

REDES NEURAIIS ARTIFICIAIS E AGRICULTURA DE PRECISÃO PARA RECOMENDAÇÃO DE ADUBAÇÃO DA CULTURA DA GOIABEIRA ¹

Silvia Helena Modenese Gorla da Silva², André Carlos Ponce de Leon Ferreira de Carvalho³, Roseli Aparecida Francelin Romero⁴, Paulo Estevão Cruvinel⁵, William Natale⁶

Recebido para publicação em 09/04/2002

Aprovado para publicação em 28/03/2004

RESUMO: *Este trabalho investiga o uso de Redes Neurais Artificiais como ferramenta de suporte para a determinação das necessidades de adubação da cultura da goiabeira utilizando agricultura de precisão. O método foi aplicado para o estudo do elemento químico fósforo.*

Palavras-chave: *redes neurais, adubação, séries temporais, agricultura de precisão, goiabeira*

ARTIFICIAL NEURAL NETWORKS AND PRECISION FARMING FOR GUAVA TREE FERTILIZATION

ABSTRACT: *This work investigates the use of Artificial Neural Networks as a support tool for the determination of the guava tree culture fertilization needs using precision farming. The method was applied to the study of the chemical element phosphor.*

Keywords: *neural networks, fertilization, time series, precision farming, guava tree*

1 INTRODUÇÃO

No processo de adubação, nutrientes são utilizados para corrigir necessidades associadas à escassez do solo e à exigência da cultura. Na adubação clássica, essas necessidades são definidas estatisticamente para todo o terreno, não levando em conta a variação normalmente existente em diferentes áreas de um mesmo terreno. O atendimento

às necessidades de diferentes áreas do terreno é o principal objetivo da agricultura de precisão. Adicionalmente, as necessidades podem ser alteradas com o passar do tempo, de forma que não somente a variabilidade espacial, mas também, temporal devem ser observados.

Quando estas variações, espacial e temporal, não são levadas em consideração, a reposição de nutrientes é

¹Parte da Dissertação de mestrado da 1ª autora intitulada: Algoritmo para Recomendação de Nutrientes em Campos Agrícolas Baseado em Técnicas do Processamento de Sinais e Imagens

²Doutoranda, Instituto de Ciências Matemáticas e de Computação, Departamento de Computação e Estatística, USP – São Carlos/SP – Brasil, silviah@icmc.sc.usp.br

³Professor associado, Instituto de Ciências Matemáticas e de Computação, Departamento de Computação e Estatística, USP – São Carlos/SP – Brasil, andre@icmc.sc.usp.br

⁴ Professora associada, Instituto de Ciências Matemáticas e de Computação, Departamento de Computação e Estatística, USP – São Carlos/SP – Brasil, rafrance@icmc.sc.usp.br

⁵ Pesquisador, Embrapa/CNPDI – São Carlos/SP – Brasil, cruvinel@cnpdia.embrapa.br

⁶ Professor adjunto, Departamento de Solo e Adubos, FCAV/UNESP - Jaboticabal/SP – Brasil, natale@fcav.unesp.br

feita segundo um único nível de nutrientes, ou seja, a aplicação é feita homogeneamente, utilizando uma única fórmula de adubo ou quantidade para um nutriente.

O principal objetivo este trabalho é a utilização de Redes Neurais Artificiais (RNAs) para a recomendação de adubação correta de fósforo para a cultura da goiabeira. RNAs são utilizadas para analisar a variabilidade temporal, conforme investigado em Modenese (1998). Esta análise tem por objetivo permitir uma reposição de nutrientes levando em consideração a variabilidade espacial e temporal presente em campos agriculturáveis. A justificativa para a utilização desta técnica está no bom desempenho apresentado por ela em problemas semelhantes.

