

PREVISÃO DA RECEPÇÃO DE LEITE EM USINAS LATICINISTAS: UMA APLICAÇÃO DE REDES NEURAIS¹

Carlos Arthur B. da Silva² e Elaine Berges da Silva³

RESUMO - As redes neurais simulam a estrutura de aprendizado e generalização do cérebro humano. A partir de observações sobre relações entre variáveis, as redes podem ser treinadas para generalizar tais relações para novos dados. Uma aplicação desta tecnologia para o problema de previsão da recepção de leite é apresentada neste trabalho. Os resultados demonstram um potencial encorajador das redes neurais para aplicações desta natureza.

Termos para indexação: redes neurais, séries temporais, previsão, leite.

FORECASTING MILK RECEPTION AT DAIRY PLANTS: AN APPLICATION OF NEURAL NETWORKS

ABSTRACT - Neural networks simulate the human brain's ability to learn and generalize. Based on observations about relationships among variables, the networks can be trained to generalize such patterns to new data. An application of this technology to the problem of forecasting milk reception in a dairy plant is presented. Results indicate an encouraging potential for neural network use in similar applications.

Index terms: neural networks, time series, forecasts, milk

INTRODUÇÃO

As redes neurais (RN's) constituem uma tecnologia fundamentada em estudos do cérebro e do sistema nervoso. Pesquisadores procuram, com essa tecnologia, desenvolver equipamentos e sistemas capazes de executar, eficientemente, tarefas para as quais os computadores convencionais não apresentam desempenho satisfatório.

1 Recebido em 14.12.94

Aceito para publicação em 19.04.95

2 Econ. Agric., Ph.D., Professor Titular da Univ. Fed. de Viçosa, DTA, 36571-000, Viçosa, MG, E-mail: USERCABS@VM.LNCC.BR

3 Engenheira de Alimentos, ex-bolsista de iniciação científica da Univ. Fed. de Viçosa. Trabalho realizado com o apoio do CNPq.

O ser humano é muito eficiente em tarefas como, por exemplo, o reconhecimento de uma imagem, ou a identificação de um padrão em uma sequência de informações. Por outro lado, mesmo os mais modernos computadores tem dificuldade para lidar com esses tipos de problema, os quais têm sido abordados com o auxílio das RN'S.

Para entender o conceito de uma RN, torna-se necessário discutir brevemente a estrutura biológica do cérebro humano, conforme exemplificado pelo programa NeuralWorks Demo, da empresa americana NeuralWare Inc. (ANON., 1990). Segundo esse texto eletrônico, o neurônio é a unidade celular fundamental do cérebro, e pode ser caracterizado como uma unidade simples de microprocessamento, que recebe e combina sinais de vários outros neurônios, através de estruturas conhecidas como dendritos. O cérebro é composto de dezenas de bilhões de neurônios, densamente interconectados. A relação de contato entre os dendritos dos neurônios é conhecida como sinapse. Esta é de natureza química, mas possui efeitos colaterais elétricos, os quais são mensuráveis. A força da sinapse é alterada quando o cérebro "aprende" (ANON., 1990).

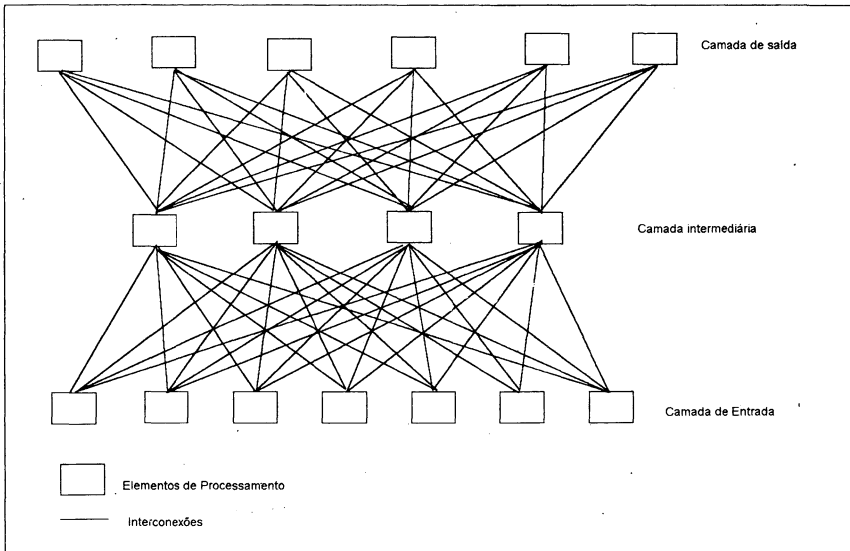
Para simular uma RN biológica, os pesquisadores da área de inteligência artificial (IA) estabeleceram uma estrutura na qual cada neurônio artificial é conhecido como elemento de processamento (EP). Esses elementos são interligados entre si, de modo que cada um possa receber e enviar sinais. Os sinais são modulados através de fatores que alteram o nível de estímulo, de sorte que, em resposta ao sinal recebido, o elemento de processamento gere ou não uma resposta. (ANON., 1990; OBERMEIER & BARRON, 1989).

