

PREVISÃO DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO REDES NEURAIS¹

Anderson Francisco da Silva², Luiz Cláudio Costa³, Gilberto Sedyama⁴

RESUMO

O objetivo deste trabalho é analisar o potencial uso das redes neurais como ferramenta de previsão da evapotranspiração de referência. As redes neurais, tomadas como um modelo de reconhecimento de padrão, deveriam ser capazes de inferir sobre o comportamento futuro da evapotranspiração, a partir de uma série histórica de dados climáticos recentes. Os dados climáticos foram coletados na estação Climatológica Principal de Viçosa-MG (83642), no período de 1992 a 2001 e foram divididos em 3 parcelas: de 1992 a 1997, utilizada para treinamento; de 1998 a 1999, para teste; e de 2000 a 2001, para validação. As melhores previsões obtidas na estimativa da evapotranspiração de referência apresentaram um erro padrão de estimativa de 0,8mm e um erro percentual relativo médio de 20%, quando se utilizou 10 dias da série história para prever a evapotranspiração ocorrida no dia seguinte. A estrutura 10-10-1, utilizando o valor 0,01 para a taxa de aprendizagem e também para o fator momentum, promoveu a obtenção do menor erro durante um aprendizado de 1000 épocas. O aumento no número de neurônios da camada intermediária, assim como, a inclusão de uma segunda camada não favoreceu melhores ajustes, enquanto o aumento no número de dias para a previsão reduziu a precisão dos resultados.

Palavras-chave: previsão, evapotranspiração, redes neurais.

ABSTRACT

Reference Evapotranspiration Prediction using Neural Networks

The objective of this paper is to study the potential use of the neural networks on predicting reference evapotranspiration. The neural networks, as standard recognition model, would have the capacity to understand the climate behavior, being able to, starting by climate data of the near past, infer about their future behavior. The best obtained predictions showed a standard square error around 0.8mm and a perceptual error around 20% to the evapotranspiration values, when using 10 days to predict the following one. The structure 10-10-1, by using the value 0.01 for the learning rate as well as the momentum factor has promoted the lowest error during 1000 learning epochs. The increase in the number of neurons in the intermediary layer, as much as, the inclusion of a second layer did not favor better adjustments, whereas the increase in the prediction days reduced the accuracy of the results.

Keywords: prediction, evapotranspiration, neural networks.

¹ Parte da dissertação de mestrado do primeiro autor.

² Bacharel em Ciência da Computação e Doutorando em Meteorologia Agrícola UFV – Bolsista CAPES – Campus Universitário CEP 36.570-000. (31) 3899-1859 – anderson@vicosa.ufv.br

³ Licenciado em Matemática e Professor Adjunto IV do Departamento de Engenharia Agrícola UFV, Universidade Federal de Viçosa. (31) 3899-1903 – l.costa@ufv.br

⁴ Engenheiro Agrônomo e Professor Titular UFV – sediyama@ufv.br

INTRODUÇÃO

A utilização racional da água constitui um dos grandes desafios da humanidade, neste novo século. Do total disponível no Planeta, 97% é água salgada (dos oceanos), 2,4% é água congelada (nos pólos) e 0,6% é água doce (dos rios, lagos, lençóis freáticos). Destes 0,6% utilizam-se 70% na agricultura, 22% na indústria e 8% nas cidades, basicamente, para o consumo humano (Springway, 2006). Estima-se que 40% da água extraída dos mananciais não alcança seu destino, em decorrência, no caso urbano, de vazamentos nos reservatórios e nas redes de distribuição e, no caso da irrigação, em consequência da aplicação de métodos de manejo pouco eficientes.

A determinação do volume de água necessário às culturas constitui informação imprescindível ao planejamento e manejo de qualquer sistema de irrigação (Salassier, 1995). A lâmina de água que deixa o solo num dado período de tempo, devido à evaporação direta da superfície do solo e à transpiração da cultura, é conhecida como evapotranspiração. A evapotranspiração de referência (ET_o) é, usualmente, associada à evapotranspiração, que se processa em um solo totalmente coberto por uma vegetação rasteira, com crescimento ativo e uniforme, sem deficiência hídrica e com altura entre 8 e 15cm (Doorenbos & Pruitt, 1977).

