

ISSN 0104-1347

# Diferentes arquiteturas de redes neurais para estimativa da evapotranspiração de referência em Córdoba, Espanha<sup>1</sup>

## Different neural networks architectures for estimating reference evapotranspiration in Córdoba, Spain

Luiz Cláudio Costa<sup>2</sup>, Anderson Francisco da Silva<sup>3</sup>, Brauliro Gonçalves Leal<sup>4</sup>

**Resumo:** A evapotranspiração de referência (ET<sub>o</sub>) é um elemento imprescindível ao estudo do ciclo hidrológico. As redes neurais, como modelo de reconhecimento de padrões, apresentam-se como uma opção à estimativa da ET<sub>o</sub> a partir de variáveis climáticas. Neste trabalho buscou-se comparar resultados de ET<sub>o</sub> obtidos com a modelagem de redes neurais (RN) e com o modelo de Penman-Monteith com ET<sub>o</sub> resultante de medidas lisimétricas de 3 anos de dados. O software livre OpenNet – [www.ufv.br/dea/opennet](http://www.ufv.br/dea/opennet) - foi utilizado para o processamento computacional de 105 RN desenvolvidas neste trabalho. A melhor RN encontrada utiliza a radiação solar, a velocidade do vento e as temperaturas máxima e mínima, como variáveis de entrada e a ET<sub>o</sub> medida como variável saída (estrutura 4-20-20-1), gerando um coeficiente de determinação de 0,9648, um erro padrão de estimativa de 0,4733 mm e um erro percentual médio de 9,9670%, enquanto Penman-Monteith apresentou 0,9130, 0,9530 mm e 15,5032%, respectivamente. Dessa forma, obteve-se melhores ajustes com RN para estimativa de ET<sub>o</sub> que com o método padrão de Penman-Monteith, comparando-se ambas as estimativas aos dados medidos pelo lisímetro para a região de Córdoba na Espanha.

**Palavras-chave:** modelagem, uso racional da água, inteligência artificial.

**Abstract:** The reference evapotranspiration is an indispensable variable for studies about the hydrologic cycle. The neural networks, as a model of pattern recognition, would have the capacity of understanding the climate behavior, being able to estimate ET<sub>o</sub> using climatic variables. The open source software OpenNet - [www.ufv.br/dea/opennet](http://www.ufv.br/dea/opennet) was used for processing the 105 nets developed during this work. The best network found uses solar radiation, wind speed and maximum and minimum temperatures as input, beside the measured ET<sub>o</sub> as output variable (structure 4-20-20-1), generating a coefficient of determination of 0.9648, a standard square error of 0.4733 mm and a percentage error of 9.967%, while Penman-Monteith presented 0.9130, 0.9530 mm and 15.503%, respectively. In that way, the neural networks have shown be more efficient to estimate ET<sub>o</sub> than the conventional method of Penman-Monteith, when both was compared with lysimetric data from Córdoba, Spain.

**Key words:** modeling, rational use of water, artificial intelligence.

<sup>1</sup> Trabalho realizado com auxílio do CNPq

<sup>2</sup> Professor Adjunto IV do Departamento de Engenharia Agrícola UFV – Licenciado em Matemática. M.S. Meteorologia Agrícola. Ph.D. Meteorologia Agrícola, Pesquisador do CNPq. Universidade Federal de Viçosa. (31) 3899-1903 – [l.costa@ufv.br](mailto:l.costa@ufv.br)

<sup>3</sup> Bacharel em Ciência da Computação. M. S. Engenharia Agrícola. Doutorando em Meteorologia Agrícola. Universidade Federal de Viçosa – Meteorologia Agrícola – Campus Universitário CEP 36.570-000. (31) 3899-1859 – [anderson@vicosa.ufv.br](mailto:anderson@vicosa.ufv.br)

<sup>4</sup> Pesquisador do CNPq, Departamento de Engenharia Agrícola, Universidade Federal de Viçosa – (31) 3899-1906 – [brauliro@ufv.br](mailto:brauliro@ufv.br)

## Introdução

O crescente aumento da demanda de água ocorrida nas últimas décadas constitui um dos mais penosos problemas ambientais enfrentados pela humanidade, particularmente pelos habitantes das regiões áridas e semi-áridas do planeta. Na agricultura, a demanda de água está associada à irrigação, cuja estimativa envolve diversos componentes do balanço hídrico, tais como: escoamento superficial, percolação, precipitação e evapotranspiração (ARCA et al., 2001).

