

ESTIMATIVA DE EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO REDES NEURAIS ARTIFICIAIS PARA O ESTADO DO RIO GRANDE DO SUL

ESTIMATING EVAPOTRANSPIRATION USING ARTIFICIAL NEURAL NETWORKS FOR THE STATE OF RIO GRANDE DO SUL

Rafael Camargo Ferraz

Resumo: A evapotranspiração de referência (ET_o) é um fenômeno complexo e não-linear, pois depende da interação entre os vários elementos climáticos. Propor uma rede neural artificial (RNA) para estimar a ET_o em função de dados climáticos e coordenadas geográficas no Estado do Rio Grande do Sul, motivou a realização do presente estudo. Os dados utilizados no treinamento da rede foram obtidos de 35 estações meteorológicas do Instituto Nacional de Meteorologia, localizadas nesse Estado. A ET_o diária calculada pelo método de Penman-Monteith (FAO-56) foi utilizada como referência para treinar as redes. As RNAs, do tipo perceptron de múltiplas camadas, foram treinadas para estimar a ET_o em função da latitude, longitude, altitude, dia do ano, temperatura máxima diária, temperatura mínima diária, umidade relativa do ar média diária, velocidade do vento, ocorrência de precipitação, radiação solar global incidente diária, duração de brilho solar diário e déficit de saturação do ar. Após o treinamento com várias configurações de rede, pode-se observar que todas as arquiteturas apresentaram índice de desempenho entre 0,85 a 0,8819, classificado como ótimo. Pelos resultados obtidos conclui-se que as RNAs são ferramentas poderosas para estimativa de evapotranspiração, principalmente ao acrescentarmos dados climáticos e espaciais.

Palavras-chave: Penman-Monteith, Backpropagation, inteligência artificial

Abstract: The reference evapotranspiration (ET_o) is a complex phenomenon and non-linear as it depends on the interaction between the various climatic elements. Propose an artificial neural network (ANN) for estimating ET_o due to climatic data and geographic coordinates in the state of Rio Grande do Sul, motivated the present study. The data used for the network training were obtained from 35 weather stations of the National Institute of Meteorology, in that State. The ET_o calculated by the Penman-Monteith (FAO-56) was used as a reference for network training. ANNs type multilayer perceptron, have been trained to estimate ET_o in function of latitude, longitude, altitude, day of the year, daily maximum temperature, daily minimum temperature, relative humidity average daily wind speed, occurrence of precipitation, solar radiation incident daily duration of sunshine daily and saturation deficit of the air. After training with various network configurations, it can be observed that all the architectures presented performance index between 0.85 to 0.8819, classified as great. From the results obtained it was concluded that the RNA's are powerful tools for estimating evapotranspiration, primarily to add climate data and spatial.

Keywords: Penman-Monteith, Backpropagation, artificial intelligence

1 INTRODUÇÃO

O conhecimento da evapotranspiração de referência (ET_o) é de fundamental importância em diversas áreas, como por exemplo, em atividades ligadas a gestão de bacias hidrográficas, em modelagem meteorológica e hidrológica e, sobretudo, no manejo hídrico da agricultura irrigada. Vários modelos de balanço hídrico de cultura utilizados no dimensionamento e planejamento de sistemas de irrigação necessitam das informações de evapotranspiração de referência como variável de estudo.

A Food and Agriculture Organization of United Nations (FAO) recomenda o método de Penman-Monteith (Allen *et al* 1998), porque ele produz resultados mais realistas (Saidati e Samuel 2006; Hazrat e Lee 2006), no entanto, esta abordagem tem sido muito criticado devido à sua exigência de um número elevado de parâmetros meteorológicos que normalmente não estão disponíveis na maioria das estações meteorológicas.

De acordo com Pereira *et al* (2002), a escolha de um método para se estimar a evapotranspiração depende de uma série de fatores, em que um deles é a disponibilidade de

dados meteorológicos, visto que os métodos mais complexos que exigem grande número de variáveis somente têm aplicabilidade quando há disponibilidade de todos os dados necessários.

Para Amatya *et al* (1992), nenhum método específico de estimativa de ETo tem sido adequado para todas as condições climáticas e locais, o que a pesquisa procura é aplicar o método que melhor corresponda à realidade de cada local.

Algumas abordagens alternativas baseadas em redes neurais artificiais (RNAs) foram utilizadas para estimar a evapotranspiração de referência (Odhiambo *et al* 2001;. Sudheer *et al* 2003;. Trajkovic *et al* 2003;.. Zanetti *et al* 2008). A evapotranspiração é um fenômeno complexo e não-linear, pois depende da interação entre os vários elementos climáticos, tais como radiação solar, velocidade do vento, temperatura e umidade do ar (KUMAR *et al*, 2002).

