

EVAPOTRANSPIRAÇÃO DE REFERÊNCIA EM PIRACICABA-SP: II. AVALIAÇÃO DE MODELOS BASEADOS EM REDES NEURAS ARTIFICIAIS

ANDREA I. IRIGOYEN¹, LUIZ R. ANGELOCCI²,
DERBLAI CASAROLI³, ALEXANDRE BARROS⁴

¹Eng. Agrônoma, M. Sc., Facultad de Ciencias Agrarias, UNMdP, Balcarce, Argentina, doutoranda do Programa de Física do Ambiente Agrícola ESALQ-USP, Piracicaba-SP, airigoyen@balcarce.inta.gov.ar

²Eng. Agrônomo, Prof. Associado, Depto. Ciências Exatas, ESALQ, USP, Piracicaba-SP, bolsista CNPq

³Eng. Agrônomo, M. Sc.; Dr. Faculdade de Agronomia, Zootecnia e Engenharias, UNIPAM

⁴Eng. Agrônomo, M. Sc., doutorando do Prog. Física do Ambiente Agrícola ESALQ-USP, Piracicaba-SP.

Apresentado no XVI Congresso Brasileiro de Agrometeorologia
- 22 a 25 de setembro de 2009 - GranDarrell Minas Hotel, Eventos e Convenções, Belo Horizonte, MG

RESUMO: Diferentes arquiteturas de redes neurais artificiais (RNAs) tipo “*multiperceptron*”, foram avaliadas pela sua capacidade de estimar a evapotranspiração de referência para a localidade de Piracicaba, quando não disponíveis todas as variáveis requeridas pelo modelo padrão Penman-Monteith. O treinamento foi de tipo supervisionado, sob algoritmo conjugado de propagação de erros, utilizando como variável de saída desejada a evapotranspiração de referência estimada pelo método Penman-Monteith (ET_{OPM}) na escala diária. Radiação global (R_g), saldo de radiação (R_n) e radiação extraterrestre (RTA) foram alternadamente combinadas nas entradas com temperatura média diária (T_{ar}), déficit de pressão de vapor médio diário (DPV), velocidade do vento média diária (u). Bom desempenho foi mostrado pelas RNAs quando consideradas R_n ou R_g na entrada. Os índices de desempenho melhoraram quando comparados aos obtidos com modelos baseados em regressão.

Palavras-Chave: método de Penman-Monteith, modelagem, *multiperceptron*.

REFERENCE EVAPOTRANSPIRATION IN PIRACICABA-SP: II. EVALUATING MODELS ON ARTIFICIAL NEURAL NETWORKS BASIS

ABSTRACT: This study evaluated the performance of multilayer perceptron neural networks with different combinations of meteorological inputs for estimating reference evapotranspiration. Daily evapotranspiration values, calculated following the Penman-Monteith equation (ET_{OPM}), were used as training patterns for the implementation of neural networks. Data of global radiation (R_g), net radiation (R_n) or extraterrestrial radiation (RTA) were alternated in combinations with air temperature (T_{ar}), vapor pressure deficit (DPV) and wind velocity (u) variables as inputs to networks. The RNAs with best performance for each combination of inputs were retained. The performances of different models were evaluated based on multi-criteria analysis. According to the results, it can be concluded that it is possible to estimate accurately daily ET_{OPM} values. Performance index improved when compared to those obtained with regression models basis.

Key-words: Penman-Monteith method, modelling, *multiperceptron*.

INTRODUÇÃO: As Redes Neurais Artificiais (RNAs) são modelos matemáticos que se assemelham às estruturas neurais biológicas e que têm capacidade computacional adquirida por meio de aprendizado e generalização (BRAGA et al., 2007). Em virtude da capacidade de resolver, basicamente, problemas de aproximação, predição, classificação, categorização e

