

ESTIMAÇÃO DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DO RIO DE JANEIRO USANDO REDES NEURAIS ARTIFICIAIS

SIDNEY S. ZANETTI¹; ELIAS F. SOUSA², DANIEL F. DE CARVALHO³, VICENTE DE PAULO S. DE OLIVEIRA⁴, FREDERICO T. DE ALMEIDA⁵

¹Engº Agrônomo, Doutorando, Bolsista do CNPq - Brasil, Laboratório de Engenharia Agrícola, Centro de Ciências e Tecnologias Agropecuárias, Universidade Estadual do Norte Fluminense, LEAG/CCTA/UENF, Campos dos Goytacazes - RJ, sidney@uenf.br.

²Engº Agrícola, Prof. Doutor, LEAG/CCTA/UENF, Campos dos Goytacazes - RJ, efs@uenf.br.

³Engº Agrícola, Prof. Adjunto, Bolsista do CNPq - Brasil, DE/IT/UFRRJ, Seropédica - RJ, carvalho@ufrj.br.

⁴Engº Agrimensor, Prof. Doutor, Centro Federal de Educação Tecnológica de Campos, Campos dos Goytacazes - RJ, vsantos@uenf.br.

⁵Engº Civil, Prof. Doutor, LECIV/CCT/UENF, Campos dos Goytacazes - RJ, fredterr@uenf.br.

Escrito para apresentação no
XXXV Congresso Brasileiro de Engenharia Agrícola
31 de julho a 4 de agosto de 2006 - João Pessoa - PB

RESUMO: Este trabalho foi realizado com o objetivo de propor uma rede neural artificial (RNA) para estimar a evapotranspiração de referência (ET_o) em função das coordenadas de posição geográfica e da temperatura do ar no Estado do Rio de Janeiro. Os dados utilizados no treinamento da rede foram obtidos de 17 séries históricas de elementos climáticos. A partir das séries históricas foi calculada a ET_o diária pelo método de Penman-Monteith, a qual foi utilizada como referência para treinar as redes. As RNAs, do tipo perceptron de múltiplas camadas (MLP), foram treinadas para estimar a ET_o em função da latitude, longitude, altitude, temperatura média do ar, amplitude térmica e do dia do ano. Após o treinamento com várias configurações de redes, selecionou-se a que apresentou o melhor desempenho, a qual é composta por apenas uma camada intermediária (com vinte neurônios e função de ativação do tipo sigmóide logística) e uma camada de saída (com um neurônio e função de ativação linear). Pelos resultados obtidos na fase de teste da RNA, pôde-se concluir que, levando em consideração apenas as coordenadas de posição geográfica e a temperatura do ar, pode-se estimar a ET_o diária no Estado do Rio de Janeiro.

PALAVRAS-CHAVE: elementos climáticos, inteligência artificial, modelos empíricos.

REFERENCE EVAPOTRANSPIRATION ESTIMATE IN RIO DE JANEIRO STATE USING ARTIFICIAL NEURAL NETWORKS

ABSTRACT: This work was performed with the aim of proposing an artificial neural network (ANN) to estimate the reference evapotranspiration (ET_o) as a function of geographic position coordinates and air temperature in Rio de Janeiro State. Data used for the network training were collected from 18 Historical series of climatic elements. Starting from historical series the ET_o was calculated by Penman-Monteith (FAO-56) method and used as a reference for network training. ANNs of multilayer perceptron type (MLP) were trained to estimate ET_o as a function of latitude, longitude, altitude, average air temperature, thermal amplitude and day of the year. After training with different network configurations the one showing best performance was selected, and was composed by only one intermediary layer (with twenty neurons and sigmoid logistic activation function) and one output layer (with one neuron and linear activation function). According to the results obtained on the test stage we can conclude that, considering only geographical positioning coordinates and air temperature it is possible to estimate daily ET_o in Rio de Janeiro State by using an ANN.

KEYWORDS: climatic elements, artificial intelligence, empirical modeling.