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. Para Sudheer *et al* (2003), a maior vantagem das RNAs sobre os métodos convencionais é que elas não requerem informação detalhada sobre os processos físicos do sistema a ser modelado, sendo este descrito explicitamente na forma matemática (modelo de entrada-saída).

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 com base em conjuntos de dados climáticos com variáveis limitadas e coordenadas geográficas, para o Estado do Rio Grande do Sul.

2 MATERIAIS E MÉTODOS

Neste estudo foram utilizadas 35 séries históricas de elementos climáticos compreendidos entre 2008 a 2012, obtidas de estações meteorológicas do Instituto Nacional de Meteorologia (INMET) localizadas no Estado do Rio Grande do Sul. (Figura 1).




Figura 11. Distribuição espacial das estações automáticas no Rio Grande do Sul
Fonte: Rafael Camargo Ferraz.

A evapotranspiração de referência utilizada como padrão foi estimada pelo método de Penman-Monteith com base na equação 1:

$$ET_o = \frac{0,408\Delta(R_n - G) + y \frac{900}{(T_{med} + 273)} U_2 (e_s - e_a)}{\Delta + y(1 + 0,34U_2)} \quad (1)$$

Em que: ET_o – evapotranspiração de referência (mm.d^{-1}); Δ – declividade da curva de pressão de vapor na saturação versus temperatura do ar ($\text{kPa}^\circ\text{C}^{-1}$); R_n – saldo de radiação na superfície do cultivo ($\text{MJ m}^{-2}\text{d}^{-1}$); G – densidade de fluxo de calor no solo ($\text{MJ m}^{-2}\text{d}^{-1}$); y – constante psicrométrica ($\text{kPa}^\circ\text{C}^{-1}$); U_2 – velocidade do vento a 2 metros de altura (m s^{-1}); e_s – pressão de vapor na saturação (kPa); e_a – pressão de vapor atual (kPa); T_{med} – temperatura média do ar tomada a 2m de altura ($^\circ\text{C}$).

2.1 ARQUITETURA E MODELAGEM DAS REDES NEURAS ARTIFICIAIS

Utilizou-se uma Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas (MLP) com o algoritmo de treinamento backpropagation com otimização de Levenberg-Marquardt, sendo considerada uma rede de aprendizado supervisionado. 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); este procedimento é repetido durante várias iterações até a finalização do treinamento.

Na obtenção do modelo para estimar a ET_o , projetou-se uma rede neural através das seguintes variáveis de entrada: latitude ($^\circ$), longitude ($^\circ$), altitude (m), dia do ano (dia), temperatura máxima diária ($^\circ\text{C}$), temperatura mínima diária ($^\circ\text{C}$), umidade relativa do ar média diária (%), velocidade do vento (m.s^{-1}) e ocorrência de precipitação (sim ou não). Além

das entradas disponíveis, foram estimadas as variáveis: radiação solar global incidente diária ($\text{MJm}^{-2}\text{d}^{-1}$), duração de brilho solar diário (h) e déficit de saturação do ar (kPa).

Na ocorrência de precipitação foram utilizados os valores 1 para os dias que foram registrados a incidência de chuva e 0 para dias sem precipitação. Estes valores são baseados na programação binária, no qual corresponde 1 para sim e 0 para não (ou nulo). Os dados de entradas foram normalização através da transformação linear, descrita na equação 2:

$$y = \frac{(b - a)(x_i - x_{\min})}{x_{\max} - x_{\min}} + a \quad (2)$$

Sendo que: a e b são limites de normalização, adotado -1 e 1 respectivamente, x_i são os valores a serem normalizados, $x_{\min}$ é o valor mínimo do banco de dados e $x_{\max}$ é o valor máximo dos dados.

Os modelos de redes foram determinados pelas variáveis de entradas e identificados por “ANN”. Na Tabela 1 estão dispostos os 10 (dez) modelos definidos.