Os sinais recebidos por um EP são acumulados através de um somatório ponderado, conhecido como "ativação interna", que é transformada por uma função matemática, geralmente uma sigmóide ou tangente hiperbólica. A estrutura de pesos usada nas ponderações simula a sinapse biológica, e é alterada por ajustamentos sucessivos até que os resultados desejados possam ser obtidos. Neste processo, a RN "aprende", a exemplo do cérebro humano, usando, para tanto, uma das dezenas de regras de aprendizado já estabelecidas pelos pesquisadores da IA. A chamada regra de "propagação retroativa" ("back-propagation") é a mais usada. (CARDILL, 1988; THOMAS, 1989; ANON., 1990)

Na estrutura esquemática de uma RN artificial pode ser observada a disposição dos EP'S em camadas e as interconexões entre os mesmos (Figura 1). Em geral, os EP'S são dispostos em uma camada de entrada ("input layer"), uma ou mais camadas intermediárias ("hidden layers") e uma camada de saída ("output layers"). Durante o treinamento da rede, os pesos que definem as interconexões são ajustados, até que, para um determinado conjunto de dados de entrada, sejam obtidas as saídas desejadas.

Figura 1

Representação esquemática de uma rede neural



A característica apresentada por uma RN de poder aprender a partir de exemplos é que a torna particularmente interessante para aplicações em um grande número de atividades. Na área de inteligência artificial, com a tecnologia de sistemas especialistas, é necessário que um "expert humano" explicita as regras que definem seu conhecimento a respeito da solução de um problema (SILVA, 1990). Somente de posse dessas regras é que o programador pode construir o sistema. Com a RN, isso não é necessário. A rede aprende automaticamente as regras para processar o conhecimento, usando os exemplos de dados a ela submetidos.

Embora a tecnologia seja muito recente, já são apontadas na literatura algumas aplicações interessantes. ORRIS & FEESER (1990) desenvolveram uma RN para análise exploratória de dados com o objetivo de detectar relações não óbvias do ponto de vista teórico ou experimental. FOSTER *et alli* (1991), assim como SHARDA & PATIL (1990), utilizaram RN'S para a previsão de séries temporais irregulares, enquanto que

UHRIG (1991) as empregou para prever o rendimento de culturas agrícolas nos EUA. Em recente congresso conjunto da Sociedade Americana de Pesquisa Operacional e do Instituto de Ciências Gerenciais, foram apresentados cerca de duas dezenas de trabalhos sobre aplicações de RN's (TIMS/ORSA, 1991). Aplicações existem ainda nas áreas de controle de processos, previsões financeiras, classificação, reconhecimento de padrões em linhas de montagem, síntese da fala, diagnósticos médicos e marketing direcionado, entre muitas outras (ANON., 1991).

Este trabalho apresenta uma aplicação das redes neurais para o problema de previsão de recepção de leite em uma empresa laticinista. Este tipo de previsão possui um papel importante no desenvolvimento de um planejamento de produção. Para a indústria de laticínios, a obtenção de maior produtividade nas operações de processamento é uma necessidade constante, em função das peculiaridades de matéria-prima e produtos com que opera. A indústria de pequeno e médio porte, em particular, deve buscar continuamente a redução de seus custos operacionais como estratégia de sobrevivência, especialmente à luz da concorrência oferecida pelas grandes cooperativas e multinacionais que operam no setor. O melhor planejamento da produção, associado a um controle de qualidade capaz de reduzir desperdícios e custos, e de assegurar a manutenção das parcelas do mercado consumidor, são algumas das estratégias para a melhoria da produtividade operacional.

METODOLOGIA

Dados e Recursos Computacionais Utilizados

Para o desenvolvimento do trabalho, foram utilizados dados de recepção mensal de leite fornecidos por uma empresa de pequeno porte, localizada na Zona da Mata de Minas Gerais, no período compreendido entre janeiro de 1989 e dezembro de 1993. A empresa tem capacidade de recepção estimada em 20000 litros/dia.

Os dados obtidos foram tabulados com o auxílio de programa LOTUS 1-2-3 (Lotus Development Corporation). Para o treinamento da rede e realização das previsões, utilizou-se o "software" @BRAIN (Talon Development Corporation), que é executado como "add-in" do LOTUS 1-2-3. O "software" foi executado em um microcomputador compatível com o padrão IBM-PC 80486 DX-2 66MHZ.