otimização, as técnicas de modelagem baseadas em RNAs têm sido adotadas com entusiasmo na área de recursos hídricos. Diferentes arquiteturas têm sido avaliadas na estimativa da evapotranspiração de referência em diferentes escalas de tempo (TAHIR,1998; KUMAR et al., 2002; SUDHEER et al., 2003; TRAJKOVIK et al., 2003, ARCA et al., 2004, ZANETTI et al., 2007), mas poucas vezes (ARCA et al., 2004; ZANETTI et al., 2007) esse fato tem ocorrido utilizando um número de variáveis menor que o requerido pelo método padrão Penman-Monteith (ET_{OPM}). No Brasil, Zanetti et al. (2007) encontraram bom desempenho de redes baseadas apenas em temperatura do ar, radiação extraterrestre e fotoperíodo. Redes com apenas uma camada oculta têm representado adequadamente as relações não lineares existentes entre as variáveis meteorológicas e a evapotranspiração de referência, coincidindo com os resultados reportados por Kumar et al. (2002) e Arca et al. (2004). Localmente, modelos baseados em regressão têm sido testados para estimar valores diários de ET_{OPM} com adequado desempenho, sempre que disponíveis os valores diários de radiação solar global ou de saldo de radiação (IRIGOYEN et al., 2009). Neste trabalho objetivou-se avaliar a capacidade das redes neurais “multiperceptron” para estimar a evapotranspiração de referência, visando reduzir o número de variáveis requeridas pelo método padrão Penman-Monteith da FAO-56 (ET_{OPM}).

MATERIAL E MÉTODOS: Dados horários registrados em estação automática localizada no campus da ESALQ-USP, Piracicaba, SP, Brasil (latitude: 22° 42’S; longitude: 47° 30’W; altitude: 546 m) no período 1997-2006 foram integrados na escala diária para estimar a evapotranspiração de referência ($mm\ d^{-1}$) seguindo o método padrão Penman-Monteith proposto pela FAO (ALLEN et al., 1998) de acordo à equação parametrizada:

$$ET_{OPM} = \frac{0,408 \delta(Rn - G) + \gamma \frac{900}{T_{ar} + 273} u(DPV)}{\delta + \gamma(1 + 0,34 u)}$$

em que Rn é o saldo de radiação ($MJ\ m^{-2}\ d^{-1}$), G é o fluxo de calor no solo ($MJ\ m^{-2}\ d^{-1}$), T_{ar} é a temperatura do ar a 2 m ($^{\circ}C$), u é a velocidade do vento a 2 m ($m\ s^{-1}$), DPV é déficit de pressão de vapor (kPa), δ é a declividade da curva de pressão de vapor na temperatura T_{ar} ($kPa\ ^{\circ}C^{-1}$) e γ é o coeficiente psicrométrico ($kPa\ ^{\circ}C^{-1}$). No cálculo de DPV foi aplicado um método baseado na integração de valores horários (LYRA et al., 2003). O saldo de radiação (Rn) foi estimado a partir da radiação global medida (Rg) seguindo a relação apresentada por Sentelhas e Nascimento (2003) com ajustes mensais. O fluxo de calor no solo (G) foi estimado seguindo Allen et al. (1998), em função da temperatura média diária (T_{ar}) e a temperatura média diária do dia anterior. Foram selecionadas para aplicar as redes neurais artificiais (RNAs) as variáveis meteorológicas radiação global (Rg); saldo de radiação (Rn), radiação extraterrestre (RTA), temperatura média diária (T_{ar}), déficit de pressão de vapor médio diário (DPV) e velocidade do vento diária (u). Diferentes arquiteturas (número de neurônios na camada intermediária) de redes tipo “multiperceptron” (MLP) considerando uma função de tipo linear na ativação da saída foram avaliadas para combinações dessas variáveis. Para evitar os problemas decorrentes de excessivo treinamento foi aplicado o método de validação cruzada (MAIER e DANDY, 2000), por isso, os dados foram divididos em três conjuntos: treinamento (1997-2002), teste (2003-2004) e validação (2005-2006). O desempenho dos modelos foi avaliado tanto através de análise de regressão quanto dos índices: raiz quadrada do quadrado médio do erro (RSME), erro médio absoluto (MAE), desvio médio (MBE) e índice (d) de concordância (WILLMOTT, 1982). Os resultados foram comparados com os obtidos com modelos baseados em regressão (IRIGOYEN et al., 2009).

