

DETERMINAÇÃO DA EVAPORAÇÃO UTILIZANDO REDES NEURAIS EM CASA DE VEGETAÇÕES

Putti, F. F.¹, Bonini Neto, A.¹, Goes, B. C.¹, Gabriel Filho, L. R. A.¹, Cremasco, C. P.¹

¹ Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Engenharia – FCE - Tupã, SP

Apresentado no
XLVII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2018
06, 07 e 08 de agosto de 2018 - Brasília - DF, Brasil

RESUMO: As redes neurais artificiais (RNA) são sistemas computacionais adaptativos inspirados nas características de processamento de informação semelhante ao neurônio biológico de organismos inteligentes. Com isso a RNA permite produzir saídas adequadas para entradas que não estavam presentes durante o treinamento. Os dados foram coletados em uma casa de vegetação situada na área experimental do Departamento de Engenharia Rural da UNESP, Faculdade Ciências Agrônômicas, localizada no município de Botucatu, São Paulo. No interior da casa de vegetação havia instalado uma estação meteorológica automática, em que a cada 5 segundo coletava os dados de temperatura do ar, umidade relativa, radiação. Assim a partir da coleta dos dados foi calculado a evapotranspiração por meio dos métodos de Pennan-Monteith e Hargreaves-Samani para a determinação da ETo. A RNA utilizada neste trabalho é a retropropagação (*Backpropagation*) composta por duas camadas, camada intermediária e a camada de saída, com treinamento supervisionado. A camada intermediária é composta por 10 neurônios e a camada de saída por 1 neurônio, o qual tem a função de informar a ETo. Pode-se constatar que, a rede tem alcançado os objetivos propostos, e predizendo com maior precisão a ETo para o interior de casa de vegetação.

PALAVRAS-CHAVE: Irrigação, inteligência artificial, eficiência;

DETERMINATION OF EVAPOTRANSPIRATION USING NEURAL NETWORKS IN A GREENHOUSE

ABSTRACT: Artificial neural networks (ANNs) are adaptive computational systems inspired by information processing characteristics similar to the biological neuron of intelligent organisms. With this the RNA allow to produce suitable outputs for inputs that were not present during the training. The data were collected in a greenhouse located in the experimental area of the Department of Rural Engineering of UNESP, Faculdade Agrônômicas, located in the city of Botucatu, São Paulo. Inside the greenhouse had installed an automatic meteorological station, in which every 5 seconds collected the data of air temperature, relative humidity, radiation. Thus, from the data collection, the evapotranspiration was calculated by the methods of Pennan-Monteith and Hargreaves-Samani for the determination of ETo. The RNA used in this work is the backpropagation (*Backpropagation*) composed by two layers, intermediate layer and the output layer, with supervised training. The intermediate layer is composed of 10 neurons and the layer of output by 1 neuron, which has the function of informing ETo. It can be verified that, the network has reached the proposed objectives, and more accurately predicting the ETo to the interior of greenhouse.

KEYWORDS: Irrigation, artificial intelligence, efficiency

INTRODUÇÃO

É de grande importância para muitos países do mundo a produção de alimentos por meio da agricultura irrigada. E devido ao crescimento da população mundial nos últimos anos, houve um aumento da demanda global por alimentos, necessitando um uso mais racional e eficiente dos recursos hídricos (ELSHAIKH; JIAO; YANG, 2018; MÉRIDA GARCÍA et al., 2018). Por sua vez, em decorrência das mudanças climáticas, refletindo no aumento da temperatura do ar e na má distribuição de chuvas, tornou-se aguda a escassez dos recursos hídricos, prejudicando a produção agrícola (ZHAO;

LIU; ZHANG, 2010). Dessa forma, para a eficiente gestão dos recursos hídricos na agricultura, torna-se importante a estimativa precisa da evapotranspiração (ET) durante todos os estágios de crescimento da cultura, evitando o desperdício da água utilizada na irrigação (SRIVASTAVA et al., 2018).

Desta maneira, foram desenvolvidos diferentes métodos para estimar a evapotranspiração das culturas, seja com base em variáveis meteorológicas, sensores de solo, ou por meio do balanço hídrico utilizando os lisímetros de pesagem (JIMÉNEZ-CARVAJAL et al., 2017; SRIVASTAVA et al., 2018).