Devido à pequena quantidade de amostras disponíveis, foram aplicados conceitos da geoestatística para estimar a variação espacial. Assim, considerando o custo da amostragem e da análise química das amostras de solo, foi possível amostrar uma quantidade bem menor de amostras. Posteriormente, por meio de um estudo geoestatístico, foram estimados pontos não amostrados. Para a estimativa da dependência espacial foi utilizada uma ferramenta da geoestatística chamada semivariograma. Após a obtenção de um semivariograma, que demonstra a correlação espacial, foi possível estimar valores em qualquer posição dentro do campo, sem tendência e com variância mínima, por meio de um método de interpolação proveniente da geoestatística, chamado krigagem (Burgess & Webster, 1980-I; Burgess & Webster, 1980-II). Neste trabalho, a utilização do método de krigagem gerou índices de nutrientes para locais não amostrados. O nome “krigagem” foi dado em homenagem ao matemático sul africano, Krige (Matheron, 1963).

RNAs têm sido aplicadas com sucesso em diversos problemas de agropecuária: Lima Neto & Ludermir (1997) utilizam RNAs em um sistema de suporte à decisão para colheita de cana-de-açúcar; Patel et al. (1998) utilizam RNAs no desenvolvimento de um sistema inteligente para seleção de ovos; Yakov et al. (1999) aplicam RNAs para estimação da condutividade hidráulica em solos; Yang et al. (2000) utilizam RNAs para a classificação de plantas, procurando distinguir plantações novas das ervas daninhas; Salehi et al. (2000) aplicam RNAs para a predição de perdas de nitrogênio na volatilização; Leung & Tran (2000) fazem uso de RNAs na predição de surtos em camarões; De la Rosa et al. (2000) aplicam RNAs na avaliação da vulnerabilidade do solo à erosão, buscando

analisar o impacto causado na produtividade das culturas.

Além disso, RNAs vêm sendo continuamente aplicadas nas mais diversas áreas, tais como, reconhecimento de padrões, processamento de sinais, controle otimização, previsão de séries temporais, reconhecimento de voz e controle de doenças. (Romero, 1993; Santos, 1994; Ballini, 1996; Diniz & Thomé, 1997; Diniz et al., 1998; Gonçalves et al., 1998; Junior et al., 1998.).

Quando RNAs são utilizadas para a análise temporal, deve-se analisar o histórico do terreno, em relação à concentração de nutrientes, aplicando-se estudos de séries temporais. Neste trabalho foi desenvolvido um estudo que leva em consideração amostras provenientes de diferentes instantes de tempo. O estudo geoestatístico foi aplicado em cada um dos instantes considerados.

Este artigo está organizado da seguinte forma. A Seção 2 apresenta os principais conceitos relacionados às RNAs, técnica utilizada neste trabalho. A Seção 3 descreve os experimentos realizados. Finalmente, na Seção 4 são apresentadas as principais conclusões.

2 CONCEITOS BÁSICOS DE RNAS

RNAs são técnicas computacionais baseadas na estrutura e funcionamento do sistema nervoso. Ao contrário das técnicas convencionais de computação, em que um programa de computador precisa ser desenvolvido para resolver um dado problema, elas aprendem a resolver problemas por aprendizado e experiência, como ocorre com os seres humanos.

RNAs são uma alternativa à utilização de técnicas estatísticas para a classificação e agrupamento de dados (Braga et al., 2000). Elas podem também ser utilizadas para encontrar correlações e agrupamentos naturais entre dados. Diferente de muitas das técnicas estatísticas utilizadas, para que RNAs sejam empregadas não é necessário conhecer a distribuição estatística dos dados.

RNAs são estruturas distribuídas formadas por um grande número de unidades de processamento (que simulam os neurônios), bastante simplificadas e conectadas entre si. Essas conexões são implementadas por canais de comunicação que estão associados a um determinado peso. As unidades realizam operações apenas sobre seus dados locais, que são entradas recebidas através das suas conexões. A Figura 01 ilustra uma RNA típica.