A evapotranspiração de referência é um dos principais componentes do ciclo hidrológico e a precisão de sua estimativa é de suprema importância para muitos estudos, tais como balanço hidrológico de água, projetos e manejo de sistemas de irrigação, simulação de produtividade de culturas, bem como o planejamento e gerenciamento de recursos hídricos (Kumar et al., 2002). Estudando a aplicabilidade das redes neurais na estimativa da evapotranspiração de referência, esses autores obtiveram resultados mais precisos que o método convencional de Penman-Monteith, quando comparados com o lisímetro. Utilizando apenas as temperaturas

máxima e mínima como padrões de entrada para as redes neurais, Zanneti et al. (2005) obtiveram erros médios na ordem de 0,4mm por dia, em relação à evapotranspiração calculada por Penman-Monteith.

Vemuri & Rogers (1994) sugerem que a previsibilidade seja peça fundamental para uma moderna visão científica da natureza, cuja essência, segundo Diniz et al. (1998) constitui-se da observação dos resultados de fenômenos do passado para antecipar seu comportamento futuro. Podendo ser vistas como um modelo matemático de reconhecimento de padrão (Haykin, 2000), as redes neurais apresentam-se como ferramenta adequada à previsão agrometeorológica. As redes neurais têm a capacidade de extrair dependências implícitas entre os dados, mesmo quando não existe entendimento da natureza dessas dependências (Neves & Cortez, 1997).

Neste trabalho, objetivou-se investigar a aplicabilidade das redes neurais à previsão da evapotranspiração de referência.

MATERIAIS E MÉTODOS

Os dados climáticos são originários da estação número 83642 do INMET – Instituto Nacional de Meteorologia, localizada no município de Viçosa, Minas Gerais. A série histórica, registrada nesta estação, compreende o período de 1992 a 2001, constituindo 10 anos de dados climáticos diários, referentes a diversas variáveis meteorológicas, dentre as quais foram selecionadas as seguintes: temperatura média diária (T_m – °C); temperatura mínima diária (T_n – °C); temperatura máxima diária (T_x – °C); umidade relativa diária (UR – %); velocidade do vento diária medida a 10 metros de altura (V_v – m.s⁻¹); e número de horas de brilho solar diárias (insolação) (Inso – horas), acrescidas da evapotranspiração de referência (ET_o – mm), calculada por Penman-Monteith (FAO, 1998). Os dados climáticos desses 10 anos foram divididos em três conjuntos (6; 2; 2): de 1992 a 1997 para treinamento; de 1998 a 1999 para teste; e de 2000 a 2001 para validação.

O processo de aprendizagem pode ser dividido em 3 etapas, para as quais é reservada uma parcela distinta dos dados de entrada: i) treinamento – os pesos sinápticos são modificados e a rede absorve novos conhecimentos; ii) teste – testa-se se a rede recém modificada supera a rede de melhor desempenho; e iii) validação – a rede gera resultados para entradas inéditas. Para que bons ajustes sejam alcançados, é necessário repetir as fases de treinamento e teste um determinado número de vezes, chamadas épocas.

O gerenciamento das redes neurais ficou a cargo do software Smart Climate, desenvolvido pelos autores, que utiliza o algoritmo de propagação retroativa do erro (Back Propagation), com taxa de aprendizagem e fator momentum (Figura 1). Os pesos sinápticos são aleatoriamente iniciados, enquanto a ativação dos neurônios obedece à função sigmóide logística parametrizada. Para avaliar os resultados, utiliza-se, concomitantemente, o erro padrão de estimativa (EPE) e o erro relativo médio (ERM), calculados exclusivamente sobre a parcela de validação, isto é sobre a parcela de dados ainda inédita às redes.