A estimativa da umidade do solo, essencial para o entendimento da relação solo-planta-atmosfera depende diretamente da precipitação e da evapotranspiração. Enquanto que a precipitação pode ser medida por pluviômetros, a evapotranspiração exige métodos mais complexos, como por exemplo, os lisímetros ou estimativas dependentes de dados climáticos (ALLEN et al., 1998). Apesar de tais métodos terem ao longo dos anos se mostrado eficientes, existe uma necessidade cada vez maior de se buscar métodos mais precisos e flexíveis de sua estimativa.

Sendo as redes neurais um modelo matemático de reconhecimento de padrões, elas são ferramentas aptas a resolver problemas de cunho geral, tais como aproximação, classificação, categorização e predição. Considerando, ainda, a capacidade das redes neurais em extrair dependências implícitas entre os dados, mesmo quando não existe entendimento da natureza dessas dependências, tal ferramenta vem sendo utilizada com sucesso em diferentes áreas do conhecimento (BRAGA, 2000).

A combinação de dois processos distintos por meio dos quais se perde água (i) pela superfície do solo (devido à evaporação) e, simultaneamente, (ii) pela cultura (devido à transpiração), é referida como evapotranspiração (THORTHWAITE, 1948).

Uma das formas de estimativa de ETo disponível atualmente é por meio da utilização de redes neurais. Uma rede neural é um modelo hierarquizado constituído de unidades de processamento simples, os neurônios, que têm a propensão natural de armazenar informações experimentais e torná-lo disponível para o uso (HAYKIN, 2000). A utilização deste modelo é

cabível principalmente nos casos onde não são conhecidas, ou passíveis de determinação, as correlações existentes entre os diversos fatores integrantes de um sistema complexo.

KUMAR et al. (2002) estudaram a aplicabilidade das redes neurais na estimativa da evapotranspiração de referência e concluíram que elas são capazes de melhor estimar a ETo que o método padrão de Penman-Monteith para Davis - USA, onde os resultados alcançaram maior precisão que os valores calculados, quando confrontados com as medições do lisímetro. Utilizando apenas as temperaturas máxima e mínima como variáveis de entrada das redes, ZANNETTI et al. (2005) obtiveram  $R^2$  próximos a 0,83 na estimativa diária da evapotranspiração calculada por Penman-Monteith para a região do Rio de Janeiro (latitude  $21^{\circ}45'S$ , longitude  $41^{\circ}18'W$  e altitude 11m, Brasil). Estudos realizados por TRAJKOVIC et al. (2003) mostraram também que as redes neurais podem ser utilizadas na previsão da evapotranspiração de referência com alta confiabilidade.

Este trabalho objetiva verificar o potencial das redes neurais na estimativa da evapotranspiração de referência na escala diária para a região de Córdoba, Espanha.

## Materiais e Métodos

Este trabalho foi realizado utilizando os dados gerados no Centro de Investigação e Desenvolvimento Agrário de Córdoba – Espanha, latitude  $38^{\circ}N$ , longitude  $05^{\circ}W$  e altitude 110m.