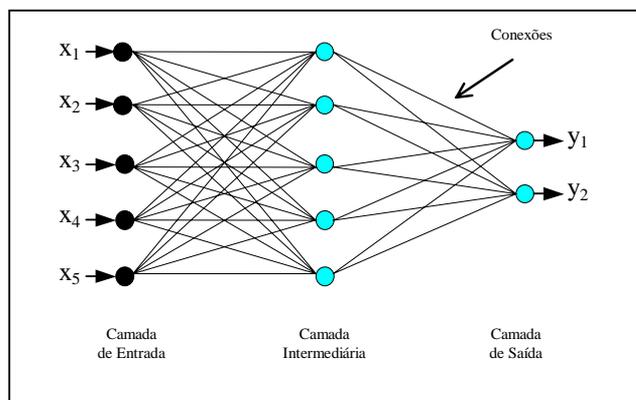


Figura 01 - Rede Neural Artificial Típica.

As RNAs apresentam características particulares, tais como: capacidade de aprender, generalizar, agrupar ou organizar dados; não linearidade; mapeamento entrada saída; adaptabilidade; respostas com níveis de confiança; agregação de informação contextual; tolerância a falhas; uniformidade de análise e projeto e analogia neurobiológica (Braga et al., 2000).

O conhecimento da rede é adquirido por meio de um processo de treinamento no qual valores de pesos associados a conexões entre as unidades são ajustados por meio de um algoritmo de treinamento. Durante o processo de treinamento, exemplos são apresentados à RNA.

Uma RNA é especificada principalmente pela sua topologia, pelas características de seus neurônios e pelo seu algoritmo de treinamento. O processo de treinamento varia de acordo com a topologia da rede (Haykin, 1994).

Este trabalho mostra o uso de RNAs, especificamente redes MLP (Multi-Layer-Perceptron) treinadas com o algoritmo backpropagation (Rumelhart et al., 1986), para a predição de séries temporais, com o objetivo de melhorar o processo de adubação para a cultura da goiabeira.

3 MATERIAIS E MÉTODOS

Para a área de experimentação, 100 x 100 m², foram

simuladas 25 amostras. As amostras foram simuladas a um espaçamento de 25 metros uma das outras. Para o estudo geostatístico, os dados foram interpolados a uma distância de 5m, sendo gerados, portanto, 441 pontos.

Com base na predição de séries temporais, foi analisado o “histórico” do terreno em quatro instantes: t_1 , t_2 , t_3 e t_4 . A partir desses dados de entrada, que é um arquivo texto contendo os resultados gerados durante a fase da análise geostatística (krigeagem), foi estimado um t_5 , em cima do qual foi feita a recomendação de adubação. Nos experimentos realizados com as RNAs, os quatros tempos krigados foram utilizados como dados de entrada, e o tempo estimado (t_5) como saída desejada.

A implementação foi realizada utilizando a ferramenta MATLAB, versão 5.2. Esta ferramenta possui um módulo especial para redes RNAs, chamado **Tool box Neural Network**. Também foi utilizada, para um pré-processamento, a planilha eletrônica MS-Excel.

Inicialmente, foi selecionado o modelo da rede. A rede escolhida foi a rede MLP, treinada com o algoritmo backpropagation. Esta escolha foi motivada por esta rede ser a mais utilizada em aplicações de séries temporais. Maiores detalhes sobre o algoritmo backpropagation podem ser encontrados em Braga et al., (2000); Haykin (1994); Rumelhart(1986).

Para avaliar o desempenho da rede, foi escolhida uma técnica estatística, chamada validação cruzada (Haykin, 1994). Esta técnica divide o conjunto de dados, aleatoriamente, em conjunto de treinamento e conjunto de teste. O conjunto de treinamento representa, aproximadamente, 2/3 do conjunto de dados e, por sua vez, é dividido em um subconjunto usado para estimar o modelo (treinamento da rede); e em um subconjunto para avaliar o desempenho do modelo (validação do modelo), este subconjunto é formado por, geralmente, 10 a 20% do conjunto de treinamento.