Os experimentos foram conduzidos em 3 etapas subseqüentes:

i) No experimento 1, objetivou-se encontrar os melhores valores para a taxa de aprendizagem (0,01; 0,10; 1,00; 10,0), para o fator momentum (0,01; 0,10; 1,00; 10,0) e para o número de épocas (1.000; 2.000; 5.000; 10.000), no qual 16 redes neurais, diferentemente parametrizadas, foram interrompidas 4 vezes durante o processamento para obtenção dos erros atuais. A estrutura [10-10-1], correspondente a 10 neurônios na camada de entrada, 10 na intermediária e 1 na saída, indicou a utilização de 10 dias da série histórica na previsão do dia seguinte.

ii) Os melhores parâmetros, obtidos no experimento 1, foram utilizados no experimento 2, cujo objetivo foi avaliar a capacidade das redes em prever 1, 2, e 5 dias (camada de saída), variando o número de neurônios na camada de entrada

(10;20;30) e na camada intermediária (10;20;30).

iii) Os melhores parâmetros, obtidos nos experimentos 1 e 2, foram utilizados no experimento 3, cujo objetivo foi avaliar a inclusão de uma segunda camada intermediária, variando em (10;20;30) o número de neurônios utilizado pelas duas.

RESULTADOS E DISCUSSÃO

Os resultados do experimento 1 indicaram que o aumento da taxa de aprendizagem e do fator momentum, ao invés de acelerar a convergência das redes, gerou uma crescente instabilidade, aumentando, gradativamente, os erros-padrão de estimativa (Figura 2). Assim, nos experimentos seguintes, adotou-se o valor 0,01 como padrão tanto para a taxa de aprendizagem como para o fator momentum, enquanto a aprendizagem das redes ficou limitada a 1000 épocas.

Nas Figuras 3a, 3c e 3e apresentam-se os resultados obtidos no experimento 2, A distribuição dos erros-padrão de estimativa para as estruturas 10-10-1, 10-10-2 e 10-10-5 estão exibidas nas Figuras 3b, 3d e 3f, respectivamente. Percebe-se que erros concentraram-se em valores próximos a zero.

Observa-se que as previsões perderam precisão à medida que se aumentou o número de dias: para 1 dia [10-10-1] teve-se um erro padrão de estimativa em torno de 0,79mm; para 2 dias [10-10-2] em torno de 0,83mm; e para 5 dias [10-10-5] em torno 0,96mm.

O resultado do experimento 3 está apresentado na Figura 4. Neste gráfico, cada linha corresponde à manutenção do número de neurônios na 1ª camada intermediária e a abscissa à variação dos neurônios da 2ª camada. Observa-se que a inclusão de uma nova camada intermediária e a variação no número de neurônios não promoveu melhorias significativas, mantendo o erro padrão de estimativa em torno de 0,8mm.