Foram utilizados dados diários de temperatura média ( $T_m$ ,  $^{\circ}C$ ), temperatura mínima ( $T_n$ ,  $^{\circ}C$ ), temperatura máxima ( $T_x$ ,  $^{\circ}C$ ), umidade relativa média ( $UR_m$ , %), umidade relativa mínima ( $UR_n$ , %), umidade relativa máxima ( $UR_x$ , %), velocidade do vento a 2 m ( $U_2$ ,  $m.s^{-1}$ ) e a radiação solar global ( $R_s$ ,  $MJ.m^{-2}$ ), declinação solar (DecSol, radiano) acrescidas da ETo calculada por Penman-Monteith e da ETo medida pelo lisímetro.

A equação de Penman-Monteith é uma representação mecânica dos fatores físicos e fisiológicos que governam o processo da evapotranspiração (ALLEN et al., 1998). É descrita pela Equação 1:

$$ET_o = \frac{0,408\Delta(Rn-G) + \gamma \frac{900}{T+273} U_2 (es-ea)}{\Delta + \gamma(1+0,34U_2)} \quad (1)$$

em que:  $ET_o$  = evapotranspiração de referência, em  $\text{mm d}^{-1}$ ;  $Rn$  = saldo de radiação diário, em  $\text{MJ m}^{-2}\text{d}^{-1}$ ;  $G$  = fluxo de calor no solo, em  $\text{MJ m}^{-2}\text{d}^{-1}$ ;  $T_m$  = temperatura média diária, em  $^{\circ}\text{C}$ ;  $U_2$  = velocidade do vento à 2m, em  $\text{m s}^{-1}$ ;  $es$  = pressão de saturação do vapor, em kPa;  $ea$  = pressão de vapor, em kPa;  $(es-ea)$  = déficit da pressão de vapor, em kPa;  $D$  = declividade da curva de pressão de vapor, em  $\text{kPa } ^{\circ}\text{C}^{-1}$ ; e  $g$  = constante psicrométrica (=  $0,063 \text{ kPa } ^{\circ}\text{C}^{-1}$ ).

A evapotranspiração de referência foi medida por um lisímetro de balança, de superfície  $2 \times 3 \text{ m}$  e profundidade de 1,5 m, por meio do qual a evapotranspiração de referência era consultada automaticamente de 10 em 10 minutos, ficando registrada a média da última hora.

O período de 01/01/1989 a 30/12/1991 compreende 1094 dias dos quais apenas 425 (38,8%) apresentavam registros completos. Para minimizar possíveis interferências relacionadas ao período de amostragem, os dados disponíveis foram dispostos em ordem aleatória, e posteriormente divididos em 3 partes: 275 para treinamento da rede, 75 para teste e 75 para o uso (dados independentes).

O software OpenNet - [www.ufv.br/dea/opennet](http://www.ufv.br/dea/opennet) (Anderson SILVA et al., 2005) foi utilizado para executar o processamento computacional das redes neurais. O algoritmo RPROP - *Resilient Backpropagation*, com parâmetros recomendados pelos autores RIEDMILLER e BRAUN (1993), realizou o aprendizado durante 5000 épocas, utilizando a função sigmóide logística na ativação dos neurônios. Os pesos sinápticos foram iniciados aleatoriamente entre  $[-0,5; +0,5]$  e, por fim, para todas as redes neurais desse trabalho foram executadas 5 repetições. Este software permite configurar a estrutura da rede neural em termos do número de suas camadas, utilizando a notação [e-h-s] em que e, h e s representam o número de neurônios das camadas de entrada, intermediária e saída, respectivamente; uma rede neural pode possuir várias camadas intermediárias de neurônios. Para efeito deste trabalho, a camada de entrada corresponde à variáveis meteorológicas e a camada de saída refere-se à  $ET_o$ .

Tendo em vista a capacidade das redes neurais em extrair dependências implícitas entre os dados é necessário parametrizá-las para cada caso a estudar. Para a estimativa da  $ET_o$  foram definidas a melhor arquitetura para este tipo de problema (Experimento 1), a quantidade de dados para treinamento da rede (Experimento 2), a melhor combinação das variáveis de entrada (Experimento 3) e avaliação de redes neurais para a estimativa da  $ET_o$  (Experimento 4).