O Quadro 01 demonstra o preparo feito para a validação cruzada.

Quadro 01 - Conjuntos de dados utilizados na validação cruzada.

Descrição	N.º de Exemplares
Conjunto de dados total	441
Subconjunto utilizado para o teste final da rede	141
Subconjunto total para o treinamento da rede	300
Subconjunto do utilizado para estimar o modelo	250
Subconjunto utilizado para avaliar o desempenho do modelo	50

Para este pré-processamento dos dados foi utilizada a planilha eletrônica MS-Excel®.

O próximo passo consistiu em selecionar outros parâmetros, nos quais os testes foram baseados. Com relação à topologia da rede, optou-se por utilizar duas camadas

intermediárias e variar o número de neurônios em ambas as camadas intermediárias utilizadas. Optou-se por utilizar a taxa de aprendizagem igual a 0.6 e constante momentum igual a 0.01. O Quadro 02 ilustra diferentes topologias adotadas para testes.

Quadro 02 - Valores adotados para teste de topologia.

N.º de neurônios na 1ª camada intermediária	N.º de neurônios na 2ª camada intermediária
6	6
11	11
20	20

Para a recomendação de adubação, levou-se em consideração que a aplicação de nutrientes de um campo agrícola é feita segundo os teores do solo e as necessidades que determinada cultura possui desses nutrientes. Foi, assim, necessária a elaboração de tabelas de adubação, de acordo com as exigências e características da cultura em questão, bem como o tipo de solo. A cultura escolhida para efeitos demonstrativos do método foi a da goiabeira. A escolha deu-se não só pela experiência com trabalhos anteriores, mas, também, por ser uma cultura de forte

expressão na região central e nordeste do estado de São Paulo. As tabelas de adubação utilizadas condensam resultados de pesquisas com adubação realizadas durante oito anos com a cultura da goiabeira, segundo Natale et al. (1996).

3 RESULTADOS E DISCUSSÕES

O processo de treinamento das redes foi realizado de

acordo com o método da validação cruzada.

A Figura 02 demonstra os diferentes erros quadráticos médios para cada um dos testes realizados.

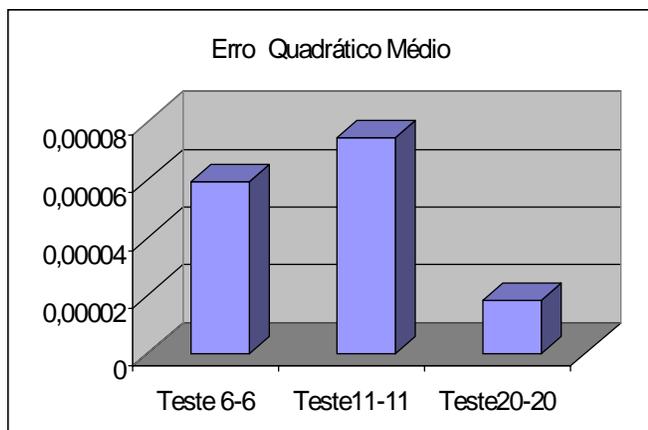


Figura 02 - Erros Quadrático Médio obtidos no processo de treinamento.

A Figura 02, que ilustra o erro quadrático médio, mostra que o teste que apresentou menor erro foi com duas camadas intermediárias, ambas com 20 neurônios.

Figura 03, seguir, apresenta os valores obtidos na estimação estocástica e no treinamento da rede.

