2.33 |
| [Max - Min] | 8.98 - 0.48 | 8.85 - 0.56 |

De acordo com a análise dos resultados apresentados na tabela 3, é possível verificar que o modelo RN-MLP apresentou em termos das medidas de tendência central valores próximos aos obtidos pelo método de Penman-Monteith (PMT) na determinação da ETo. Apesar do modelo proposto, ter apresentado uma suavização dos valores de maiores

intensidades da ETo. Essa diferença não foi estatisticamente significativamente a nível de 5% (p-valor < 0.05), quando comparados com os valores obtidos pelo método PMT.

Tabela 4 – Desempenho do modelo RN-MLP na predição da ETo diária para o município de Teresópolis no conjunto teste.

| | Erros | | | | |
|---|---|---|---|---|---|
| N° épocas | MAE | MSE | MAPE(%) | RMSE | Índice de Concordância |
| 5957 | 0.081 | 0.114 | 2.578 | 0.106 | 0.996 |

A configuração da rede MLP com duas camadas ocultas e número de neurônios (6,4) nas referidas camadas respectivamente, apresentou índice de concordância (0.996), indicando ótimo desempenho na predição da ETo, quando comparada com o modelo de Penman-Monteith. Analisando os valores dos erros da tabela 4, podemos verificar que o modelo neural proposto apresentou um ótimo desempenho na reprodução dos valores preditos referente a evapotranspiração de referência.

A dispersão da ETo diária no conjunto de teste, estimada pelo método de Penman-Monteith e o modelo computacional estruturado em rede neural MLP, para a estação meteorológica no município de Teresópolis – RJ, está representada na Figura 3.

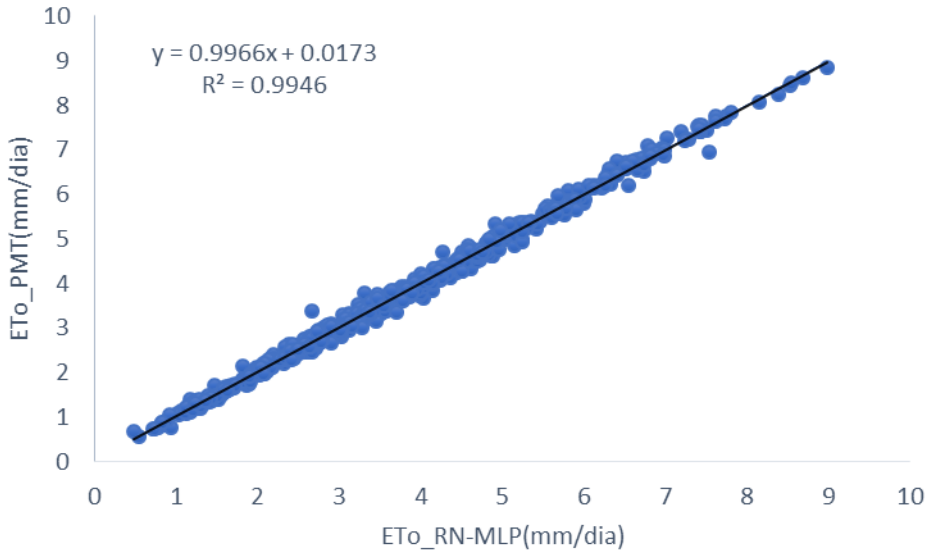



Figura 3- Correlações entre a ETo estimada pelo método PMT e RN-MLP, no conjunto de teste.

Na Figura 3, pode se verificar que o modelo estruturado em inteligência computacional proposto apresentou elevada correlação na estimative da ETo diária no município de Teresópolis-RJ.

## 4 CONCLUSÕES

O presente estudo discute a aplicação e utilidade da abordagem de modelagem de RNA na predição da ETo. Os resultados são bastante encorajadores e sugerem a utilização de técnicas de modelagem baseadas em rede neurais para prever com precisão a evapotranspiração como uma alternativa ao método de Peanman-Moneith.

Além disso, os resultados obtidos na literatura, mostram que as redes neurais se tornaram ferramentas ponderosas para modelagem em vários campos de pesquisa. Elas são capazes de construir, de maneira simples e eficaz modelos precisos e parcimoniosos em termos de número de parâmetros. Entretanto, mesmo com os resultados promissores obtidos com a utilização do modelo computacional proposto na predição da ETo, se faz necessário comparar a eficiência do modelo com outros métodos empíricos.

