

PREDIÇÃO DO NÚMERO DE REFEIÇÕES UTILIZANDO REDES NEURAS ARTIFICIAIS

HEVERTON A. PEREIRA¹, LEONARDO B. FELIX², LILIANE LOPES CORDEIRO³, HÉLIO M. A. ANTUNES⁴

¹ *Depto. de Engenharia Elétrica e de Computação Universidade Estadual de Campinas, Endereço: Rua Albert Einstein, 400 – Barão Geraldo CEP : 13.083.852, Campinas, SP – Brasil*

² *Depto. de Engenharia Elétrica e Produção Universidade Federal de Viçosa, Endereço: Av. Ph Holfs , s/n – Campus Universitário CEP : 36.570-000, Viçosa, MG – Brasil*

³ *Depto. de Matemática, Universidade Federal de Viçosa, Endereço: Av. Ph Holfs , s/n – Campus Universitário CEP : 36.570-000, Viçosa, MG – Brasil*

⁴ *Depto. de Engenharia Elétrica, Universidade Federal do Espírito Santo, Endereço: Av. Fernando Ferrari, s/nº - Goiabeiras CEP: 29060-900, Vitoria, ES – Brasil*

E-mails: hevertonaugusto@yahoo.com.br , bonato@ufv.br , lililopescordeiro@yahoo.com.br , helioantunes@gmail.com.

Abstract— In several moments of the life the people being would want to have a crystal ball to foresee what could be happened certain attitudes they were taken. A great problem faced today by the University Restaurant (RU.) of the Federal University of Viçosa is to foresee the amount of users that they will feed in each meal. RU. possesses a forecast system that bases on statistical methods. The objective of this work is to use Networks Neurals Artificiais (RNAs), more specifically Peceptron Multiple Layers (MLP) to do the prediction of the number of meals of RU. The obtained results will already be compared with the prediction system existent, because, a system Networks Neurals Artificiais of foreseeing the behavior of the served meals can bring economy and efficiency in the process of preparation of the meals.

Keywords— Prediction, Networks Neurals Artificiais, Economy, Efficiency.

Resumo— Quando na vida é possível prever o que vai acontecer, um problema pode ser minimizado através da utilização eficiente dos recursos para resolvê-lo. O principal problema atualmente enfrentado pelo Restaurante Universitário (RU) da Universidade Federal de Viçosa é prever quantas pessoas vão fazer suas refeições no café da manhã, no almoço e no jantar. O atual método é baseado em modelo estatístico. O objetivo deste trabalho é desenvolver uma Rede Neural do tipo MLP (Perceptron Múltiplas Camadas), para fazer a predição do número de usuários que irão fazer suas refeições no RU. Também, é feita uma comparação entre os resultados alcançados com o modelo utilizando Redes Neurais e o existente, buscando assim um modelo mais preciso para conseguir economias tanto em termos de quantidade de alimentos preparados quanto tornar o processo de preparação mais eficiente evitando o desperdício.

Palavras-chave— Predição, Redes Neurais Artificiais, Economia, Eficiência.

1 Introdução

A previsão é um fenômeno universal utilizado em atividades cognitivas de baixo nível como visão e percepção, mas também em outras de alto nível como planejamento e inferência, bastante utilizadas na área de Economia e Finanças (SATYADAS, 1994).

O Restaurante Universitário (R.U.) da Universidade Federal de Viçosa enfrenta como seu principal problema, prever quantas pessoas irão se alimentar nas refeições. São servidas durante a semana três refeições: café da manhã, almoço e jantar que é subdividido em jantar normal e alternativo. Nos finais de semana são servidas apenas as duas primeiras refeições.

O R. U. conta com um sistema de predição baseada em métodos estatísticos e na experiência dos funcionários. Mas, frequentemente ocorrem variações muito grandes entre as refeições previstas e

as servidas. Para ajudar a minimizar o erro entre o número de refeições previstas e servidas foi desenvolvido um sistema de predição baseada em Redes Neurais Artificiais (RNAs).

A solução de diversos problemas de engenharia através de RNAs é bastante interessante, tanto pela forma como são representados internamente pela rede, como também pelos resultados que gera, pois podem chegar a apresentar um desempenho superior ao dos modelos tradicionais, por exemplo, as análises de regressão (BOCANEGRA, 2002).

Entre as diversas arquiteturas de RNAs, foram escolhidas as redes Perceptron Múltiplas Camadas (MLP).

Elas constituem os modelos de RNAs mais utilizados e conhecidos atualmente. Tipicamente, esta arquitetura consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou ocultas) de unidades computacionais e uma camada de saída (HAYKIN, 1994).

A figura 1 representa um esquema típico de uma rede neural artificial com múltiplas camadas. As entradas são conectadas aos elementos processadores básicos, que são por sua vez interconectados com elementos de outras camadas e/ou saída da rede.