## Resultados e Discussão

### *Experimento 1: Definição da arquitetura*

Inicialmente todas as variáveis disponíveis foram utilizadas para estimar a  $ET_o$  medida pelo lisímetro, para 4 diferentes arquiteturas de rede (1A[9-10-1], 1B[9-10-10-1], 1C[9-20-1] e 1D[9-20-20-1]), todas com 9 neurônios na camada de entrada ( $T_m$ ,  $T_n$ ,  $T_x$ ,  $UR_m$ ,  $UR_n$ ,  $UR_x$ ,  $V_v$ ,  $R_s$  e  $ET_o$  calculada) e um neurônio na camada de saída ( $ET_o$  medida).

Os resultados obtidos no experimento 1 (Tabela 1) demonstram que a variação do número de neurônios e a variação do número de camadas ocultas não promoveram melhores ajustes (coeficiente de determinação  $R^2$  H" 0,95), permitindo que para os experimentos subsequentes fosse utilizada como padrão a estrutura n-20-20-1, em que n é o número de variáveis na entrada.

A Tabela 2 exhibe a época na qual a rede de melhor desempenho foi encontrada. Como a maioria das melhores redes foi encontrada anteriormente à época 4000, a duração padrão de aprendizagem foi estipulada em 5000 épocas.

### *Experimento 2: Teste da Rede e verificação de "overfitting"*

Com o intuito de verificar a ocorrência do fenômeno conhecido como adequação exagerada ou "overfitting", os dados de teste (75) foram divididos em duas partes: Parte 1 (38 dias) e parte 2 (37 dias). Como em todas as repetições desse experimento, os valores de  $R^2$  se aproximavam de 0,95, conclui-se que não houve ajuste excessivo durante o treinamento. A Tabela 3 exhibe para cada rede, o erro acumulado para todos os padrões reservados aos testes da parte 1 e 2.

Pelos resultados obtidos neste experimento, julga-se desnecessária a utilização de testes nos experimentos subsequentes.

*Experimento 3: Teste de diferentes combinações de elementos meteorológicos*

Percebe-se que a radiação foi o elemento climático que mais interferiu na evapotranspiração (Tabela 5), pois se verificou uma queda nos valores de  $R^2$  em relação às outras combinações. Esse fato é confirmado por MELLO (1998), que realizou uma análise de sensibilidade dos componentes da equação de Penman-Monteith.

Embora as redes 3D e 3E do experimento 3 terem se igualado nos valores de  $R^2$ , nota-se que apresentaram comportamentos opostos, tendo uma leve tendência a subestimar ( $y = 0,9961x$ ) e a superestimar ( $y = 1,0023x$ ) a evapotranspiração de referência (Figura 1), respectivamente.

*Experimento 4: Redes neurais para estimativa da ETo*

Analisando os resultados do experimento 3, definiu-se o conjunto de 8 diferentes agrupamentos de elementos que deveriam ser testados como dados de entrada das redes neurais (Tabela 6).

**Tabela 1.** Valores de  $R^2$  para cada repetição do Experimento 1.

Estrutura da Rede	Repetição				
	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
1 <sup>a</sup> 9-10-1	0,9568	0,9567	0,9559	0,9550	0,9587
1B 9-20-1	0,9558	0,9546	0,9571	0,9554	0,9548
1C 9-10-10-1	0,9550	0,9545	0,9574	0,9571	0,9419
1D 9-20-20-1	0,9587	0,9585	0,9578	0,9569	0,9565

**Tabela 2.** Quantidade mínima de épocas para cada repetição do Experimento 1

Estrutura da Rede	Repetição				
	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
1 <sup>a</sup> 9-10-1	2516	2945	4715	4057	3943
1B 9-20-1	4923	2287	4535	3989	3329
1C 9-10-10-1	4568	611	4706	1569	4017
1D 9-20-20-1	855	1629	1027	2357	1437