INTRODUÇÃO: As RNAs têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas em várias áreas do conhecimento. Segundo GALVÃO et al. (1999), em função

de sua estrutura não-linear, as RNAs conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais.

A evapotranspiração é um fenômeno complexo e não-linear, pois depende da interação entre os vários elementos climáticos (radiação solar, velocidade do vento, temperatura e umidade do ar) e do tipo e estágio de crescimento da cultura (KUMAR et al., 2002).

Vários autores realizaram trabalhos utilizando RNAs com a finalidade de estimar a evapotranspiração em função de elementos climáticos (ODHIAMBO et al., 2001; KUMAR et al., 2002; SUDHEER et al., 2003; TRAJKOVIC et al., 2003), sendo que todos encontraram resultados satisfatórios, inclusive melhores do que os obtidos com o método convencional de Penman-Monteith (KUMAR et al., 2002). Embora tenham conseguido bons resultados, os autores que utilizaram RNAs para estimar a ETo não se empenharam em simplificar as variáveis de entrada, utilizando, em vários trabalhos, os mesmos dados climáticos requeridos para aplicação do método de Penman-Monteith.

Nesse contexto, e diante da importância da evapotranspiração no manejo da irrigação e na modelagem hidrológica, realizou-se este trabalho com o objetivo de propor uma RNA visando estimar a evapotranspiração de referência em função da temperatura do ar, para o estado de Rio de Janeiro, levando-se em consideração a posição geográfica das estações meteorológicas utilizadas.

MATERIAL E MÉTODOS: Neste estudo foram utilizadas 17 séries históricas de elementos climáticos, compreendidas entre 1961 e 1978. Tais séries foram obtidas de estações meteorológicas do Inmet, localizadas no Estado do Rio de Janeiro (Tabela 1). Os dados utilizados foram: temperatura do ar (máxima e mínima); umidade relativa do ar (máxima e mínima); insolação; e velocidade do vento. A partir desses dados foi calculado a ETo diária pelo método de Penman-Monteith (FAO-56) (ALLEN et al., 1998).

Tabela 1. Estações meteorológicas utilizadas na estimação da evapotranspiração de referência no Estado do Rio de Janeiro

Estação	Nome	Código	Latitude (Sul)	Longitude (Oeste)	Altitude (m)	Nº. de anos de registro
1	Angra dos Reis 83788	02344013	23°04'00"	44°19'00"	2	12,8
2	Bangu 83790	02243141	22°52'00"	43°27'00"	40	7,5
3	Barreirinha 83752	02244017	22°27'00"	44°50'00"	757	14,1
4	Cabo Frio 83747	02242066	22°53'00"	42°01'00"	3	7,6
5	Campos 83698	02141044	21°45'00"	41°20'00"	11	17,9
6	Ecologia Agric. (km 47) 83741	02243186	22°46'00"	43°41'00"	33	17,2
7	Ilha Guafba 83758	02344017	23°01'00"	44°02'00"	64	7,0
8	Itaperuna 83695	02141045	21°12'00"	41°54'00"	124	10,2
9	Nova Friburgo 83745	02242070	22°17'00"	42°32'00"	857	11,3
10	Núcleo Colonial São Bento 83802	02243157	22°44'00"	43°18'00"	6	16,1
11	Pinheiral 83754	02244093	22°31'00"	44°00'00"	385	13,0
12	Piraí 83757	02243165	22°38'00"	43°53'00"	388	7,6
13	Praça XV/Aterro Flamengo 83743	02243129	22°54'00"	43°10'00"	5	18,0
14	Resende 83738	02244092	22°29'00"	44°26'43"	440	18,0
15	Santa Maria Madalena 83696	02142051	21°57'00"	42°01'00"	620	16,0
16	Teresópolis (Parque Nac.) 83806	02242071	22°26'00"	42°59'00"	959	16,7
17	Vassouras 83742	02243151	22°25'00"	43°40'00"	437	16,2

Na obtenção do modelo para estimar a ETo, uma rede neural foi projetada utilizando as seguintes variáveis de entrada: latitude, longitude, altitude, temperatura média do ar, amplitude térmica e data juliana. A temperatura média do ar e a amplitude térmica foram obtidas a partir da média e da diferença entre as temperaturas máxima e mínima do ar, respectivamente. Portanto, o modelo proposto demanda somente dados diários das temperaturas máxima e mínima do ar para estimar a ETo, já que as demais variáveis são características espaciais e temporais facilmente obtidas.