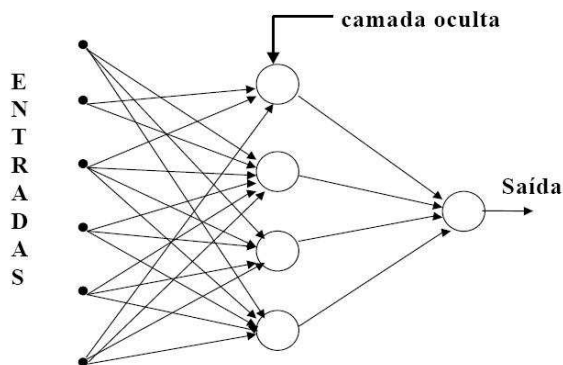


Figura 1 - Rede com múltiplas camadas

Com os dados obtidos da coordenação do R.U. foi modelado o problema, definindo as entradas para a rede. Com o vetor de dados foi realizado o treinamento, sendo que diversas topologias de redes foram utilizadas variando o número de neurônios e também a quantidade de camadas intermediárias. A validação e a comparação com o sistema atualmente utilizado no R.U. foram realizadas após o treinamento.

2 Metodologia

O trabalho foi desenvolvido nos laboratórios de Engenharia elétrica da Universidade Federal de Viçosa em colaboração com a direção do Restaurante Universitário.

Foram coletados os dados referentes ao período de 17 de janeiro de 2006 a 14 de julho do mesmo ano. Neste período ocorreram feriados e recessos escolares, em que o R.U. não funcionou. O conjunto de dados formou um vetor com 155 dias.

Como pode ser observado na figura 2, o sistema de previsão do R.U. nem sempre consegue prever de maneira eficiente o número de refeições a serem servidas.

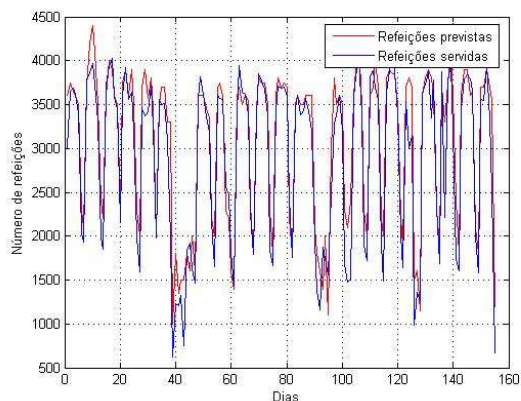


Figura 2- Gráfico das refeições servidas e previstas

Na figura 3 é exibido o erro entre a previsão do R.U. e o número de refeições servidas. Observa-se, pela figura 3 a importância de um sistema de predição eficiente, para evitar que problemas como o excesso ou a falta de comida ocorra. Esses erros causam respectivamente, desperdício de alimentos que não podem ser armazenados ou demora no atendimento, que tem como consequência grandes filas e insatisfação dos usuários.




Figura 3- Erro entre o número de refeições servidas e previstas

Os dois pontos críticos observados são:

- Previsão de 1337 refeições acima do servido.
- Previsão de 477 refeições a menos do que foi servido.

O primeiro passo na implementação do sistema de predição, utilizando Redes Neurais (MLP), foi definir quais são os fatores a serem estudados (entradas). Para isso, algumas considerações foram feitas. A primeira é que todos os usuários do refeitório são carnívoros. A partir desta afirmativa, e do fato de que algumas carnes têm uma maior aceitação (devido a vários fatores como sabor), o número de pessoas que irão se alimentar no RU está ligado à qual carne está no cardápio do dia.

Na tabela 1 são exibidos todos os tipos de carnes servidas, agrupadas por valores que variam de 1 a 13. É importante ressaltar que durante o treinamento a rede atribuirá pesos para a entrada carne que será multiplicado pelo respectivo valor da carne do dia.

Tabela 1. Carnes agrupadas com respectivos valores.

Valor	Prato principal (carne)
1	Carnes moídas
2	Hambúrguer
3	Almôndega
4	Picado Baiano
5	Cozidos Portuguêss, Húngaro, suíno, bovino
6	Bife Role, Panela
7	Espetinho, Torta americana, Ragú mexicano
8	Frango assado
9	Bife Milanese
10	Lombo, Pernil, Cupim, Largato
11	Torta de peixe, Iscas de Clã
12	Lasanha, Feijoada
13	Strogonoff

A segunda entrada que influencia o número de usuários do RU é o dia da semana. Dias de quarta e quinta, geralmente apresentam maior demanda de refeições, e finais de semana apresentam menor procura. Assim, foi definido para os dias da semana valores entre 1 e 10, os quais são indicados abaixo na tabela 2.

Tabela 2. Dias da semana com respectivos valores.