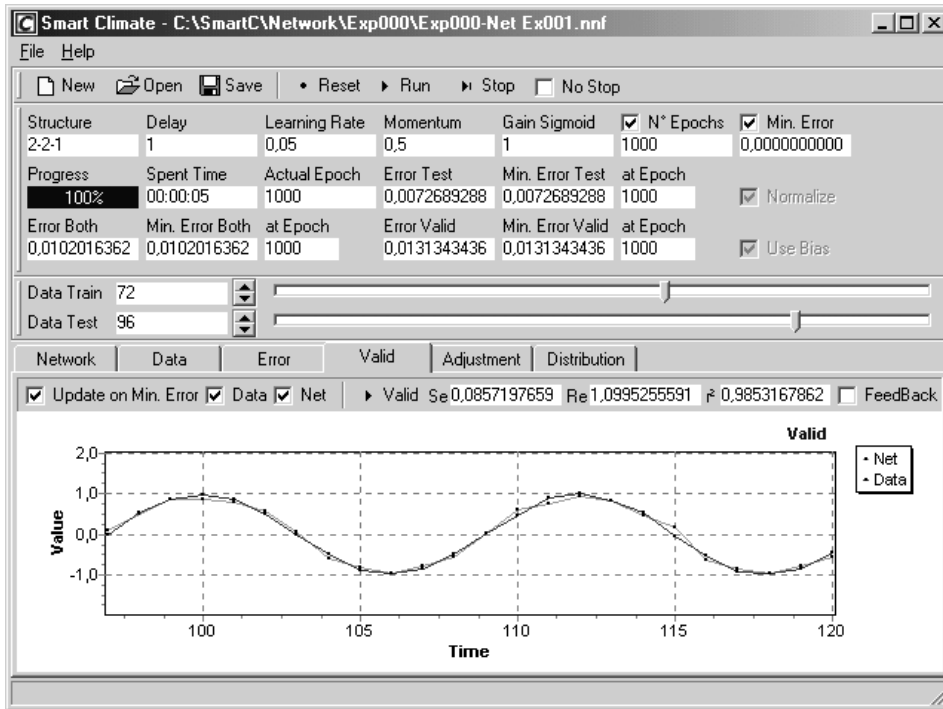


Figura 1. Software Smart Climate

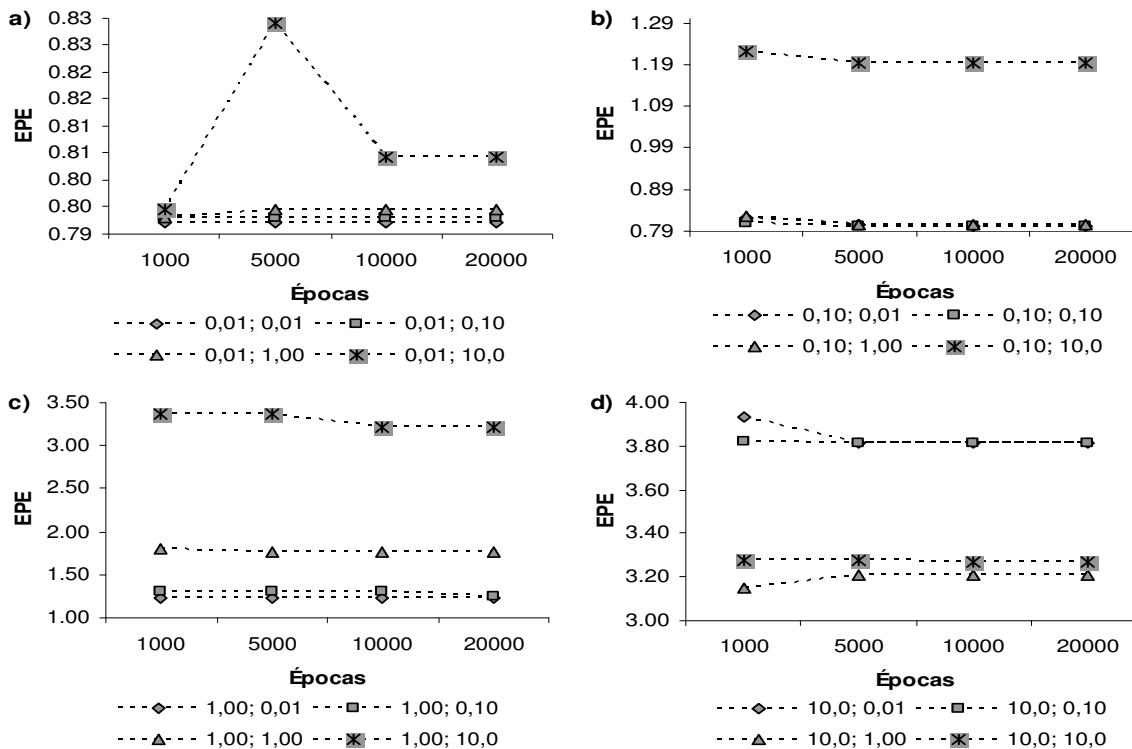


Figura 2. Resultados obtidos no experimento 1 para as épocas 1.000, 5.000, 10.000 e 20.000. a) Aprendizagem constante de 0,01 e momentum variando entre 0,01; 0,10; 1,00 e 10,0. b) Aprendizagem constante de 0,10 e momentum variando de 0,01; 0,10; 1,00 e 10,0. c) Aprendizagem constante de 1,00 e momentum variando entre 0,01; 0,10; 1,00 e 10,0. d) Aprendizagem constante de 10,0 e momentum variando entre 0,01; 0,10; 1,00 e 10,0

