

METODOLOGIA PARA CORRIGIR, PREDIZER E DISPONIBILIZAR A EVAPOTRANSPIRAÇÃO DE REFERÊNCIA, ATRAVÉS DE REDES NEURAIS ARTIFICIAIS, PARA RACIONALIZAÇÃO DE PRÁTICAS DE MANEJO DE IRRIGAÇÃO

MORETHSON RESENDE

Endereço: Embrapa Milho e Sorgo. Cx. Postal 151. 35701-970 Sete Lagoas, MG. e-mail: resende@cnpms.embrapa.br

Palavras-chave: evapotranspiração, evapotranspiração de referência, redes neurais, manejo de irrigação, irrigação.

RESUMO EXPANDIDO

A sustentabilidade das áreas irrigadas, a incorporação e a conseqüente expansão de novas áreas devem estar associadas ao aumento de produtividade e preservação dos recursos naturais. Aproximadamente 23% da área cultivada no planeta constituem-se de solos salinos e 37% de solos sódicos (Szabolcs, 1989; citado por Aragües, 1998), principalmente devido ao manejo inadequado das irrigações. A baixa eficiência no uso da água é resultado de vários componentes, principalmente pela falta do uso de algum método de manejo de irrigação pelos produtores irrigantes. Almeida (1997), desenvolvendo trabalhos de avaliação de sistemas de irrigação, concluiu que, 63% dos lotes avaliados, estavam aplicando excesso de água e que as dotações de irrigação eram constantes e iguais às determinadas no projeto para o ano todo e às vezes superiores às requeridas nos meses de maior demanda evaporativa. Vários trabalhos apontam baixos valores de eficiência, indicando com isso, a necessidade de utilização de estratégias de manejo para estimativa do momento e da quantidade de água a ser aplicada, visando proporcionar melhoria nos níveis de eficiência. Segundo Christofides (1999), estima-se que, em média, a eficiência de irrigação é de 45% e as maiores perdas são devido ao inadequado manejo de irrigação.

Normalmente, as alternativas de métodos de manejo de irrigação, são baseadas em dois princípios: a – monitoramento do solo e /ou da planta, que consiste em medir o potencial ou o teor de umidade no solo e na planta, o potencial de água ou temperatura do dossel da folha; b – balanço de água no solo, feito com base na capacidade do solo em armazenar água, da profundidade do sistema radicular, do nível de esgotamento permissível, da evapotranspiração e das características da cultura (Martin et.al.1992).

De modo geral, o agricultor baseia-se em sua própria experiência para programar as irrigações e, em muitos casos, se vê limitado pela falta de dados, de conhecimento ou de orientação técnica. Alguns fatores têm contribuído para a não adoção de algum sistema de manejo de irrigação pelos produtores, podendo-se destacar, dentre eles, que: a)- os dados necessários para um manejo adequado de irrigação são específicos para cada área e, muitas vezes, de difícil obtenção; b)- alto custo e deficiência generalizada de equipamentos de controle das condições de umidade do solo, fatores da planta e atmosfera; c)- métodos de manejo de irrigação, trabalhosos e/ou de baixa precisão; d)- outros.

A estratégia mais simples de se manejar as irrigação é a baseada em uma série

histórica de dados climáticos, que visa o cálculo da evapotranspiração de referência (ET_o) média e em informações sobre a cultura, o solo e o sistema de irrigação. Esse método permite fazer um calendário das irrigações antes mesmo do plantio, contendo datas e tempo de funcionamento do equipamento, ou seja, quando e quanto irrigar. A principal fonte de erro que tem sido atribuída a esse método, é que se assume que a média da ET_o diária de anos anteriores, calculada com base em uma série histórica de dados climáticos, não representa os valores reais de ET_o diários do período em que a lavoura estiver sendo conduzida.

Assumindo-se que as irrigações são realizadas após um período de estiagem, ou alguns dias após uma irrigação, os dados de ET_o de dias chuvosos não representam as condições reais do momento em que as irrigações estão sendo requeridas. Valores médios de ET_o de períodos de 10, 20 ou 30 dias, de meses como novembro, dezembro ou janeiro poderão ser inferiores aos valores de ET_o de meses sabidamente com menor demanda atmosférica, como maio, junho e julho, devido a baixíssimos valores de ET_o obtidos em dias chuvosos de verão. Portanto, através da caracterização da disponibilidade hídrica, de períodos de dias chuvosos e de estiagem de uma série histórica de dados climáticos, é possível selecionar os dias com alta umidade relativa, baixa insolação e baixa taxa de radiação solar, para que se possa fazer ajustes nos valores da ET_o desses dias. A grande variabilidade dos valores diários de ET_o, principalmente na época de verão, deve-se à ocorrência de dias chuvosos, enquanto que, em dias ensolarados, os valores das ET_o são menos variáveis e mais representativos dos requerimentos de água pelas culturas, no momento da necessidade de irrigação, num determinado mês. Isso é válido tanto para elaborar projetos de irrigação como para se fazer um manejo racional. Portanto, a correção e a predição de valores de ET_o com base em uma série histórica de dados climáticos poderão tornar o método do calendário mais preciso e simples para se manejar irrigação.