RESULTADOS E DISCUSSÃO: Os valores diários de evapotranspiração de referência (ET_{OPM}) mostraram falta de normalidade nas séries utilizadas para treinamento, teste e validação. A distribuição de frequências de valores no conjunto de treinamento não diferiu das respectivas frequências nos conjuntos de teste e validação. Os valores diários das variáveis escolhidas como entradas nas RNAs também não seguiram a distribuição normal em qualquer um dos conjuntos (treinamento, teste e validação). A distribuição de frequências de valores no conjunto de treinamento também não diferiu das respectivas nos conjuntos de teste e validação para todas as variáveis de entrada avaliadas. Desse modo, atendeu-se o requisito das séries pertencerem à mesma população (MAIER e DANDY, 2000). Este fato é relevante, pois foi aplicada a validação cruzada no processo de treinamento, sendo esta sensível à forma em que os dados disponíveis são divididos. As características da rede mostrando melhor desempenho para cada combinação de variáveis são apresentadas na Tabela 1. O número de neurônios na camada intermediária variou entre oito e vinte. Este número de neurônios na camada intermediária, também chamada de camada oculta, esteve na faixa reportada na literatura. Mesmo que não exista uma regra fixa em relação ao número de neurônios nesta camada e, assim, ao número de pesos a serem ajustados, tem sido sugerido que no mínimo se guarde relação com o número de exemplos apresentados no treinamento. A relação mais extrema, citada por Maier e Dandy (2000), expressa uma relação de 10:1 entre o número de exemplos e o número de pesos a serem ajustados. Neste estudo, houve disponibilidade de 2163 exemplos no processo de treinamento, por isso foi amplamente satisfeita esta relação em qualquer dos modelos ajustados. Embora diversos tipos de função de ativação tenham sido utilizadas em RNAs, as funções de tipo sigmóide, tais como a logística e a tangente hiperbólica, são usadas com maior frequência. As RNAs considerando a função tangente hiperbólica na ativação da camada intermediária foram predominantes, tanto quando foram baseadas em R_n quanto em R_g como variável indicadora da energia disponível para evapotranspirar. No conjunto de redes que consideraram a inclusão da radiação teórica (RTA) na entrada não se apresentou alguma função de ativação na camada intermediária como predominante entre as de melhor desempenho.

Tabela 1. Características das redes neurais artificiais de tipo “*multiperceptron*” (MLP) de melhor desempenho para cada combinação avaliada de variáveis.

Modelo	Estrutura	Ativação na camada intermediária	Entradas
RNA ET_{OPM} (R_n , Tar)	MLP 2-9-1	Tangente hiperbólica	R_n , Tar
RNA ET_{OPM} (R_n , DPV)	MLP 2-16-1	Exponencial	R_n , DPV
RNA ET_{OPM} (R_n , Tar, DPV)	MLP 3-20-1	Logística	R_n , Tar, DPV
RNA ET_{OPM} (R_n , u)	MLP 2-13-1	Tangente hiperbólica	R_n , u
RNA ET_{OPM} (R_n , Tar, u)	MLP 3-8-1	Tangente hiperbólica	R_n , Tar, u
RNA ET_{OPM} (R_n , DPV, u)	MLP 3-9-1	Exponencial	R_n , DPV, u
RNA ET_{OPM} (R_g , Tar)	MLP 2-8-1	Tangente hiperbólica	R_g , Tar
RNA ET_{OPM} (R_g , DPV)	MLP 2-11-1	Tangente hiperbólica	R_g , DPV
RNA ET_{OPM} (R_g , Tar, DPV)	MLP 3-6-1	Tangente hiperbólica	R_g , Tar, DPV
RNA ET_{OPM} (R_g , u)	MLP 2-17-1	Tangente hiperbólica	R_g , u
RNA ET_{OPM} (R_g , Tar, u)	MLP 3-20-1	Exponencial	R_g , Tar, u
RNA ET_{OPM} (R_g , DPV, u)	MLP 3-19-1	Tangente hiperbólica	R_g , DPV, u
RNA ET_{OPM} (RTA, Tar)	MLP 2-16-1	Exponencial	RTA, Tar
RNA ET_{OPM} (RTA, DPV)	MLP 2-10-1	Exponencial	RTA, DPV
RNA ET_{OPM} (RTA, Tar, DPV)	MLP 3-10-1	Logística	RTA, Tar, DPV
RNA ET_{OPM} (RTA, u)	MLP 2-5-1	Tangente hiperbólica	RTA, u
RNA ET_{OPM} (RTA, Tar, u)	MLP 3-19-1	Tangente hiperbólica	RTA, Tar, u
RNA ET_{OPM} (RTA, DPV, u)	MLP 3-2-1	Logística	RTA, DPV, u