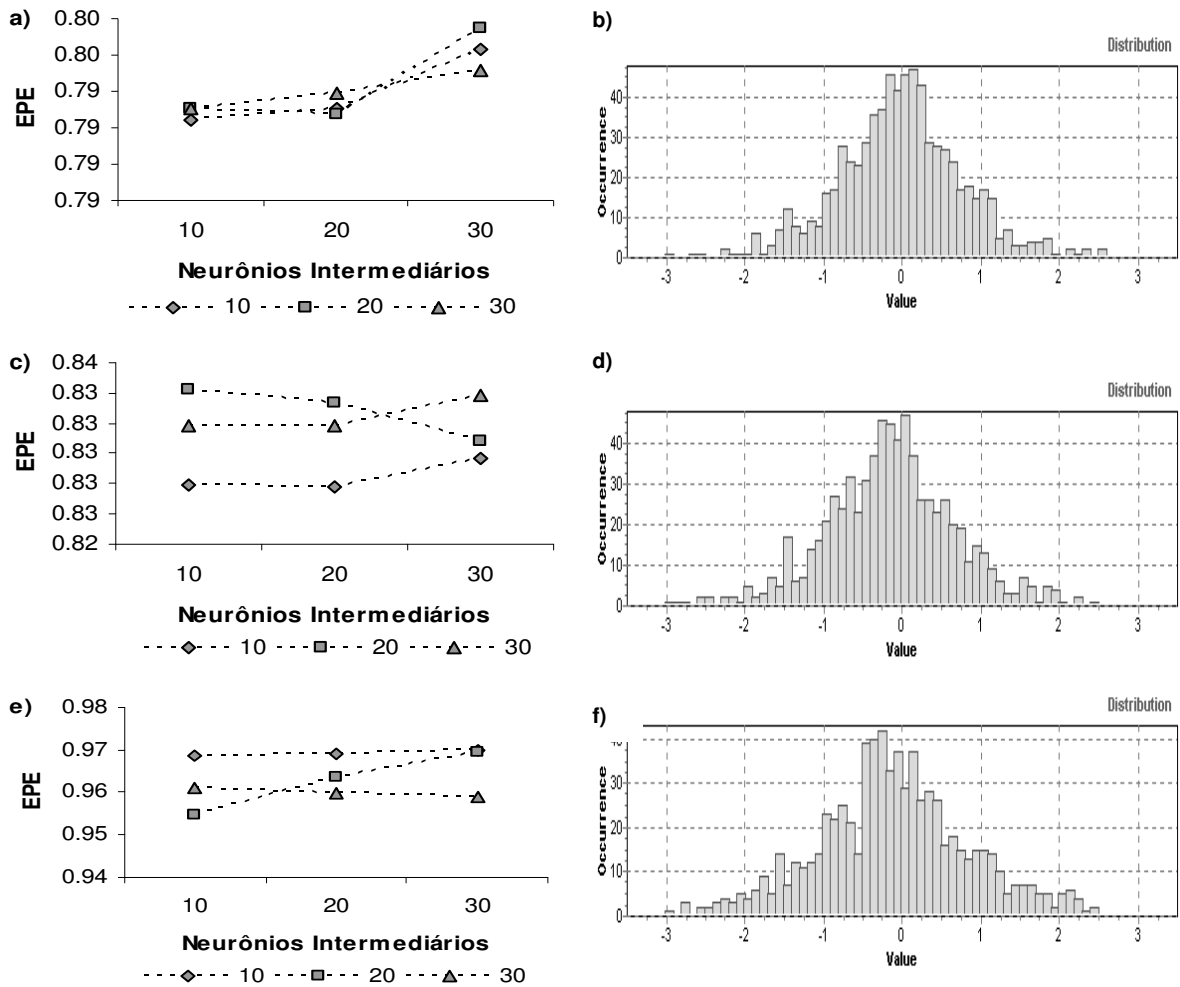


Figura 3. Resultados do experimento 2. a) Previsão de 1 dia, A-B-1, neurônios na camada de entrada A variando entre 10, 20 e 30, neurônios na camada intermediária B variando entre 10, 20 e 30. b) Distribuição dos EPE's para a rede 10-10-1. c) Previsão de 2 dias, A-B-2, neurônios na camada de entrada A variando entre 10, 20 e 30, neurônios na camada intermediária B variando entre 10, 20 e 30. d) Distribuição dos EPE's para a rede 10-10-2. e) Previsão de 5 dias, A-B-5, neurônios na camada de entrada A variando entre 10, 20 e 30, neurônios na camada intermediária B variando entre 10, 20 e 30. f) Distribuição dos EPE's para a rede 10-10-5