Predizer o futuro tem sido uma das maiores ambições da humanidade desde os tempos mais remotos. Tratando-se do domínio industrial, onde se emprega alta tecnologia na produção de bens para a população, a necessidade de se conhecer antecipadamente o futuro a curto, médio ou longo prazo, é um requisito básico para a continuidade da atividade produtiva. As séries temporais representam uma forma de entender e caracterizar um sistema de modo a tornar possível a previsão de seu comportamento futuro. No caso em que o seu comportamento é regido por equações determinísticas e conhecidas, a resolução dessas equações, a partir de condições iniciais, é suficiente para se obter uma predição confiável de seu comportamento futuro. Na maioria das situações reais, essas equações e as condições iniciais não são conhecidas ou são apenas conhecidas parcialmente. É preciso, pois, buscar regras que regem o comportamento do sistema, através de uma análise exploratória de algumas regularidades observáveis nas medidas passadas de séries temporais do sistema. Os métodos tradicionais de predição de séries temporais são os modelos MA ("moving average"), AR ("auto-regressive") e ARMA, uma combinação dos outros dois. Em 1943, McCulloch e Pitts (1943) descreveram um modelo simplificado, porém poderoso, do neurônio real, o qual ainda se encontra em uso atualmente na maioria dos modelos de Redes Neurais Artificiais (RNAs). O modelo de McCulloch e Pitts (ou modelo MCP) é baseado na plausibilidade neurofisiológica de um neurônio, desempenhando uma função de soma e "threshold", onde os pesos nas conexões entre os nodos correspondem às sinapses inibidoras e excitadoras de um neurônio

real. Embora não esteja explícito no trabalho original de McCulloch e Pitts, os nodos MCP são capazes de se adaptar através do ajuste dos pesos de cada conexão. Esse processo de adaptação - ou *aprendizado* - permite o desenvolvimento de procedimentos para o ajuste gradual dos pesos, de forma que a rede desempenhe a função desejada. A primeira teoria neurofisiológica para modificação de sinapses em neurônios reais foi proposta por Hebb (1949). De acordo com a teoria de Hebb, uma entrada sináptica que é ativada quando a saída do neurônio também é ativada, deverá ser fortalecida. Esse procedimento de ajuste de pesos, freqüentemente chamado de regra de Hebb, tem sido adotado de formas diferentes em algoritmos de aprendizado para modelos de RNAs baseados no modelo MCP (Willshaw, et al., 1969; Kohonen, 1972; Anderson, 1972; Hopfield, 1982). Outro procedimento para a adaptação de pesos é a chamada regra de Widrow-Hoff, proposta por Widrow e Hoff (1960). Essa regra se baseia no cálculo do erro entre a soma atual dos pesos das entradas e a saída desejada, ajustando-se, então, o peso de forma que o erro se torne zero. Uma variação da regra de Widrow-Hoff foi proposta por Rumelhart et al. (1986a, 1986b) em sua descrição do algoritmo *Backpropagation* para redes multiníveis. Redes Neurais Artificiais (RNAs) do tipo "feedforward", que usam "taped delay", têm sido usadas com sucesso para aprender a função capaz de prever o valor futuro de uma série com um número pequeno de medidas passadas. Essas redes são potencialmente capazes também de emular as regularidades de curto prazo inesperadas. Em se tratando de dados climáticos, é possível prever valores de ETo com base no comportamento dos dados anteriores, para substituir os valores que deverão ser corrigidos utilizando-se RNAs. Da mesma forma, como alternativa à determinação da média dos valores da ETo de uma série histórica, poderão ser estimados os valores de ETo de determinado ano, com base no comportamento dos dados corrigidos de anos anteriores, empregando-se RNAs. A utilização de redes neurais do tipo GMDH ("Group Method of Data Handling") têm apresentado resultados satisfatórios no modelamento do fluxo de rios (Valença e Ludermir, 1990). Sistemas empregando Redes Neurais podem trabalhar em conjunto com outras técnicas, como a Lógica Nebulosa e os Algoritmos Genéticos, tendo aplicações práticas, como pode ser visto em Bellini et al. (1998); Carneiro et al. (1998).

Para o desenvolvimento das metodologias propostas, deverá ser feita uma caracterização da disponibilidade hídrica de uma série histórica de dados climáticos, estipulando-se os limites de umidade relativa e de insolação, bem como a ocorrência de chuvas visando as datas em que os dados de ETo serão substituídos por dados corrigidos. Essa correção poderá ser feita através da estimativa da ETo, baseando-se no comportamento dos valores de dados anteriores, empregando-se, primeiramente, Redes Neurais Artificiais (RNAs) "feedforward" com "taped delay". Em um segundo momento, poderão ser utilizados métodos de Lógica Nebulosa e Algoritmos Genéticos, todos em conjunto com as redes neurais, otimizando-se os resultados. De posse do banco de dados dos valores de ETo corrigidos, poderão ser preditos os valores de ETo diários para o ano seguinte, também empregando-se, primeiramente, Redes Neurais Artificiais (RNAs) "feedforward" com "taped delay" e posteriormente empregando-se métodos de Lógica Nebulosa e Algoritmos Genéticos, todos em conjunto com as redes neurais, otimizando-se os resultados.