**Tabela 3.** Erro das redes nas fases de teste: Parte 1 e 2 .



Estrutura da Rede	9-20-20-1	Repetição				
		1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
2A	Parte 1	0,010543	0,010934	0,009801	0,009393	0,010784
2B	Parte 2	0,019864	0,023183	0,019820	0,022097	0,021167

**Tabela 4.** Erro das redes na fase de teste (inversão do teste de validação).

Estrutura da Rede	9-20-20-1	Repetição				
		1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
2C	Teste	0,019369	0,020045	0,021630	0,023301	0,018744
2D	Validação	0,010776	0,011209	0,009917	0,012640	0,009464

Tabela 5. Valores de  $R^2$  para cada rede do Experimento 3.

Variáveis de Entrada exceto	Repetição				
	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
3B Tm	0,9545	0,9426	0,9486	0,9551	0,9539
3C Tn Tx	0,9497	0,9453	0,9550	0,9554	0,9560
3D URm	0,9512	0,8715	0,9554	0,9553	0,9553
3E URn URx	0,9610	0,9565	0,9356	0,9558	0,9488
3F Vv	0,9264	0,9183	0,9326	0,9388	0,9373
3G Rs	0,9321	0,8540	0,9075	0,9034	0,8964

Figura 1. Ajuste da ETo ( $\text{mm d}^{-1}$ ) medida e estimada pelas redes neurais (a) 3D e (b) 3E, ambas do experimento 3.

Observando-se a Tabela 6, verifica-se que a rede 4E ( $R^2$  H<sup>2</sup> 0,95) mostrou-se mais eficiente que a rede 4D ( $R^2$  H<sup>2</sup> 0,94), ou seja, a Tn e Tx promovendo melhores ajustes do que a Tm isoladamente, devido a utilização de mais de um elemento na estimativa de ETo (OBSERVAÇÃO: Penman-Montheith não utiliza temperatura mínima)

Nota-se que a rede 4E apresentou os melhores ajustes, cujo erro mínimo da melhor rede, a época de sua descoberta e o  $R^2$  são exibidos na Tabela 7. Nota-se, ainda, que a 4<sup>a</sup> rede do experimento 4F foi vítima de um mínimo local ( $R^2 = 0,4181$ ), daí a importância das repetições de um mesmo experimento.

Um ajuste excessivo pode ter ocorrido na 4<sup>a</sup> repetição do experimento 4E, pois apesar de apresentar menor erro na fase de teste (0,032981) provocou um pior ajuste na fase de uso ( $R^2 =$

0,9456), ou seja, o aprendizado extra ocorrido no treinamento, que bem se adequou aos dados de teste, diminuiu a capacidade de inferência da rede em relação aos dados de uso. A semelhança entre a época mínima de obtenção da melhor rede nas repetições 3 e 4 (2137) (Tabela 7), e o mesmo  $R^2$  (0,9456) entre as repetições 1 e 4 foram conferidas e são absolutamente casuais.

A Figura 3 compara a ETo medida com os valores gerados pela 3<sup>a</sup> repetição da rede 4E e os valores calculados por Penman-Monteith, ambos para a série completa (425 dias).


O fato do  $R^2$  da série completa (0,9648) (Figura 2) ser superior ao  $R^2$  exclusivo aos dados de uso (0,9506) não surpreende, uma vez que os pesos sinápticos foram ajustados segundo os dados de treinamento e a melhor rede escolhida segundo os dados de teste.

