

Utilização de Rede Neural para Estimativa do Tempo de Variação da Pressão Matricial do Solo

F.J.F. Canafistula¹; A.P.S. Braga²; A.S. Teixeira³.

RESUMO: A conservação de energia e a economia de água são dois temas que vêm ganhando cada vez mais relevância no momento atual. Na irrigação de precisão, em especial estas duas metas podem ser alcançadas de forma eficiente através do aperfeiçoamento da estratégia de controle do sistema de irrigação. O presente artigo busca contribuir neste sentido ao propor uma irrigação mais eficiente que se baseie em uma curva de retenção de água no solo estimada através de uma rede neural. Os dados utilizados para alimentar a referida rede provem de sensores de umidade do solo instalados em um sistema automático de malha fechada para irrigação de precisão. A Rede Neural Artificial (RNA) estima o tempo de variação da Pressão Matricial do Solo (PMS), permitindo a melhoria *on-line* da estratégia de controle da irrigação, sem a necessidade de análise em laboratório.

Palavras-chaves: energia, controle, irrigação.

Use of Neural Net for Estimate of the Time of Variation of the Matric Pressure of the soil.

SUMMARY: Water and energy conservation are topics that get great relevance nowadays. In precision irrigation, these two goals can be efficiently reached by using appropriate algorithms for control. This article presents a proposal of applying artificial neural network for soil water retention curve fitting. The data applied to train the neural network were obtained from soil moisture sensors previously installed in a closed loop feedback control network for precision irrigation. The neural network succeeded in estimating the rate of change of the soil matric potential. This information can now be applied to improve irrigation control routines without need of tedious laboratory analysis.

Keywords: energy, control, irrigation.

INTRODUÇÃO

O tempo de irrigação depende da quantidade de água necessária em um sistema de

¹ Mestrando, Universidade Federal do Ceará, Depto. de Engenharia Elétrica, Fortaleza, CE, Fone: 08533669765, email: firmino@dee.ufc.br .

² Prof. Dr., Depto de Engenharia Elétrica, UFC, Fortaleza, CE.

³ Prof. PhD., Depto de Engenharia Agrícola, UFC, Fortaleza, CE

irrigação (RIBEIRO & YODER, 1997; CANAFÍSTULA et al., 2005). Esta variável é fundamental para o sistema como um todo, pois ela afetará diretamente: (i) a produtividade da plantação, (ii) a quantidade de energia elétrica utilizada, (iii) o volume de água aplicado e o (iv) período (sujeito a diferentes tarifações) em que essa energia vai ser utilizada. No entanto, irrigar uma cultura com uma quantidade de água pré-estabelecida (controle do tempo de irrigação baseado na lâmina a ser aplicada na cultura) nem sempre é ideal, pois a adoção de uma quantidade de água fixa na plantação desconsidera a dinâmica de variáveis que influenciam no sistema, como a disponibilidade de água, a qualidade de água, o tipo de solo, o tipo de cultura, as fases fenológicas da cultura, radiação solar, umidade relativa do ar, temperatura, índice pluviométrico e etc.

Estudos sobre variabilidade têm revelado que as propriedades físicas de um solo podem variar significativamente entre pontos relativamente próximos de uma mesma área, sem causa visual aparente (BECKETT & WEBSTER, 1971). Dentre as propriedades físico-hídricas, uma de difícil caracterização tanto pelo tempo que se consome nas análises quanto pela intrínseca modificação da amostra devido à histerese, é a Curva de Retenção da Água no Solo (abreviadamente curva de retenção) que expressa a relação entre a umidade do solo, a base de massa ou volume, e o potencial mátrico correspondente (CHILDS, 1940).

Sobre as considerações acima, há que se buscar alternativas para o modelamento das características que definem quando e quanto irrigar. Uma solução interessante para o problema é a adoção de uma Rede Neural Artificial (RNA) (HAYKIN, 1999) – uma ferramenta computacional inspirada no sistema nervoso humano com capacidade de aquisição e manutenção do conhecimento. Uma RNA pode ser treinada para atender uma necessidade particular, através do ajuste dos valores de conexão entre os neurônios (DEMUTH & BEALE, 1998). Comumente uma rede é treinada, ou ajustada, de maneira que um conjunto particular de dados gere um outro conjunto específico de saída (ANGELICO, 2005).