Tabela 1. Modelos de arquiteturas de redes neurais e suas variáveis de entrada

Modelo	Entrada	Variáveis											
		Lat	Lon	Alt	DA	Tmin	Tmax	UR	VV	P	Ro	N	Δe
		(°)	(°)	(m)	(dia)	(°C)	(°C)	(%)	(m.s^{-1})	(s/n)	($\text{MJm}^{-2}\text{d}^{-1}$)	(h)	(kPa)
ANN1	7	•	•	•	•	•	•	•					
ANN2	8	•	•	•	•	•	•	•	•				
ANN3	9	•	•	•	•	•	•	•	•		•		
ANN4	10	•	•	•	•	•	•	•	•		•	•	
ANN5	11	•	•	•	•	•	•	•	•		•	•	•
ANN6	12	•	•	•	•	•	•	•	•	•	•	•	•

Lat – latitude; Lon - longitude; Alt - altitude; DA - dia do ano; $T_{\min}$ - temperatura mínima diária; $T_{\max}$ - temperatura máxima diária; UR - umidade relativa do ar média diária; VV - velocidade do vento; P - ocorrência de precipitação; Ro - radiação global incidente diária; N - duração de brilho solar diário e Δe - déficit de saturação do ar.

Para obter o melhor modelo de rede neural artificial para estimar a evapotranspiração de referência, foram estruturadas diferentes arquiteturas de rede, alterando as variáveis de entradas, número de neurônios na camada oculta e função de ativação.

As variações utilizadas no trabalho podem ser observadas no esquema estrutural ilustrado na Figura 2.




Figura 2. Arquitetura de redes com função de ativação sigmoide logística (a) e tangente hiperbólica (b)

Para cada modelo de rede foram testadas diferentes arquiteturas, variando o número de neurônios na camada intermediária entre 10 e 50, com intervalo de 5 por rede. Além dos

neurônios, foram utilizados duas funções de ativação, tangente hiperbólica e sigmoide logística na camada escondida. 29

Os dados diários das estações foram agrupados em planilha eletrônica, obtendo-se um conjunto com 35.775 observações diárias. Destes, foram derivados dois subconjunto: o primeiro, com 80% das observações, destinou-se para o treinamento da rede e o segundo, com 20% dos dados, foi utilizado para testar e validar o seu desempenho. As linhas do arquivo contendo os dados foram submetidas a uma aleatorização visando eliminar qualquer influência do ordenamento dos dados no referido processo.

2.2 AVALIAÇÃO DOS RESULTADOS

A análise dos dados foi realizada através da regressão linear ($y = a + bx$) onde x representa os valores de evapotranspiração estimados pelo Método de Penman-Monteith e y representa os valores estimados.

A determinação da raiz quadrada do erro médio aplicou-se a equação 2:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (2)$$

Sendo que E_i é o valor de evapotranspiração de referência estimada, O_i é o valor padrão determinado por Penman-Monteith e n o número de observações.

Adicionalmente e visando quantificar o grau de ajustamento entre os valores observados e estimados, calculou-se 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 o valor 0 indica o oposto.

3 RESULTADOS

Visando selecionar uma RNA que proporcionasse o melhor desempenho, foram definidos 6 modelos em relação a suas variáveis de entrada e posteriormente alternadas a arquitetura das redes, variando-se o número de neurônios e a função de ativação nas camadas de entrada. Para cada modelo foi selecionada a arquitetura que apresentou melhor resultado.

Apresentam-se, na Tabela 2, os indicadores estatísticos da comparação os valores de ETo calculados pelo método de Penman-Monteith (valores observados) e os estimados pela rede neural artificial (valores estimados).

Tabela 2. Arquitetura de rede para cada modelo, média, desvio padrão, raiz do erro médio quadrático (RMSE) e coeficiente de determinação (R^2).

Modelo	Função de Ativação	Arquitetura	Média	Desvio Padrão	RMSE	R^2
ANN1	Sigmoide Logística	7-50-1	3,9359	1,4355	0,5874	0,8560
ANN2	Sigmoide Logística	8-45-1	3,9274	1,4523	0,5315	0,8821
ANN3	Sigmoide Logística	9-50-1	3,9272	1,4488	0,5320	0,8818
ANN4	Sigmoide Logística	10-50-1	3,9275	1,4522	0,5249	0,8850
ANN5	Sigmoide Logística	11-50-1	3,9354	1,4586	0,5373	0,8795
ANN6	Tangente Hiperbólica	12-45-1	3,925	1,452	0,538	0,879

Com base na Tabela 2, pode-se observar que os resultados obtidos pelas redes neurais artificiais apresentaram índice de determinação (R^2) entre 0,8560 e 0,8850, quando comparado com os valores observados. Os autores Sobrinho *et al* (2011), ao comparar modelos de redes neurais e método empíricos, também afirmam que as RNAs apresentam desempenhos superiores e baixo erro médio quadrático, afixando entre 0,016 e 0,496%.

A qualidade do ajuste pode ser confirmada ainda pelos altos valores do índice de desempenho, conforme demonstrado na Tabela 3.