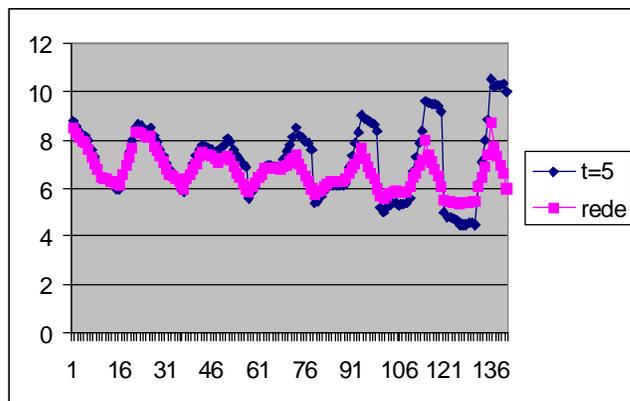


Figura 03 - Valores de fósforo obtidos na predição estocástica em comparação o uso de RNAs.

A análise do efeito do uso de RNAs na recomendação de adubação permite observar uma pequena alteração

de quantia de adubação. O Quadro 03 demonstra esta variação, bem como o local onde a mesma ocorreu.

Coordenadas da Célula	P (resina) t=5	P (resina) Rede	Doses de P ₂ O ₅ em g/cova para t=5	Doses de P ₂ O ₅ em g/cova para rede
70 - 100	5,99	6,17	180	140
85 - 05	5,84	6,05	180	140
90 - 15	5,83	6,05	180	140
95 - 50	5,56	6,01	180	140
100 - 100	10	5,96	140	180

4 CONCLUSÕES

O uso de redes MLP treinadas com o algoritmo backpropagation mostrou seu grande potencial para a recomendação de adubação correta de fósforo para a cultura da goiabeira, levando-se em consideração princípios da agricultura de precisão.

Propondo uma nova técnica para a avaliação das necessidades de uma forma mais precisa, este trabalho teve o objetivo de mostrar o potencial da utilização de RNAs como ferramenta para uma melhor representação e interpretação das necessidades de nutrientes em agricultura de precisão. Espera-se, como resultado desta inves-

tigaçãõ, que a t cnica seja utilizada como apoio para a recomendaçãõ da reposiçãõ de f sforo adequada na implantaçãõ da cultura da goiabeira.

Foi apresentada neste artigo uma aplicaçãõ pr tica, com a recomendaçãõ de adubaçãõ baseada nos conceitos de variabilidade espacial e temporal, ilustrando o potencial da aplicaçãõ de RNAs em ci ncias agron micas.

Embora o m todo tenha sido demonstrado para a cultura da goiabeira, esta metodologia pode ser aplicada outras culturas de interesse.

Desta maneira, podem ser sugeridas v rias propostas de trabalhos futuros, tais como: aplicaçãõ de RNAs durante a an lise de variabilidade espacial (geoestat stica); testes com outros modelos de RNAs, diferentes topologias e diferentes valores para os par metros de treinamento; testes com valores colhidos de campo, bem como a resposta da cultura para diferentes adubações; possibilidade da aplicaçãõ de t cnicas de mineraçãõ de dados na fase de interpretaçãõ de resultados; realizaçãõ de um estudo geo-referenciado.