## AGRADECIMENTOS

A UFRRJ pelo apoio financeiro e ao CPTEC/INPE, pela disponibilização dos dados utilizados.

## REFERÊNCIAS

Abbas, S. A.; Hassan, a. A.; Al-rekabi, w. Estimation of MeanReference Evapotranspiration in Basrah City, Soutth of Iraq Using Fuzzy Logic. In: *Journal of Babylon Univesity/Engineering Sciences/* No. [s.1.]:[s:n], 2017.

Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M. Crop evapotranspiration: Guidelines for computing crop water requirements. Rome: FAO, 1998. 300 p. (FAO – Irrigation and Drainage Paper, 56).

Alves, W. B.; rolim, G. D. S.; Aparecido, l. E. D. O. Reference evapotranspiration forecasting by artificial neural

networks. *Engenharia Agricola*, [s.l.], 2017. ISSN: 18084389, DOI: 10.1590/1809-4430-eng.agric.v37 n.6, p. 1116-1125.

Back, A. J. Variação da evapotranspiração de referência calculada em diferentes intervalos de tempo. Engenharia Agrícola, v.27, p.139-145, 2007.

Braga, A.P.; Carvalho, A.P.L.F; Ludermir, T.B. Redes Neurais Artificiais: Teoria e Aplicações. {s.1]:[s.n], 2000. p.262, Ed. LTC, ISBN: 8521612184.

Celeste, A.; Chaves, V. S. Avaliação de algoritmos de otimização e funções objetivo para calibração automática

do modelo chuva-vazão tank model. *Ciência e Natura*, [s.l.], v. 36, nº 3, 2014. ISSN: 2179-460X, DOI:

10.5902/2179460X13421.

Dong, B.;Dai, A. The uncertainties and causes of the recent changes in global evapotranspiration from 1982 to

2010. *Climate Dynamics*, [s.l.], v. 49, nº 1–2, p. 279–296, 2017. ISSN: 0930-7575, DOI: 10.1007/s00382-016-

3342-x.

Fonseca, J. S.; Martins, G. A.; Toledo, G. L. Estatística Aplicada . Ed. 2, p. 267, 2012.

Haykin, S. Redes Neurais - Principios e Praticas. [s.l.]: [s.n.], 2001. 898 p. ISBN: 8573077182.

Mamak, M., Ünes, F., Kaya, Y.Z., Demirci, M.. Evapotranspiration Prediction Using Adaptive Neuro-Fuzzy Inference System and Penman FAO 56 Equation for St. Johns, FL, USA. In: *Proccedings of 10th International Conference "Environmental Engineering"*. [s.l.]: VGTU Technika, 2017. Disponível em:

<http://enviro.vgtu.lt/index.php/enviro2017/2017/paper/view/438>. ISBN: 978-609-476-044-0, DOI:

10.3846/enviro.2017.085.

Parasuraman, K.; Elshorbagy, A.; Carey, S. K. Modelling the dynamics of the evapotranspiration process using

genetic programming. *Hydrological Sciences Journal*, [s.l.], v. 52, nº 3, p. 563–578, 2007. ISSN: 0262-6667,

DOI: 10.1623/hysj.52.3.563.

Raziei, T.; Pereira, L. S. Estimation of ETo with Hargreaves–Samani and FAO-PM temperature methods for a

wide range of climates in Iran. *Agricultural Water Management*, [s.l.], v. 121 p. 1–18, 2013. ISSN: 03783774,

DOI: 10.1016/j.agwat.2012.12.019.

Trajkovic, S.; kolakovic, S. Evaluation of Reference Evapotranspiration Equations Under Humid Conditions. *Water Resources Management*, [s.l.], v. 23, nº 14, p. 3057–3067, 2009. ISSN: 0920-4741, DOI: 10.1007/s11269-009-9423-4.

Yao Y.; Liang S., Li X.; Chen J.; Liu S.; Zhang X.; Xiao Z.; Fisher J.B.; Mu Q.; Pan M.; Liu M.; Cheng J.; Jiang B.; Xie X.; Grünwald T.; Bernhofer C.; Roupsard O**.** 2017. *Agricultural and Forest Meteorology*, 242 : p. 55-74. DOI: 0.1016/j.agrformet.2017.04.011.