Utilizou-se uma RNA do tipo perceptron de múltiplas camadas (MLP, *multilayer perceptron*). Nesse tipo de rede o sinal de entrada se propaga para frente (*feedforward*), camada por camada, sendo em

seguida, retropropagado para a correção do erro (ajuste dos pesos sinápticos). Esse procedimento é repetido por várias iterações até a finalização do treinamento.

A RNA foi treinada de forma supervisionada com o algoritmo de Levenberg-Marquardt, o qual utiliza, para aproximação do mínimo da função de erro (Equação 1), o método de Newton.

$$EQM = \frac{\sum_{i=1}^n (Y_o - Y_e)^2}{n} \quad (1)$$

em que EQM = erro quadrado médio (mm/dia)²; n = número de observações; Y_o = ETo estimada pelo método de Penman-Monteith, mm/dia; e Y_e = ETo estimada pela rede neural artificial, mm/dia.

Visando selecionar uma RNA que proporcionasse o melhor desempenho, foi feito um estudo prévio, no qual foram realizados vários testes, variando-se o número de camadas intermediárias, bem como o número de neurônios e a função de ativação nas camadas. Para cada combinação dessas características a rede foi treinada e testada, possibilitando a escolha da melhor RNA para estimar a ETo. A camada de saída da rede foi predefinida com apenas um neurônio e função de ativação do tipo linear.

Após o processo de treinamento da RNA e, utilizando o conjunto de dados destinado para teste da mesma (13.806 observações), os valores de ETo foram estimados com a rede neural e comparados com os valores de ETo calculados pelo método de Penman-Monteith.

Para cada estação foi realizada uma regressão linear simples ($Y = \beta_0 + \beta_1.X$), sendo considerado como variável dependente os valores de ETo calculados pelo método de Penman-Monteith e como variável independente os valores de ETo estimados com a rede neural. Os resultados foram analisados por meio dos parâmetros (β_0 e β_1) das equações e pelo coeficiente de determinação (r^2) das regressões. O teste “t” foi utilizado para avaliar estatisticamente o valor do intercepto ($H_0: \beta_0 = 0$) e da inclinação da reta ($H_0: \beta_1 = 1$), em nível de 1% de probabilidade.

Adicionalmente, visando quantificar o grau de ajustamento entre os valores observados e estimados, foi calculado o índice de desempenho (c) proposto por CAMARGO & SENTELHAS (1997), o qual é resultante da multiplicação entre o índice de concordância proposto por WILLMOTT (1981) e o coeficiente de correlação de Pearson. O índice c é um valor adimensional, variando entre 0 e 1, sendo que o valor 1 representa o completo ajustamento, enquanto que o valor 0 indica o oposto.

RESULTADOS E DISCUSSÃO: A RNA escolhida, ou seja, a que apresentou melhor desempenho com a mínima configuração possível, é constituída por uma camada de entrada (com seis variáveis), uma camada intermediária (com vinte neurônios) e uma camada de saída (com um neurônio). O fato da rede escolhida, que apresentou melhor desempenho, ter apenas uma camada intermediária está de acordo com os resultados encontrados por KUMAR et al. (2002), pois esses autores concluíram que uma RNA com apenas uma camada intermediária é suficiente para representar a relação não-linear entre os elementos climáticos e a correspondente ETo.

Para os neurônios da camada intermediária foi adotada a função de ativação sigmóide logística, pois esta proporcionou melhores resultados.

Na Tabela 2 estão apresentados os indicadores estatísticos do ajuste entre os valores de ETo calculados pelo método de Penman-Monteith e os estimados pela rede neural artificial para cada uma das 17 estações meteorológicas consideradas.