Neste trabalho, a proposta é a utilização de uma rede neural para estimar o tempo de variação da Pressão Matricial do Solo (PMS). Esta estimativa pode ser utilizada para: (i) Aperfeiçoar o manejo da irrigação em sistemas com diversas parcelas; (ii) Otimizar a irrigação para economia do custo de energia elétrica ao reduzir o tempo de irrigação, e planejar a operação do sistema fora do horário de ponta (horário com cobrança de maior tarifação pela concessionária de energia); (iii) Economia de água e adubos através da redução de perdas por percolação; (iv) Redução no impacto ambiental devido à implantação sistema; e

(v) Avaliar curvas de retenção de água no solo sem necessidade de análises de laboratório e utilização de parâmetros indiretos.

Os dados para treinamento e validação da rede neural foram obtidos a partir de medições de PMS realizadas através de sensores eletrônicos instalados em campo. Os resultados obtidos mostram o potencial da técnica proposta ao exibir a proximidade verificada entre as estimativas realizadas pela rede neural e os dados reais coletados.

MATERIAIS E MÉTODOS

Os sensores de Pressão Matricial do Solo utilizados no experimento são do tipo watermark, eles são monitorados por um sistema de aquisição de dados comercial. O sistema de aquisição de dados grava a leitura dos sensores de hora em hora, sendo a unidade utilizada no sistema o kilopascal (kPa). Foram instalados 48 sensores na planta, com 16 sensores a 10 cm de profundidade do solo, 16 sensores a 30 cm e 16 sensores a 50 cm. Os sensores utilizados para treinamento e validação da rede foram os instalados a 30 cm de profundidade, e destes, somente aqueles que apresentaram resultados coerentes da medida da pressão matricial da água no solo foram utilizados.

Tabela 1 – Exemplo de amostragem coletada através do sistema de aquisição de dados processada pelo programa que faz o processamento de sinais dos sensores de PMS.

Hora	Bat V	T painel	T10 cm	T30cm	T 50 cm	T1_10R1	T1_10R4	T1_10R3
0	12,37	25,52	31,24	31,47	31,5	9,47	26,65	11,52
100	12,36	25,34	31	31,45	31,52	9,48	26,56	11,66
200	12,34	24,47	30,73	31,41	31,54	9,56	26,46	11,79
300	12,32	23,29	30,43	31,36	31,56	9,64	26,42	11,92
400	12,30	22,39	30,13	31,33	31,56	9,73	26,54	12,05
500	12,28	21,81	29,81	31,25	31,57	9,82	26,53	12,17
600	12,26	21,38	29,49	31,16	31,57	9,92	26,47	12,29
700	12,25	21,20	29,19	31,07	31,56	10,02	26,42	12,42
800	12,51	22,18	28,93	30,94	31,55	10,12	26,38	12,54
900	12,95	24,24	28,83	30,83	31,52	10,27	26,36	12,74
1000	13,02	27,59	29,06	30,72	31,49	10,52	26,52	13,04

A **Tabela 1** mostra um exemplo de amostragem dos dados coletados pelo sistema: a primeira coluna indica o tempo que é feito o armazenamento de dados pelo sistema, esse valor é uma média das amostragens de dados monitoradas pelos sensores, que é feita a cada 60 segundos. O sistema de aquisição de dados, além das coletas, também faz o controle automático da irrigação, usando para isso dados dos demais sensores, e como esses sensores são sensíveis à variação de temperatura, os dados dos mesmos precisam ser corrigidos. É

necessário então monitorar a temperatura no solo como é visto nas colunas 04, 05 e 06. Os dados de temperatura não são utilizados para o treinamento da RNA, pois a correção é feita através de uma equação que faz conversão do sinal de tensão elétrica gerado pelo sensor para o Potencial Mátrico do Solo. Esta equação está no programa que processa todos os dados e geram os valores apresentados na **Tabela 1**.

A área irrigada está dividida em 16 parcelas, em cada parcela é colocado um sensor a 30cm de profundidade. Quatro destas parcelas são submetidas a um tratamento, ou seja, aplicação de volume de água uniforme nas parcelas. O volume de água aplicado é determinado pelo tempo de irrigação e pela Pressão Matricial de água no solo, logo temos quatro tratamentos diferenciados. A amostragem para a Rede Neural Artificial é feita de sensores com tratamentos diferenciados e que apresentem a curva de retenção de água no solo coerentes. A **Figura 1.a** mostra o gráfico gerado por quatro sensores do tratamento três. Observar que temos sensores que apresentam curvas incoerentes, dessa forma não podemos utilizar seus dados para treinamento e validação da rede.