No entanto, devido ao alto custo dos métodos diretos para determinação da ET, são também utilizados modelos empíricos como Pennan-Monteith, baseado em parâmetro climáticos, que por sua vez são limitados em razão das limitações de várias estações meteorológicas, sendo assim, os fatores mais importantes de utilização nos modelos empíricos de determinação da ET, radiação solar, velocidade do vento e umidade relativa do ar (MOSES; HAMBIRA, 2018; VALIPOUR, 2015).

As redes neurais artificiais (RNA) são modelos que possuem função de auto-organização, adaptativa e de autoaprendizagem, armazenando o conhecimento experimental tornando-o disponível para uso, permitindo saídas adequadas para entradas que não estavam presentes durante o treinamento (GU et al., 2017; KOVACS, 2006). Assim, com a utilização das RNAs para o desenvolvimento de um sistema de irrigação, apurou-se numa economia de 20,46% e de 23,9% de energia (GU et al., 2017; KARASEKRETER; BAŞÇIFTÇI; FIDAN, 2013).

Dessa forma, o objetivo do presente trabalho calcular a evapotranspiração de referência a partir da utilização de redes neurais.

MATERIAL E MÉTODOS:

O experimento foi realizado em casa de vegetação situada na área experimental do Departamento de Engenharia Rural da UNESP, Faculdade Ciências Agrônomicas, Fazenda Experimental Lageado, localizada no município de Botucatu, São Paulo, com localização geográfica definida pelas coordenadas 22° 51' Latitude Sul (S), 48° 26' Longitu de Oeste (W), e altitude de 786m, durante os meses de janeiro a maio do ano de 2013. A temperatura e umidade foram medidas diárias por meio de uma estação automática, a qual foi instalada dentro da estufa.

O modelo de um neurônio artificial pode ser visto na Figura 1.




Figura 1 – Modelo artificial do neurônio biológico.

onde \sum representa o somatório dos produtos das entradas ($x_1, x_2, x_3, \dots, x_n$) pelos respectivos pesos ($w_1, w_2, w_3, \dots, w_n$), ou seja, $u = \sum_{i=1}^n x_i w_i + \text{bias}$, em que bias é usado para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento a ela fornecido e $f(u)$ é a função de ativação para obter a saída. A função de ativação utilizada neste trabalho para a saída de ambas as camadas é a função tangente sigmoide:

$$f(u) = (1 - e^{-\lambda u}) / (1 + e^{-\lambda u}) \quad (1)$$

onde λ é uma constante arbitrária e corresponde a inclinação da curva.

A Figura 2 representa a rede utilizada neste trabalho contendo duas camadas, uma com 10 neurônios e a outra com 1 neurônio.

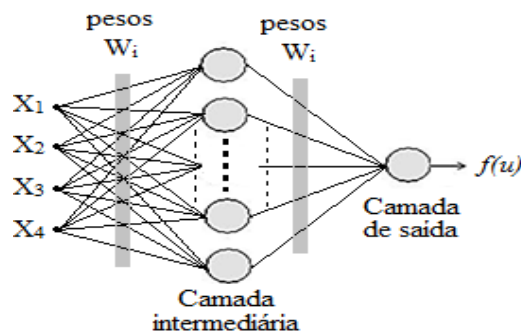


Figura 2 – RNA utilizada neste trabalho.

RESULTADOS E DISCUSSÃO:

Na Figura 3 apresentam os valores obtidos pela rede após o treinamento e comparados com as saídas desejadas. Nota-se que as saídas obtidas são praticamente iguais às saídas desejadas, mostrando mais uma vez o excelente treinamento da rede. Outro aspecto importante que é mostrado na Figura 4 é o erro correspondente a diferença entre o valor desejado e obtido (erro médio de $4,66 \times 10^{-2}$). A Figura 4 apresenta a relação entre os valores obtidos e desejados no processo de treinamento, a equação dos mínimos quadrados e o valor de R, mostrando uma forte relação.