Definição da estrutura da rede neural

A previsão de séries temporais por meio de rede neurais requer, em primeiro lugar, a definição de uma topologia onde se definam os elementos das camadas de entrada, intermediária e de saída. Traçando-se um paralelo com os modelos econométricos tradicionais, a camada de entrada corresponderia às variáveis independentes, enquanto que a camada de saída equivaleria a uma ou a mais variáveis dependentes. A partir de

experiências relatadas na literatura (SHARDA & PATIL, 1990; RAPOSO, 1992), optou-se por utilizar um modelo recursivo, no qual a recepção de leite em um determinado período (camada de saída), seria "explicada" pela recepção no mês, bimestre, semestre e ano anteriores. Estas defasagens foram consideradas suficientes para captar os efeitos da sazonalidade típica da região onde se localiza a usina laticinista, onde as variações de oferta de leite entre os períodos de safra e entressafra chegam a mais de 50% da capacidade de recepção. Utilizou-se apenas uma camada intermediária, cujo número de elementos de processamento foi definido automaticamente pelo "software" utilizado. Assim, a rede foi constituída por quatro elementos de processamento de entrada, quatro elementos em uma camada intermediária, e um elemento na camada de saída.

Deve ser observado que as definições utilizadas são, necessariamente, arbitrárias. Com relação à estrutura do modelo, poder-se-ia, alternativamente, utilizar variáveis explicatórias tais como preços, índices de qualidade de pastos e outras, como camada de entrada. Esta alternativa ao modelo recursivo requereria, no entanto, dados que não estavam imediatamente disponíveis. Quanto ao número de camadas intermediárias da rede, não existem evidências conclusivas na literatura sobre a maior eficiência da utilização de um número superior que um (Talon Development Co., 1992). Por outro lado, o número de elementos de processamento da camada intermediária pode ser ajustado a critério do formulador do modelo. Teoricamente, quanto maior esse número, maior a complexidade das funções modeladas pela rede. Contudo, a experiência com o uso do "software" em outros problemas estudados pelos autores mostrou que a determinação automática produz resultados bastante satisfatórios.

Treinamento da Rede

O treinamento da rede requer a especificação de um subconjunto dos dados para essa finalidade, e de um outro, para testes. Cerca de 90% das observações foram aleatoriamente selecionadas para o treinamento, ficando os restantes 10% reservados para os testes. Estabeleceu-se uma tolerância de 0,07 como critério para se estabelecer se um valor calculado pela rede é considerado aceitável. Esta tolerância corresponde à uma fração do intervalo entre o maior e menor valor dos dados da camada de saída. Quanto menor a tolerância, maior a precisão da rede. Como critério de conclusão do treinamento, adotou-se a minimização da raiz do quadrado médio dos erros dos dados de teste. O treinamento da rede foi feito em aproximadamente 80 minutos de processamento.

RESULTADOS E DISCUSSÃO

A rede conseguiu prever cerca de 68% das observações utilizadas para o treinamento, dentro do critério de tolerância considerado. Em termos práticos, para a tolerância de 0,07 aqui definida, a previsão é considerada correta quanto o volume mensal

previsto difere do volume observado dentro de um intervalo máximo de 4,7% em torno da média das observações. Isto corresponde a um erro máximo de previsão equivalente a cerca de 14600 litros mensais, o que pode ser considerado razoável, considerando-se a capacidade de recepção da usina. Na média, o erro de previsão computado para os dados usados no treinamento foi de 4,13% (Tabela 1).

TABELA - Estatísticas do treinamento da Rede

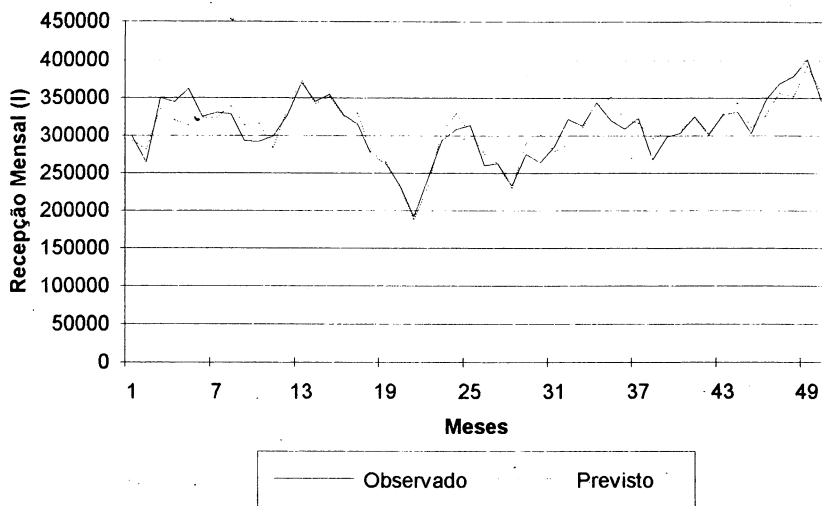
Número de observações	40
Previsões corretas	27
Erro médio de previsão	4,13%
Coefficiente de determinação	0,8767