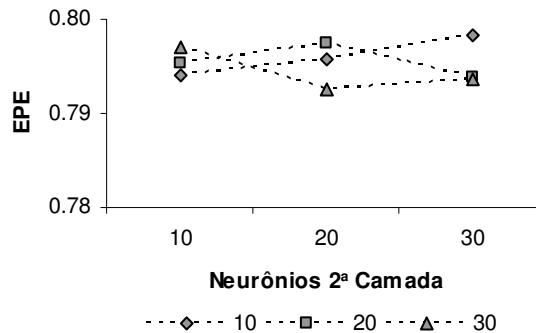


Figura 4. Redes Multicamadas, estrutura 10-X-Y-1. Cada linha mantém constante o número de neurônios na 1ª camada (10, 20, 30). O eixo X corresponde à variação do número de neurônios da 2ª camada (10, 20, 30)

Na Figura 5, apresenta-se, de forma completa, a previsão diária para os anos de 2000 e 2001 para a melhor rede encontrada (10-10-1; 0,01; 0,01), e na Figura 6, a correlação para o mesmo período. De acordo com os resultados obtidos, os dados estimados pelas redes neurais acompanham o comportamento dos dados observados. No

entanto, a baixa correlação encontrada entre os dados observados e estimados mostra que, ainda, é necessário o teste da metodologia com séries climáticas mais longas bem como para outras regiões com diferentes características climáticas, a fim de se estabelecer o real potencial de uso do modelo.