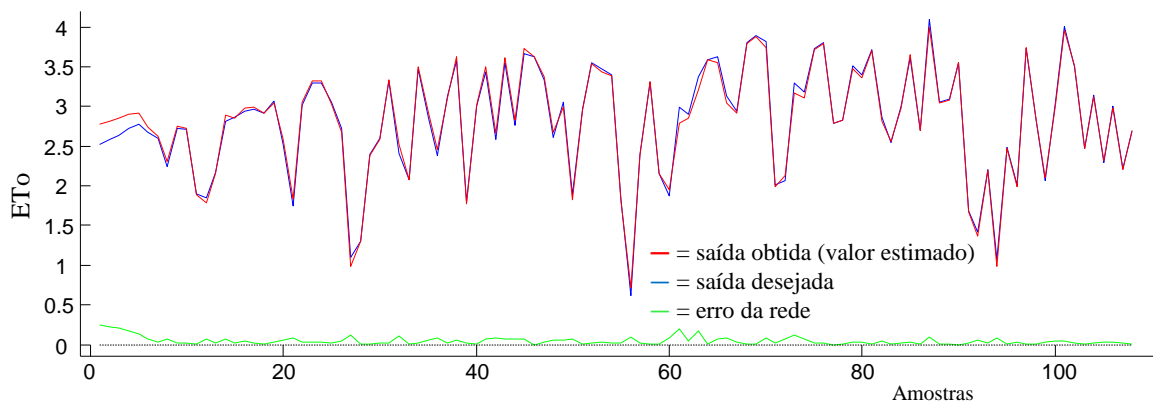


Figura 3 - Processo de treinamento para as 108 amostras.

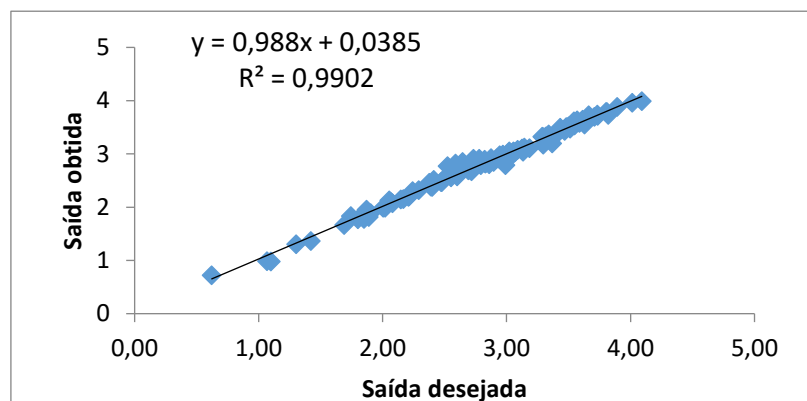


Figura 4 - Relação entre os valores obtidos e desejados, reta dos mínimos quadrados, valor do R^2 .

CONCLUSÕES

Pode-se concluir que o a utilização de redes neurais artificiais possibilita a predição com alto grau de precisão da evapotranspiração de referência. Assim, sendo um método robusto e com baixo erro de previsão.

REFERÊNCIAS

- ELSHAIKH, A. E.; JIAO, X.; YANG, S. Performance evaluation of irrigation projects: Theories, methods, and techniques. **Agricultural Water Management**, v. 203, p. 87–96, abr. 2018.
- GU, J. et al. An improved back propagation neural network prediction model for subsurface drip irrigation system. **Computers & Electrical Engineering**, v. 60, p. 58–65, maio 2017.
- JIMÉNEZ-CARVAJAL, C. et al. Weighing lysimetric system for the determination of the water balance during irrigation in potted plants. **Agricultural Water Management**, v. 183, p. 78–85, mar. 2017.
- KARASEKRETER, N.; BAŞÇIFTÇI, F.; FIDAN, U. A new suggestion for an irrigation schedule with an artificial neural network. **Journal of Experimental & Theoretical Artificial Intelligence**, v. 25, n. 1, p. 93–104, mar. 2013.
- KOVACS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações: Um texto básico**. 4. ed. [s.l.] Livraria da Física, 2006.
- MÉRIDA GARCÍA, A. et al. Coupling irrigation scheduling with solar energy production in a smart irrigation management system. **Journal of Cleaner Production**, v. 175, p. 670–682, fev. 2018.
- MOSES, O.; HAMBIRA, W. L. Effects of climate change on evapotranspiration over the Okavango Delta water resources. **Physics and Chemistry of the Earth, Parts A/B/C**, mar. 2018.
- SRIVASTAVA, R. K. et al. Comparison of actual evapotranspiration of irrigated maize in a sub-humid region using four different canopy resistance based approaches. **Agricultural Water Management**, v. 202, p. 156–165, abr. 2018.
- VALIPOUR, M. Investigation of Valiantzas' evapotranspiration equation in Iran. **Theoretical and Applied Climatology**, v. 121, n. 1–2, p. 267–278, jul. 2015.
- ZHAO, W.; LIU, B.; ZHANG, Z. Water requirements of maize in the middle Heihe River basin, China. **Agricultural Water Management**, v. 97, n. 2, p. 215–223, fev. 2010.