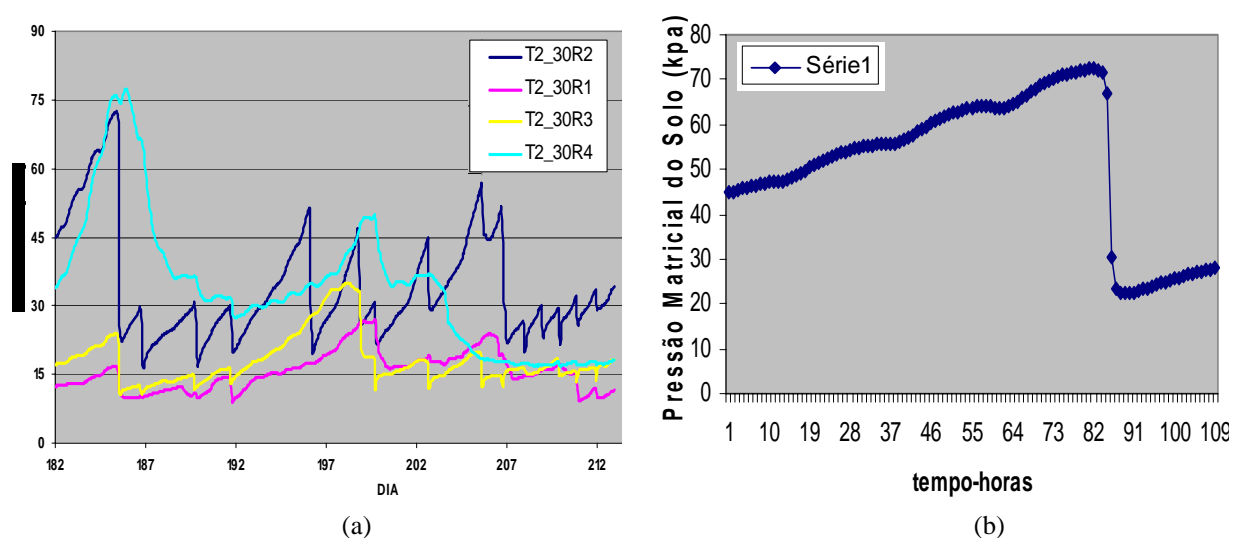


Figura 1 – (a) Evolução do Potencial Mátrico do Solo em quatro sensores do tratamento quatro. (b) Curva de Retenção de Água no solo, estimada com dados do sensor .

A variação de comportamento dos sensores pode ser atribuída a vários fatores, dentre eles podemos destacar: instalação inadequada, variação da uniformidade do solo, e interação com meio ambiente. Dessa forma, a escolha de dados através da análise do comportamento do sensor é relevante para o desempenho correto da RNA. Na **Figura 1.a** temos dados de trinta dias do mês de julho de 2006, a notação utilizada para definir o tempo (eixo horizontal) é o dia Juliano. Analisando o gráfico da **Figura 1.a**, o sensor T2_30R2 apresenta o melhor

desempenho. Dessa forma, os dados que geram suas curvas podem ser pré-processadas para serem utilizadas na RNA.

O desempenho da rede está associada à precisão dos dados utilizados para seu treinamento e validação. Desta maneira, usar dias como grandeza de tempo, tornaria impreciso os resultados obtidos na estimativa, de maneira que a amostragem do tempo é feita em horas. A **Figura 1.b** mostra um exemplo da curva de retenção de água, em horas, utilizada para a obtenção dos dados de treinamento e validação da rede. A RNA utilizada para estimar a curva de retenção de água no solo foi uma rede MLP com 24 entradas, 24 saídas, e uma camada escondida, ela é treinada em 3000 iterações, e suas funções de ativação são sigmóides. Dada a simplicidade da arquitetura da RNA adotada, esta pode ser implementada em microcontroladores, ou até mesmo na plataforma do programa utilizado no sistema de aquisição de dados. Essa é uma das motivações na escolha deste tipo de rede, a outra seria sua grande capacidade para resolver problemas que envolvem estimativa (ANGELICO, 2005). Esta rede neural artificial foi implementada no Matlab versão 7.0.1.

RESULTADOS E DISCUSSÃO

A rede MLP (HAYKIN, 1999) implementada apresenta uma aproximação eficiente da curva de retenção de água no solo, como podemos observar na **Figura 2.a**.