5 REFER NCIAS BIBLIOGR FICAS

- BALLINI, R.** Redes Neurais Artificiais para Previs o Chuva Vaz o, **Dissertaç o de Mestrado, ICMC – USP – S o Carlos/SP, 1996.**
- BURGESS, T.M., WEBSTER, R. Optimal interpolation and isarithmic mapping of soil properties. I. The semi-variogram and punctual kriging. *Jour. Soil Sci.* 31:315-331, 1980
- BURGESS, T.M., WEBSTER, R. Optimal interpolation and isarithmic mapping of soil properties. II. Block kriging. *Jour. Soil Sci.* 31:333-341, 1980.
- BRAGA, A. P., CARVALHO, A. P. L. F., LUDERMIR, T. B. **Redes Neurais Artificiais: Teorias e Aplicaç es.** Rio de Janeiro: Editora LTC, 2000.
- DE LA ROSA, D. MORENO, J. MAYOL, F. BONSON, T. Assessment of soil erosion vulnerability in western Europe and potential impact on crop productivity due to loss of soil depth using the ImpelERO model. *Agriculture Ecosystems & Environment*, v. 81, p.179-190, 2000.
- DINIZ, S., THOM , A. G. **Uso de T cnica Neural para o Reconhecimento de Comandos   Voz.** In: S mpoio Brasileiro de Redes Neurais, 4, 1997, Universidade Federal de Goi s, Goi nia, 1997.
- DINIZ, H., ANDRADE, L. C. M., CARVALHO, A. C. P. L. F., ANDRADE, M. G. **Previs o de S ries Temporais Utilizando Redes Neurais Artificiais e Modelos de Box&Jenkins,** S mpoio Brasileiro de Redes Neurais, Universidade Federal de Minas Gerais, Belo Horizonte, 1998.
- JUNIOR, F. M. B., FECHINE, J. M., NETO, B. G. A. **“Algoritmo Modificado de Kohonen Aplicado ao Projeto de Dicion rios de Padr es Ac sticos para Reconhecimento de Locutor”** In: S mpoio Brasileiro de Redes Neurais, 5, 1998, Universidade Federal de Minas Gerais, Belo Horizonte, 1998.
- LEUNG, P. TRAN, L. T. Predicting shrimp disease occurrence: artificial neural networks vs. logistic regression. *Aquaculture*, v. 187, p. 35-49, 2000.
- LIMANETO, F. B., LUDERMIR, T. B. **“Suporte a Decis o para Colheita de Cana-de-a car”**, IV S mpoio Brasileiro de Redes Neurais, Universidade Federal de Goi s, Goi nia, 1997.
- MATHERON, G. Principles of geostatistics. *Econ. Geology*, 58: 1246- 1266, 1963.
- MODENESE, S. H. **“Algoritmo para Recomendaç o de Nutrientes Agr colas Baseado em T cnicas de Processamento de Sinais e Imagens”**, Dissertaç o de Mestrado, Universidade Federal de S o Carlos / SP, 1998.
- NATALE, W.; MODENESE, S. H. Software para recomendaç o da calagem e adubaç o da goiabeira: Congresso Brasileiro de Fruticultura, 14, 1996, Curitiba, PR. **Resumos.** Londrina: IAPAR, 1996.
- PACHEPSKY, Y.A. TIMLIM, D.J. AHUJA, L.R. Estimating saturated soil hydraulic conductivity using water retention data and neural networks. *Soil Science.* v. 164, n. 8, 1999.
- PATEL, V.C. MCCLENDON, R.W. GOODRUM, J.W. Development and evaluation of an expert System for egg sorting. *Computers and Electronics in Agriculture.* v.20, p.97-116, 1998.
- ROMERO, R. A. F. **Otimizaç o de Sistemas Atrav s de Redes Neurais Artificiais,** Tese de Doutorado, FEE – UNICAMP – Campinas/SP, 1993.
- SALEHI, F. PRASHER, S.O. AMIN, S. MADANI, A. JEBELLI, S.J. RAMASWAMY, H.S. TAN, C. DRURY, C.F. Prediction of annual nitrate-N losses in drain outflows with artificial neural networks. *Transactions of the Asae*, v. 43, p. 1137-1143, 2000.
- SANTOS, V. P. **“Aplicaç o de Redes Neurais no Reconhecimento de Doenç s do Cora o Utilizando o MATLAB”**, Projeto de Graduaç o – ICMC – USP, S o Carlos/SP, 1994.
- YANG, C.C. PRASHER, S.O. LANDRY, J.A. RAMASWAMY, H.S. DITOMMASO, A. Application of artificial neural networks in image recognition and classification of crop and weeds. *CANADIAN AGRICULTURAL ENGINEERING*, v. 42, n.3, p. 147-152, 2000.