**Tabela 6.** Valores de  $R^2$  para cada rede do Experimento 4.

Variáveis de Entrada	Repetição				
	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>	5 <sup>a</sup>
4 <sup>a</sup> Rs	0,8372	0,8431	0,8449	0,8409	0,8457
4B Rs + Vv	0,8530	0,8537	0,8511	0,8464	0,8387
4C Tm + Tx + Tn + URm + URx + URn	0,8431	0,7863	0,8444	0,8434	0,8610
4D Rs + Vv + Tm	0,9482	0,9461	0,9419	0,9461	0,9501
4E Rs + Vv + Tx + Tn	0,9456	0,9508	0,9506	0,9456	0,9502
4F Rs + Vv + URm	0,9030	0,8971	0,8957	0,4181	0,8864
4G Rs* + Vv + URx + URn	0,8696	0,8799	0,8529	0,8559	0,8687
4H DecSol + Rs* + Vv + Tx + Tn	0,9480	0,9436	0,9441	0,9445	0,9471

**Tabela 7.** Rede 4E (4-20-20-1; Rs, Vv, Tx, Tn)

Repetição	Erro Mínimo do Teste	Época Mínima	$R^2$ na fase de uso
1 <sup>a</sup>	0,037147	1503	0,9456
2 <sup>a</sup>	0,037137	2818	0,9508
3 <sup>a</sup>	0,036461	2137	0,9506
4 <sup>a</sup>	0,032981	2137	0,9456
5 <sup>a</sup>	0,036115	3377	0,9502

**Figura 2.** Ajuste ETo (mm d<sup>-1</sup>) medida e estimada pela (a) rede neural 4E, experimento 4 e (b) Método de Penman-Monteith, ambos com uma série de 425 dias.

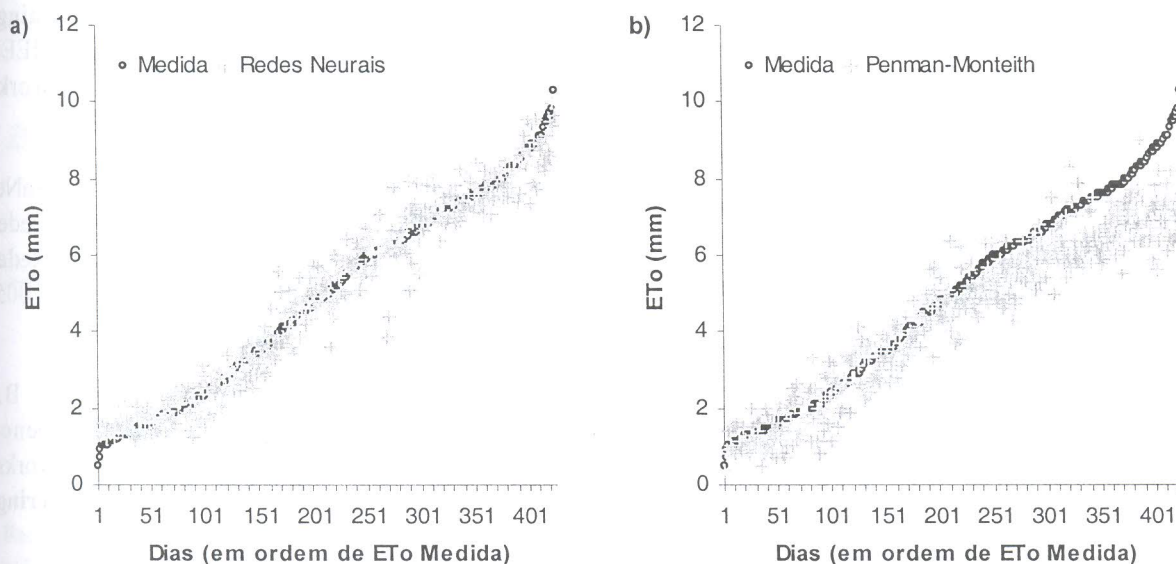


Figura 3. Valores da ETo ( $\text{mm d}^{-1}$ ) (a) estimada pela rede neural 4E, experimento 4 e (b) e medida estimada Método de Penman-Monteith, ambos com uma série de 425 dias.