Após o desenvolvimento das metodologias de correção e predição da ETo será possível disponibilizar estas informações via rede, específica para qualquer local do

País através do acesso a banco de dados climáticos disponível em Instituições com o INIMET. Primeiro estima-se os valores de ETo, se possível, utilizando-se o método de Penman-Monteith, gerando, assim, um novo banco de dados contendo uma série de 40 anos de ETo, em seguida corrige-se os dados de ETo utilizando-se as RNAs, obtendo-se assim um segundo banco de dados de ETo corrigidos e por último faz-se a predição dos valores de ETo para o ano seguinte. Esta metodologia permitirá obter seis bancos de dados, sendo: a) ETo diária de todos os anos da série, estimados pelo método de Penman-Monteith ou outro método; b) ETo média diária dos valores de ETo diária de todos os anos da série, estimados pelo método de Penman-Monteith; c) valores de ETo diários corrigidos pela RNAs de todos os anos da série; d) ETo predita pelas RNAs, para o ano seguinte, com base nos valores de ETo diária corrigidos pelas RNAs dos anos anteriores da série; e) ETo média diária dos valores de ETo diária de todos os anos da série, corrigidos pelas RNAs f) ETo predita pela RNAs com base nos valores de ETo diária dos anos anteriores da série (sem correção), calculados pelo método de Penman-Monteith.

LITERATURA CITADA

- ALMEIDA, F.T. **Avaliação dos sistemas de irrigação pressurizados e do manejo da água na cultura da banana no Projeto Gorutuba**. Viçosa: UFV, 1997. 100p. Tese Mestrado.
- ANDERSON, J.A. A simple neural network generating an interactive memory. **Mathematical Biosciences**, *New York*, v.14,p.197-220, 1972.
- ARAGÜES, R. Calidad de agua para riego. In: CURSO INTERNATIONAL DE RIEGO, 9., 1998, Tenerife.. 162p.
- BALLINI, R; SOARES,S. E ANDRADE,M.G. "Na Adaptive Neural Fuzzy Network Model for Seasonal Streamflow Forecasting. . In: BRAZILAIN SYMPOSIUM ON NEURAL NETWORKS, 5., 1998, Belo Horizonte, MG. **SBRN98**. – proceedings... p 215-219
- CARNEIRO, A. A. F.M.; LEITE, P.T. E, CARVALHO, A. C.L.F. "A Genetic Algorithm Approach to Optimize the Operation Panning of Hydrothermal System Scheduling. In: BRAZILAIN SYMPOSIUM ON NEURAL NETWORKS, 5., 1998, Belo Horizonte, MG. **SBRN98**. – proceedings... p 253-258.
- CHRISTOFIDIS, D. **Recursos hídricos e irrigação no Brasil**. Brasília: Universidade Federal de Brasília/ Centro de Desenvolvimento Sustentável, 1999. 34p.
- HEBB, D.O. **The organization of behaviour**. New York: John Wiley, 1949.
- HOPFIELD, J..J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy Science of the United Estates of America**, *Washington*, v.79, p.2554-2558, 1982.
- KOHONEN, T. Correlation matrix memories. **IEEE Transactions on Computers**, *New*

York, v.21, p.353-359, 1972.

MARTIN, D.L; STEGMAN, E.C. ; FERERES, E. Irrigation scheduling principles. In: HOFFMAN, G.J. **Management of Farm Irrigation Systems**, St. Joseph: ASAE, 1992. p.155-206

MCCULLOCH, W.S. ; PITTS, W.A. logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, *Elmsford*, v.5, p.115-133, 1943.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning internal representations by error propagation. In RUMELHART, D.E.; McClelland, J.L. eds. **Parallel Distributed Processing: Explorations in the Microstructures of Cognition**, Cambridge: MIT Press, 1986b

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by back-propagation of errors. **Nature**, London, v.323, p.533-536, 1986b.

VALENÇA, M. E ; LUDERMIR, T. "Self - Organizing Modeling in Forecasting Daily River Flows. In: BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 5., 1998, Belo Horizonte, MG. **SBRN98** – proceedings. p 210-214.

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. *In: IRE WESCON Convention Record* . New York: IRE Press, 1960. p.96-104

WILLSHAW, D.J.; BUNEMAN, O.P.; LONGUET-HIGINS, H.C. Non-Holographic Associative Memory. **Nature**, *London*, v.222, p.960-962, 1969.