Os parâmetros a e b obtidos no ajuste por regressão entre a saída desejada (ET_{OPM}) e os valores estimados por cada uma das RNAs considerando Rn ou Rg na entrada, não diferiram estatisticamente de 0 e 1, respectivamente, permitindo inferir que a ET_o estimada pelas RNAs não diferiu estatisticamente da ET_o calculada pelo método padrão de Penman-Monteith (Tabela 2). Os erros absolutos médios (MAE) apresentaram valores entre 0,1 e 0,2 mm, representando entre 4 e 6% do valor médio de ET_{OPM} , o que significa um nível de erro bem aceitável para estimativas na escala diária. Os modelos de regressão múltipla com diferentes combinações de variáveis com Rn quanto Rg, também tinham apresentado bom desempenho (IRIGOYEN et al., 2009). A melhoria resultante da aplicação de modelos baseados em RNAs significou até uma redução em torno de 7% e 20% nos valores de RSME nos modelos considerando os valores de DPV combinados com Rn e Rg, respectivamente. Dentre as RNAs com entrada de valores diários de RTA, aquelas combinações que consideraram a entrada de valores médios diários de DPV resultaram as de melhor desempenho conjunto. Os erros absolutos médios dessas redes foram em torno de 10% do valor médio de ET_{OPM} . Quando avaliadas as mesmas combinações em modelos de regressão múltipla, os erros representavam em torno de 14% do valor médio de ET_{OPM} . A dispersão dos valores estimados pelas RNAs em relação aos valores médios do ajuste por regressão foi maior, exibindo valores entre 0,35 e 0,87 para os coeficientes de determinação.

Tabela 2. Índices obtidos na validação de modelos baseados em redes neurais artificiais (RNAs) para estimar valores diários de ET_{OPM} .

Modelo	a mm d ⁻¹	b	R ²	RSME mm d ⁻¹	MAE mm d ⁻¹	MBE mm d ⁻¹	d
RNA ET_{OPM} (Rn, Tar)	0,0066	0,9849	0,95	0,238	0,179	0,039	0,988
RNA ET_{OPM} (Rn, DPV)	0,0301	0,9875	0,98	0,167	0,128	0,007	0,994
RNA ET_{OPM} (Rn, Tar, DPV)	0,0131	0,9891	0,98	0,157	0,118	0,020	0,995
RNA ET_{OPM} (Rn, u)	0,0517	0,9794	0,95	0,252	0,184	0,010	0,986
RNA ET_{OPM} (Rn, Tar, u)	0,0130	0,9870	0,96	0,219	0,166	0,026	0,990
RNA ET_{OPM} (Rn, DPV, u)	0,0206	0,9971	0,98	0,146	0,113	-0,018	0,995
RNA ET_{OPM} (Rg, Tar)	0,0414	1,0037	0,95	0,236	0,178	0,030	0,988
RNA ET_{OPM} (Rg, DPV)	0,0156	1,0000	0,95	0,254	0,185	0,0004	0,988
RNA ET_{OPM} (Rg, Tar, DPV)	0,0297	1,0040	0,97	0,194	0,149	0,018	0,992
RNA ET_{OPM} (Rg, u)	0,0388	0,9930	0,93	0,287	0,220	-0,018	0,982
RNA ET_{OPM} (Rg, Tar, u)	0,0356	0,9733	0,96	0,227	0,176	0,045	0,989
RNA ET_{OPM} (Rg, DPV, u)	0,0021	1,0018	0,96	0,228	0,179	-0,037	0,988
RNA ET_{OPM} (RTA, Tar)	0,2792	0,8528	0,45	0,837	0,644	0,188	0,790
RNA ET_{OPM} (RTA, DPV)	0,3621	0,8958	0,82	0,472	0,370	-0,057	0,952
RNA ET_{OPM} (RTA, Tar, DPV)	0,1060	0,9377	0,87	0,407	0,306	0,085	0,964
RNA ET_{OPM} (RTA, u)	0,3128	0,8495	0,35	0,900	0,686	0,161	0,741
RNA ET_{OPM} (RTA, Tar, u)	0,1902	0,8871	0,56	0,749	0,583	0,166	0,848
RNA ET_{OPM} (RTA, DPV, u)	-0,1132	1,0246	0,83	0,452	0,352	0,039	0,950