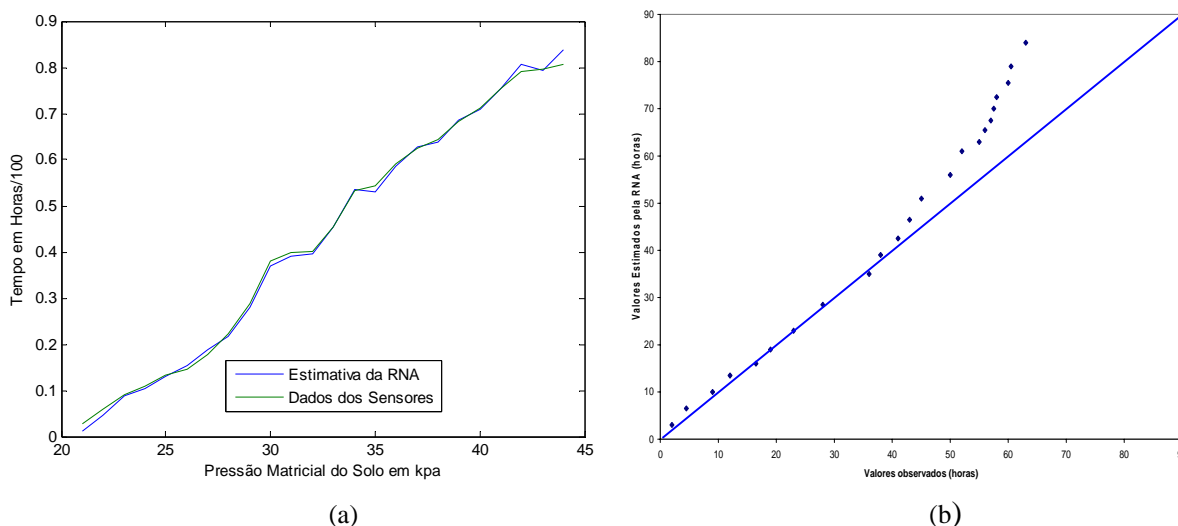


Figura 2 – (a) Gráfico gerado com a utilização da RNA. (b) Gráfico de validação da RNA.

A curva azul representa a estimativa obtida com a RNA, enquanto a curva verde é o dado real coletado. A **Figura 2.b** apresenta o gráfico gerado de dados obtidos pela estimativa da RNA e dados gerados pelos sensores instalados na área experimental escolhidos para a validação da RNA. A reta de tendência da curva está próxima de 45°, logo os valores obtidos

com o treinamento da RNA podem ser utilizados como estimativa confiável.

CONCLUSÕES

Quantos sensores poderíamos usar em um hectare de irrigação com automação? Essa seria uma pergunta de difícil resposta. No entanto, aplicado um estimador dentro do programa que faz o controle da irrigação, com certeza a resposta da pergunta anterior fica mais óbvia. Como essa rede é um programa simples, há possibilidade de se colocar em controles que fazem seu processamento através de microcontroladores. A estimativa permite também prever o tempo em pontos que o sensor não estava ligado e que se precisa ter dados para fazer a otimização da irrigação.

BIBLIOGRAFIA

- ANGELICO, J. C. Desempenho das Redes Neurais Artificiais na Estimativa das Variáveis Físicas e Químicas do Solo. 2005. Tese (Doutorado em Energia (Botucatu)) – UNESP.
- CANAFISTULA, F. J. F.; TEIXEIRA, A. S.; RIBEIRO, R. S. F.; GONDIM, R. S. & MIRANDA, F. R. Controle de Malha Fechada para Irrigação de Precisão. Integração e Tecnologia Moderna, Brasília, v. 67, p.82-85, 2005.
- CINTRA, F. L. D.; LIBARDI, P. L. & SAAD, A. M. Balanço Hídrico no Solo para Portas-enxerto de Citros em Ecossistema de Tabuleiro Costeiro. Revista Brasileira de Engenharia Agrícola e Ambiental, v.4, n.1, p.23-28, 2000 Campina Grande, PB, DEAg/UFPB.
- DEMUTH, H. ; BEALE, M. Neural Network Toolbox – For Use with Matlab. User's Guide, version 3, 1998.
- HAYKIN, S., Neural Networks 2^o Ed., Prentice-Hall, New Jersey, 1999.
- RIBEIRO, R.S.F. & YODER, R.E. An Automated Fuzzy Irrigation Control System. In Proceedings: The 18th Annual Irrigation Association Exposition and Technical Conference, American Irrigation Association, Nashville, pp. 171-178, 1997.
- SOUZA, O. T. L. Desenvolvimento de um Modelo Fuzzy para Determinação do Calor com Aplicação em Sistemas de Irrigação. 2004. 113f. Tese (Doutorado em Agronomia/ Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu. 2004.
- YODER, R.E.; JOHNSON, D.L.; WILKERSON, J.B.; YODER, D.C. *Soil water sensor performance*. American Society of Agricultural Engineers, v. 14, n. 2, p. 121-133, 1998.