Valor	Dia da semana
1	Sábado
2	Domingo
5	Segunda-feira
7	Terça-feira
9	Quarta-feira
10	Quinta-feira
5	Sexta-feira

Considerando também, o fato de que existe uma tendência em aumento ou diminuição do número de usuários, devido a fatores como feriados, datas especiais, final de período, foi definido como mais 3 entradas para a rede o número de usuários que se alimentaram durante os três últimos dias, antes do dia em que se deseja prever.

Na figura 4 temos o mesmo modelo exibido na figura 1, mas com as entradas já definidas para obter na saída o número de refeições a serem servidas.




Figura 4 – Entradas e saída da rede proposta

Com as entradas definidas para rede, começa a etapa de treinamento. Vários algoritmos de treinamento foram testados, mas o que proporcionou melhor resultado foi o *traincgp* (Conjugate gradient backpropagation with Polak-Ribiere updates). Ressalta-se que todo o treinamento foi realizado com o software Matlab.

Este algoritmo não envolve o cálculo das derivadas segundas das variáveis e converge ao mínimo da função quadrática em um número finito de iterações. O algoritmo do gradiente conjugado, sem ainda assim aplicar ao algoritmo de propagação backward consiste em:

1. Selecionar a direção de p_0 , a condição inicial, no sentido negativo do gradiente.

$$p_0 = -g_0 \quad (1)$$

$$g(k) = \nabla e(x) |_{x=x_k} \quad (2)$$

2. Selecionar a taxa de aprendizagem α_k para minimizar a função ao longo da direção.

$$x_{k+1} = x_k + \alpha_k p_k \quad (3)$$

3. Selecionar a direção seguinte de acordo com a equação:

$$p_k = -g_k + \beta_k p_{k-1} \quad (4)$$

Onde:

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{g_{k-1}^T g_{k-1}} \quad (5)$$

4. Se o algoritmo neste ponto ainda não convergiu, regressamos a etapa número 2.

Embora seja complexa esta forma modificada do algoritmo backpropagation converge em poucas iterações, e é inclusive um dos algoritmos mais rápidos para redes multicamadas.

Para o cálculo da eficiência da rede neural desenvolvido, tanto na etapa de treinamento quanto na etapa de validação, será utilizado a raiz quadrada do erro médio quadrático.

Segundo MACIEL (2005), uma das formas de avaliação do desempenho da rede neural é através do erro quadrático médio (*mse* – mean squared error), isto é, a média do somatório dos quadrados dos erros de cada caso, tanto do conjunto de treinamento, quanto do conjunto de validação. Será adotada a raiz quadrada do erro médio quadrático (*rmse*) no cálculo do erro da rede neural. O cálculo do *rmse* pode ser determinado pela equação 6.

$$rmse = \sqrt{\frac{\sum (y - \tilde{y})^2}{n}} \quad (6)$$

Onde:

y = saídas reais normalizadas;

\tilde{y} = saídas normalizadas previstas pela rede;

n = número de dias.

3 Resultados

Através da modelagem dos dados, foram realizadas inúmeras simulações com diversas topologias (números de neurônios nas camadas intermediárias), tentando obter os melhores resultados para a validação do modelo proposto. Sendo que, várias funções de ativação e de treinamento foram testadas.

Juntamente com o algoritmo de treinamento já detalhado, *traincgp*, foram usadas as funções de ativação para as camadas de neurônios intermediários

tansig e logsig. Na figura 5, são exibidos os gráficos das funções de ativação.




Figura 5 - Gráficos das funções de ativação utilizadas

Dos 155 dias, 135 foram utilizados para o treinamento da rede e 20 para a validação.

Das diversas topologias testadas, a que apresentou melhor resultado para as entradas definidas, foi com 100 neurônios na primeira camada oculta e 20 neurônios na segunda camada oculta. O gráfico da figura 6 mostra a saída obtida com o treinamento da rede comparada com a saída desejada.




Figura 6 - Gráfico da saída treinada e real

Observa-se que o erro no treinamento é quase imperceptível, pois, a saída treinada segue a saída desejada. Na figura 7 é exibido o gráfico do erro entre a saída desejada e a saída treinada. Sendo que, o erro máximo ficou em 280 refeições para menos.




Figura 7 - Gráfico do erro do treinamento

Mas, deve-se analisar como a rede se comporta durante a validação, que são de 20 dias. Na figura 8 é exibido o gráfico da saída calculada e desejada. Para

analisar o erro da validação é exibido o gráfico da figura 9.

Observa-se, um erro acentuado nos primeiros dias da validação, devido a um feriado.