Tabela 3. Melhor arquitetura de rede para cada modelo, coeficiente de correlação (r), índice de concordância (c), índice de desempenho (Id) e classificação.

Modelo	Função de Ativação	Arquitetura	R	C	Id	Desempenho
ANN1	Sigmoide Logística	7-50-1	0,9252	0,9226	0,8535	Ótimo
ANN2	Sigmoide Logística	8-45-1	0,9392	0,9373	0,8803	Ótimo
ANN3	Sigmoide Logística	9-50-1	0,9391	0,9370	0,8799	Ótimo
ANN4	Sigmoide Logística	10-50-1	0,9407	0,9388	0,8832	Ótimo
ANN5	Sigmoide Logística	11-50-1	0,9378	0,9362	0,8780	Ótimo
ANN6	Tangente Hiperbólica	12-45-1	0,938	0,936	0,877	Ótimo

Para os diferentes modelos, o desempenho variou entre 0,8535 a 0,8832, classificando-se como ótimo, de acordo com o critério de interpretação proposto por Camargo & Sentelhas (1997). O modelo ANN1 apresentou o menor desempenho. Esse fator pode estar relacionado no baixo número de variáveis de entrada. Para Zanetti *et al* (2008), ao realizar a estimativa utilizando apenas temperatura, amplitude térmica e dados locais, determinaram um índice de desempenho de 0,88, afirmando que a grande vantagem desse modelo é utilização de poucas variáveis, necessitando apenas um termômetro de máxima e mínima para a determinação.

Do ponto de vista prático, e com base no trabalho desenvolvido por Zanetti *et al* (2007), a grande vantagem do método proposto no presente estudo (rede neural artificial) 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.

4 CONCLUSÕES

O presente estudo aborda a aplicação e utilização modelagem de redes neurais artificiais na previsão de evapotranspiração de referência. Os resultados apresentaram ótimo em todas as arquiteturas de redes, no qual o possibilita a utilização de técnicas de modelação com base na rede neural artificiais como uma alternativa ao método de Penman-Monteith, principalmente em situações em que não há disponibilidade de dados climáticos. Ainda é possível concluir que o número de variáveis de entrada apresenta pouca influência na definição do resultado, pois todas as redes ficaram com ótimo desempenho. Essas características, auxiliam na redução do custo para a obtenção dos valores de evapotranspiração de referência.

AGRADECIMENTOS

Os autores expressam seus agradecimentos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq, pelo auxílio financeiro concedido para a realização do trabalho.

- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. Crop evapotranspiration - guidelines for computing crop water requirements. Rome: FAO, 1998. 300p. Irrigation and Drainage Paper: 56.
- AMATYA, D. M.; SKAGGS, R. W.; GREGORY, J. D. Comparison of methods for estimating potential evapotranspiration. St. Joseph: ASABE, 1992. 27 p.
- CAMARGO, A. P.; SENTELHAS, P. B.; Avaliação do desempenho de diferentes métodos de estimativas de evapotranspiração potencial no Estado de São Paulo, Brasil. Revista Brasileira de Agrometeorologia, v.5, n.1, p. 89-97, 1997.
- GALVÃO, C. O.; *et al* Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais. Porto Alegre: UFRGS/ABRH, 1999. 246p.
- HAZRAT MA, LEE TS. Potential evapotranspiration model for Muda. Irrigation project, Malaysia. Water Resour Managv. 23, p. 57–69, 2006.
- 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.
- PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C.; FOLEGATTI, M.V.; NOVA, N. A. V.; MAGGIOTTO, S. R.; PEREIRA, F. A. C. Substantiation of the day FAO-56 reference evapotranspiration with data from automatic and conventional weather stations. Revista Brasileira de Agrometeorologia, v.10, n.2, p.251, 2002.
- SAIDATI B, SAMUEL P. Evapotranspiration de référence dans la région aride de Tafilalet au sud-est du Maroc. AJEAM-RAGEE v. 11, p.1–16, 2006.
- SOBRINHO, T. A.; RODRIGUES, D. B.B.; OLIVEIRA, P. T. S.; REBUCCI, L. C. S.; PERTUSSATTI, C. A. Estimativa da evapotranspiração de referência através de redes neurais artificiais. Revista Brasileira de Meteorologia, v. 26, n. 2, p. 197-203, 2011.
- 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.
- ZANETTI, S. S.; SOUSA, E. F. CARVALHO, D. F.; BERNARDO, S. Estimção da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. Revista Brasileira de Engenharia Agrícola e Ambiental, v.12, n.2, p.174-180, 2008.