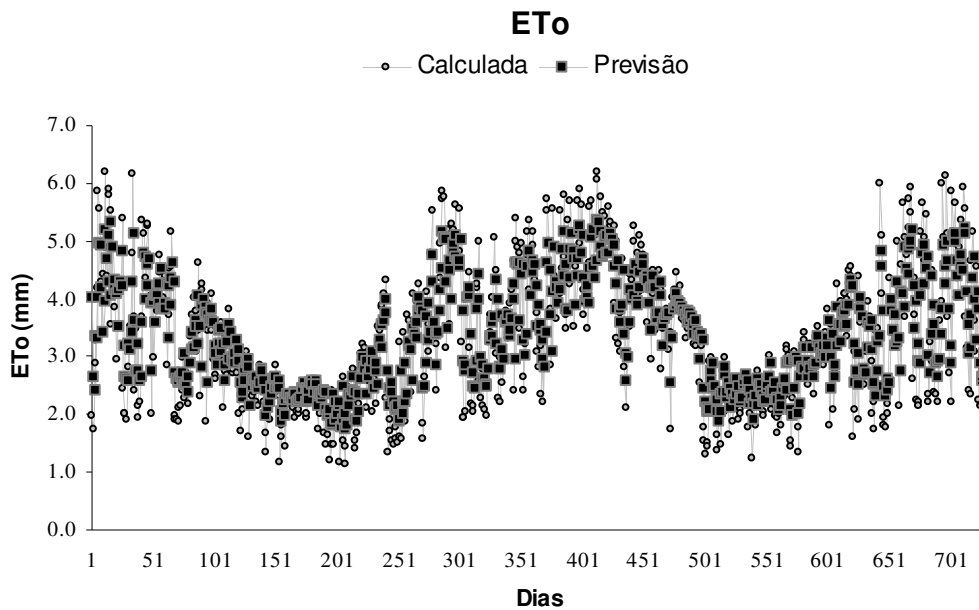


Figura 5. ETo calculada x ETo prevista - Previsão diária para 2000 e 2001

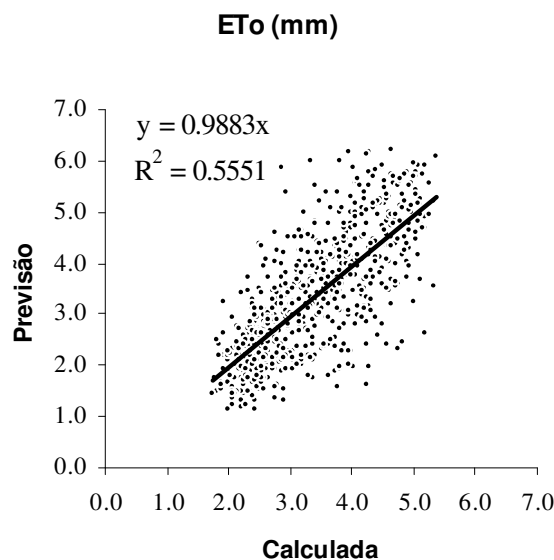


Figura 6. Correlação ETo calculada x previsão para 2000 e 2001

CONCLUSÕES

Os resultados mostraram que as redes neurais apresentam grande potencial para serem utilizadas na previsão da evapotranspiração de referência. Os melhores resultados foram obtidos utilizando-se 10 dias contíguos da série histórica para a previsão do dia imediatamente subsequente. A estrutura 10-10-1, com taxa de aprendizagem e fator momentum iguais a 0,01, durante um aprendizado de 1000 épocas, gerou um erro padrão de estimativa de 0,79mm e um erro relativo médio de 20%. Os resultados mostraram, ainda, que a precisão das previsões reduziu-se à medida que o número de dias preditos aumentou. O aumento no número de neurônios da camada intermediária, assim como, a inclusão de uma segunda camada intermediária não promoveu melhoria nos resultados.

REFERÊNCIAS BIBLIOGRÁFICAS

- DINIZ, H., ANDRADE, L.C.M. de, CARVALHO, A.C.P. de L.F. de, ANDRADE, M. G. de A. Previsão de Séries Temporais Utilizando Redes Neurais Artificiais e Modelos de Box e Jenkins. In: SBRN - Simpósio Brasileiro de Redes Neurais, 5, 1998. **Anais...** Sociedade Brasileira de Computação, Belo Horizonte - MG, 1998. v.2, p.173-178.
- DOORENBOS, J., PRUITT, W.O. **Guidelines for Predicting Crop Water Requirements.** Irrigation Drain, FAO, Rome, Italy. 1977. Paper 24.
- ALLEN, R.G., PEREIRA, L.S., RAES, D., SMITH, M. FAO Irrigation and Drainage Paper 56. Crop Evapotranspiration – Guidelines for Computing Crop Water Requirements., 1998. Food and Agriculture Organization of the United Nations, Rome, 1998, 309p.
- HAYKIN, S. **Redes Neurais - Princípios e Prática.** Tradução: Paulo Martins Engel, Porto Alegre: Editora Bookman, 2ª Edição, 2000. 900p.
- 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.
- NEVES, J., CORTEZ, P. An Artificial Neural Network – Genetic Based Approach for Time Series Forecasting. In: Brazilian Symposium on Neural Networks, 4, 1997. **Proceedings...** Sociedade Brasileira de Computação, Belo Horizonte - MG, 1997. p.9-13.
- SALASSIER, B. **Manual de Irrigação.** Viçosa: Imprensa Universitária da Universidade Federal de Viçosa, 1995. 463p.
- SPRINGWAY. **A Água no Mundo.** http://www.springway.com.br/agua_mundo.htm. 01 abr. 2006.
- VEMURI, V.R., ROGERS, R.D. **Artificial Neural Networks: Forecasting Time Series.** Los Alamitos - CA: IEEE Computer Society Press, 1994. 220p.
- ZANETTI, S.S., SOUSA, E.F., OLIVEIRA, V.P.S., ALMEIDA, F.T. Estimação da Evapotranspiração de Referência Usando Redes Neurais Artificiais. In: CONBEA – Congresso Brasileiro de Engenharia Agrícola, 34, 2005. **Anais...** Sociedade Brasileira Agrícola, Canoas – RS, 2005. v.1, p.1-4.