O coeficiente de determinação entre os valores previstos e observados é outro indicador da eficiência relativa da rede neural para este problema específico. Aproximadamente 88% das variações nos valores previstos são explicadas pelas variações nos valores observados. Obteve-se, portanto, nível relativamente alto de ajuste, tanto nos dados usados para treinamento quanto para teste (Tabela 2 e Figura 2).

TABELA 2 - Estatística de Teste

Número de observações	10
Previsões corretas	7
Erro médio de previsão	4,25%
Coefficiente de determinação	0.6680

Figura 2 - Valores observados x previstos pela rede



Uma vez considerada suficientemente treinada, a rede pode então ser utilizada para efetuar previsões dos valores futuros da recepção na usina. Para esta finalidade, o modelo recursivo utilizado mostrou-se bastante adequado, pois os valores da camada de entrada, necessários para a previsão, são conhecidos.

CONCLUSÕES

A tecnologia de redes neurais, embora relativamente recente, já tem suas aplicações bastante difundidas nas mais diversas áreas do conhecimento. Para a previsão de séries temporais, as redes têm se mostrado altamente eficientes, e, por este motivo, o setor financeiro por exemplo, tem sido um grande usuário de suas aplicações (LAWRENCE, 1991; NELSON & ILLINGWORTH, 1991; RAPOSO, 1993).

No presente trabalho, a tecnologia demonstrou um potencial encorajador para aplicações similares. Quando comparada a metodologias convencionais de previsão de séries temporais, as redes apresentam a vantagem de não requererem conhecimentos avançados de econometria para uma utilização eficiente. A partir de observações passadas, a rede "aprende" a relação entre os dados de entrada e saída e usa esse "conhecimento" para efetuar as previsões. Este processo de treinamento, com os recursos de "software"

hoje disponível, é uma tarefa bastante simples e acessível a qualquer usuário que saiba manipular dados uma planilha eletrônica.

REFERÊNCIAS BIBLIOGRÁFICAS

- ANON., 1990; Introduction to neural computing; NeuralWare, Inc.; Pittsburgh, 1990 (Publ. Eletr.)
- ANON., 1991; Using NWORKS - An extended tutorial for NeuralWorks Professional II/ Plus and NeuralWorks Explorer; NeuralWare, Inc.; Pittsburgh, 1991.
- CARDILL, M.: 1988; Neural networks primer - Part III; AI Expert, June 1988, pp. 53-59.
- FOSTER, B.; COLLOPY, F.; UNGAR, L.; Neural network forecasting of short, noisy time series. Computers and Chemical Engineering (submetido), 1991
- LAWRECE, J; Introduction to neural networks. California Scientific Software, Grass Valey 1991, 213 p.
- NELSON, M. & ILLINGWORTH, W. T; A practical guide to neural nets. Addison-Wesley, Reading, 1991, 344p.
- OBERMEIER, K. & BARRON, J.; Time to get fired up; BYTE; August 1989, pp. 217-245.
- ORRIS, J. & FEESER, H.; Using neural networks for exploratory data analysis. Butler University, 1991 (mimeo)
- RAPOSO, C. M.; Redes neuronais na previsão de séries temporais. Tese de Mestrado. COPPE - UFRJ, 1992; 73 p.
- SHARDA, R. & PATIL, R.; Connectionist approach to time series prediction: an empirical test; Business and Economics Research 11-90; Oklahoma State University, 1990.
- SILVA, Carlos Arthur B.; Sistemas Especialistas para Economistas Rurais: Potencial e Relevância; Revista de Economia e Sociologia Rural (28) 2, pp. 155-174, 1990.
- R. Econ. Sociol. Rural**, Brasília, v. 33, nº 1, p. 89-97, jan./mar. 1995

Talon Development Corporation; @BRAIN Neural Network Development System - User's Guide, Milwaukee, 1992.

THOMAS, P.; Chips mit starken Nerven.; Unit, 2/89, pp. 8-15; 1989.

TIMS/ORSA; Program of the 31st Joint National Meeting; Nashville, 1991.

UHRIG. J.; Prediction of US corn yields using a neural network; Proceedings of the 26th EAAE Seminar - Economics and Artificial Intelligence in Agriculture; Grignon, 1991.