A Figura 3 exibe a evapotranspiração medida em ordem crescente, acompanhada dos valores estimados pelas Redes Neurais e pela equação de Penman-Monteith. Importante notar que Penman-Monteith apresentou a tendência de subestimar a evapotranspiração de referência medida para valores altos, diferentemente das redes neurais. Subestimativas para valores altos da evapotranspiração de referência podem acarretar subestimativas na necessidade de irrigação e, conseqüentemente, comprometer a produtividade esperada.

### Conclusões

As redes neurais apresentaram melhores ajustes que a equação de Penman-Monteith na estimativa da evapotranspiração de referência quando confrontadas com os dados do lisímetro, para a região de Córdoba, Espanha.

Dentre as 105 redes neurais executadas durante 525.000 épocas, destaca-se a estrutura 4-20-20-1 (Tx, Tn, Vv, Rs), a qual promoveu um coeficiente de correlação de 0,9648, um erro padrão de estimativa de 0,4733 mm e um erro percentual médio de 9,9670%, enquanto o modelo de Penman-

Monteith apresentou 0,9130, 0,9530 mm e 15,5032%, respectivamente.

Apesar dos resultados obtidos indicarem um melhor desempenho das redes neurais, em comparação com o modelo de Penman-Monteith, é importante notar que o uso dessa metodologia para outras localidades requer a execução do processo de treinamento da rede neural, conforme descrito.

Os resultados obtidos estimulam novos estudos sobre a aplicabilidade das redes neurais na estimativa de outras variáveis agrometeorológicas.

### Referência Bibliográfica

ARCA, B., BENINCASA, F., VINCENZI, M. De, Evaluation of neural network techniques for estimating evapotranspiration. EANN – E. A. Neural Networks. 2001.

BRAGA, A. P., LUDEMIR, T. B., CARVALHO, A. C. P. L. F. **Redes neurais artificiais, teoria e aplicações**. Editora LTC - Livros Técnicos e Científicos, Rio de Janeiro, RJ, 1ª Edição, 2000. 323 p.

ALLEN, R.G., PEREIRA, L.S., RAES, D., SMITH, M. **Crop evapotranspiration – guidelines for**

- computing crop water requirements.** Rome: FAO (Irrigation and Drainage Paper 56), 1998, 309 p.
- HAYKIN, S. **Redes neurais - princípios e prática.** Tradução: Paulo Martins Engel, Editora Bookman, Porto Alegre RS, 2ª Edição, 2000. 900 p.
- KUMAR, M. et al. **Estimating evapotranspiration using artificial neural network.** Journal of Irrigation and Drainage Engineering, v.128, n.4, p. 224-233, 2002.
- MANTOVANI, E.C. **Desarrollo y evaluación de modelos para el manejo del riego; estimación de la evapotranspiración y efectos de la uniformidad de aplicación del riego sobre la producción de la cultivos.** Tesis presentada para optar al grado de Doctor Ingeniero Agrónomo. Córdoba, Septiembre 1993.
- MELLO, J.L.P. **Análise de sensibilidade dos componentes da equação de Penman-Monteith-FAO.** 1998. 79 p. Tese (Doutorado em Meteorologia Agrícola) – Curso de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa.
- RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: The RPROP algorithm.** In Proceedings of IEEE International Conference on Neural Networks (ICNN), p. 586-591, San Francisco, 1993.
- SILVA, A.F., LEAL, B.G., COSTA, L.C. **OpenNet – software livre para estudo e prática de redes neurais.** *Revista da Sociedade Brasileira de Redes Neurais: Learning and Nonlinear Models*, 2005. (no prelo).
- TRAJKOVIC, S.; TODOROVIC, B.; STANKOVIC, M. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of Irrigation and Drainage Engineering*, v.129, p. 454, 2003.
- ZANETTI, S. S., SOUSA, E. F., OLIVEIRA, V. P. S., ALMEIDA, F. T. **Estimação da evapotranspiração de referência usando redes neurais artificiais.** In: XXXIV CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA. CD-ROM. Canoas: SBEA, 2005.