CONCLUSÕES: As redes neurais de tipo “*multiperceptron*” apresentam grande potencial para serem utilizadas na estimativa de valores diários de evapotranspiração de referência. O desempenho desses modelos foi levemente superior para cada combinação de variáveis em relação aos respectivos modelos baseados em regressão, quando disponíveis os dados diários de saldo de radiação (Rn) ou radiação global (Rg). Embora, os modelos com a radiação extraterrestre (RTA) como variável de entrada não apresentassem índices de desempenho tão

satisfatórios quanto os modelos baseados em R_n ou R_g , foram esses modelos os que mostraram maior nível de aprimoramento em relação aos modelos baseados em regressão para cada combinação de variáveis. Resta avaliar outros tipos de combinações que possibilitem estimar os valores diários de evapotranspiração de referência quando os valores R_n ou R_g não sejam disponíveis.

REFERÊNCIAS BIBLIOGRÁFICAS:

ALLEN, R.G. et al. **Crop evapotranspiration. Guides for computing crop water requirements.** FAO Irrigation Drainage Paper N° 56. FAO, Rome, Italy, 300 p.1998.

ARCA, B., BENISCASA, F.; VINCENZI, M. Evaluation of neural network techniques for estimating evapotranspiration. **National Research Council.** 2004.

BRAGA, A.P. et al. **Redes Neurais Artificiais: Teoria e aplicações.** Rio de Janeiro, RJ: LCT editora, 2007. 226 p.

IRIGOYEN, et al. Evapotranspiração de referência em Piracicaba-SP: I. ajuste e validação de modelos baseados em regressão. **XVI Congresso Brasileiro de Agrometeorologia,** 2009.

KUMAR, M. et al. Estimating evapotranspiration using artificial neural network. **Journal of Irrigation and Drainage Engineering,** v. 128, p. 224-233, 2002.

LYRA, G. et al. Média diária do déficit de pressão de saturação do vapor d'água e sua influencia na evapotranspiração de referência pelo modelo de Penman-Monteith em Piracicaba-SP. **Engenharia Agrícola,** v.4, p. 328-337, 2004.

MAIER, H.R.; G.C. DANDY. Neural network for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environmental Modelling & Software,** v. 15, p. 101-124, 2000.

SENTELHAS, P.C.; A. NASCIMENTO. Variação sazonal da relação entre o saldo de radiação e a irradiância solar global. **Revista Brasileira de Meteorologia,** v.18, p.71-77, 2003.

SUDHEER, K.; 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, p. 214-218, 2003.

TRAJKOVIC, S.; TODOROVIC, B.; STANKOVIC, M. 2003. Forecasting reference evapotranspiration by artificial neural networks. **Journal of Irrigation and Drainage Engineering,** v. 129, p. 454- 457, 2003.

TAHIR, S.A. **Estimating potential evaporation using artificial neural network.** In. Water and Land Resources Development and Management for Sustainable Use. Vol II. 10th ICID New Delhi. India: ICID Publications.1998.

WILLMOTT, C.J. 1982. Some comments on evaluation of model performance. **American Meteorology Society,** v. 63, p. 1309-1313, 1982.

ZANETTI, S.S. et al. Estimating evapotranspiration using artificial neural network and minimum climatological data. **Journal of Irrigation and Drainage Engineering,** v. 33, 83-89, 2007.