Os parâmetros β_0 e β_1 obtidos para ambas as localidades não diferiram estatisticamente de 0 e 1, respectivamente. Isso permite inferir que a ETo estimada pela rede neural não diferiu estatisticamente da ETo calculada pelo método de Penman-Monteith.

A qualidade do ajuste pode ser confirmada ainda pelos altos valores do índice de desempenho (c). Para as diferentes localidades o desempenho variou entre “Bom” (c = 0,675) e “Ótimo” (c = 0,880), de acordo com o critério de interpretação proposto por CAMARGO & SENTELHAS (1997).

Pode-se observar, pelos resultados apresentados na Tabela 2, que o modelo baseado na rede neural artificial foi eficiente para estimar a ETo, possibilitando bom desempenho para realizar extrapolações.

Sob o ponto de vista prático, a grande vantagem do método proposto no presente estudo (rede neural) está na utilização de registros diários das temperaturas máxima e mínima do ar, fato que possibilita estimar a ETo com a simples utilização de um termômetro de máxima e de mínima.

Tabela 2. Indicadores estatísticos do ajuste entre os valores de ETo estimada por Penman-Monteith e ETo estimada pela rede neural

Estação	β_0	β_1	r^2	n	EQM (mm/dia) ²	c
1	-0,013	1,004	0,7289	704	0,4	0,782
2	0,247	0,925	0,7548	441	0,5	0,808
3	0,028	0,999	0,8222	812	0,4	0,861
4	-0,085	1,019	0,6176	451	0,6	0,682
5	-0,150	1,033	0,7111	1053	0,9	0,765
6	-0,066	1,030	0,7633	1025	0,9	0,810
7	-0,073	1,016	0,6243	378	1,2	0,689
8	-0,093	1,016	0,7799	591	0,5	0,825
9	0,207	0,930	0,6363	666	0,4	0,706
10	-0,092	1,026	0,8061	922	0,4	0,846
11	-0,019	1,018	0,7970	773	0,4	0,839
12	-0,011	0,989	0,7573	398	0,4	0,807
13	-0,155	1,025	0,6324	1047	0,8	0,696
14	-0,196	1,046	0,6125	1104	0,9	0,675
15	-0,041	1,018	0,8240	939	0,3	0,861
16	-0,024	1,002	0,8466	985	0,2	0,880
17	0,111	0,966	0,6852	954	0,7	0,747

CONCLUSÕES: A evapotranspiração de referência, no estado do Rio de Janeiro, pode ser estimada com segurança utilizando redes neurais artificiais, a partir de dados de temperaturas máxima e mínima do ar e das coordenadas de posição geográfica do local (latitude, longitude e altitude).

REFERÊNCIAS BIBLIOGRÁFICAS:

- 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).
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. *Revista Brasileira de Agrometeorologia*, Santa Maria, v.5, n.1, p.89-97, 1997.
- GALVÃO, C. O., VALENÇA, M. J. S., VIEIRA, V. P. P. B., DINIZ, L. S., LACERDA, E. G. M., CARVALHO, A. C. P. L. F, LUDERMIR, T. B. *Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais*. Porto Alegre: UFRGS/ABRH, 246 p. 1999.
- KUMAR, M.; RAGHUWANSHI, N. S.; SINGH, R.; WALLENDER, W. W.; PRUITT, W. O. Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, v.128, n.4, p. 224-233, 2002.
- ODHIAMBO, L. O.; YODER, R. E.; YODER, D. C.; HINES, J. W. Optimization of fuzzy evapotranspiration model through neural training with input-output examples. *Transactions of the ASAE*, v.44, n.6, p. 1625-1633, 2001.
- SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of Irrigation and Drainage Engineering*, v.129, n.3, p. 214-218, 2003.
- TRAJKOVIC, S.; TODOROVIC, B.; STANKOVIC, M. Forecasting of Reference Evapotranspiration by Artificial Neural Networks. *Journal of Irrigation and Drainage Engineering*, v.129, n.6, p. 454-457, 2003.
- WILLMOTT, C. J. On the validation of model. *Physical Geography*, v.2, n.2, p.184-194, 1981.