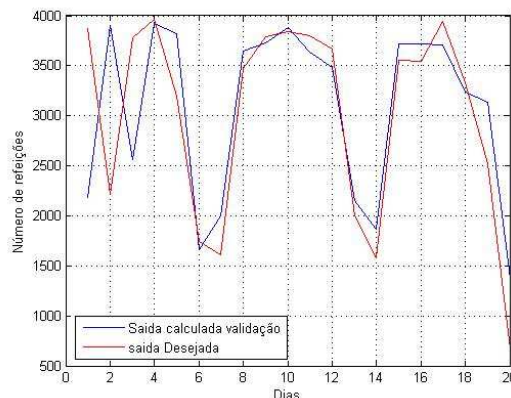


Figura 8 - Saída da rede treinada e desejada.

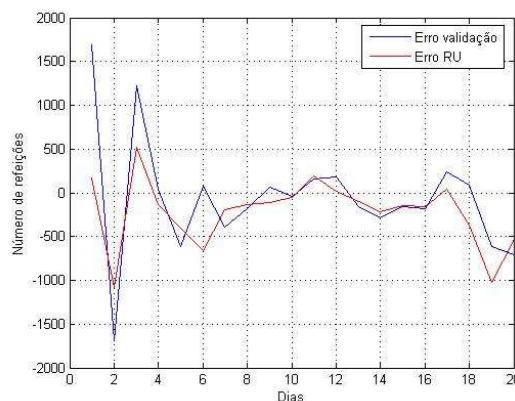


Figura 9 - Gráfico do erro da validação

O cálculo do rmse (raiz quadrada do erro médio quadrático) foi realizado para os dados de treinamento e validação do sistema neural desenvolvido e para o sistema de predição do R. U. e são exibidos na tabela 3.

Tabela 3. Percentual do rmse para rede com 100 neurônios na primeira camada intermediária e 50 na segunda.

	Erro Quadrático Médio rmse (%)	
	Treinamento	Validação
Sistema Neural	2,66	17,01
R.U.	6,64	10,06

Observa-se um valor de rmse para o treinamento dos dados de 2,66%, sendo menor que o do R.U. que foi de 6,64%, ambos calculados para as 135 refeições usadas no treinamento da rede. A mesma vantagem do sistema neural não prevaleceu na etapa de validação, onde o rmse para a validação foi de 17,01% enquanto que a do R.U. que foi de 10,06%.

Foram realizadas inúmeras simulações com diferentes topologias para as camadas intermediárias. Na tabela 4 são exibidos os valores de rmse para uma rede com 50 neurônios na primeira camada intermediária e 20 neurônios para segunda camada.

Tabela 4. Percentual do rmse para rede com 50 neurônios na primeira camada intermediária e 20 na segunda.

	Erro Quadrático Médio rmse (%)	
	Treinamento	Validação
Sistema Neural	3,22	23,92
R.U.	6,64	10,06

Mais uma vez é observado um baixo valor percentual de rmse na etapa de treinamento que foi de 3,22%, mas com um alto valor desse mesmo índice para a etapa de validação, que foi de 23,92%.

Para redes com mais de duas camadas intermediárias os resultados encontrados não foram satisfatórios.

4 Conclusão

Através da utilização de redes MLP, foi possível fazer a predição do número de usuários que irão se alimentar no RU. hehe

Com o aprimoramento da rede neural desenvolvida, e com a análise de outros parâmetros de entrada para a rede como presença ou não de sucos e doces, tipo de saladas pretende-se fazer uma predição que proporcione uma saída cada vez mais próxima da realidade.

O aumento da quantidade de dias para treinamento da rede também é de fundamental importância para aumentar a sua capacidade de generalização do problema.

O valor de rmse (raiz quadrada do erro médio quadrático), ainda não se encontra em valores aceitáveis, pois para a melhor situação o rmse foi de 17,01% enquanto que o do RU foi de 10,06%.

Com um aprimoramento no sistema de predição utilizando Redes Neurais Artificiais é esperada uma redução no desperdício de alimentos e aumento na eficiência do processo de preparo dos alimentos.

Agradecimentos

Este trabalho foi desenvolvido com o apoio da direção do Restaurante Universitário da Universidade Federal de Viçosa.

Referências Bibliográficas

- BRAGA, A. de P.; T.B Ludermir; A. C. P Carvalho. de L. F., (2001). Redes neurais: teoria e aplicações. São Paulo: Livros Técnicos e Científicos.
- BOCANEGRA, C. W. E., (2002). Procedimento para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. Tese de mestrado apresentada a Escola de Engenharia de São Carlos.

FREIMAN, J. P. e PAMPLONA, E. de O., (2005). Redes Neurais Artificiais na Previsão do Valor de Commodity do Agronegócio. V Encontro Internacional de Finanzas. Santiago, Chile.

HAYKIN, S., (1994). Neural networks: a comprehensive foundation. New York, Macmillan College Publishing Company.

MACIEL, J, (2005). Análise de um sistema de crédito cooperativo através de redes neurais (MLP) com a utilização do algoritmo Levenberg Marquardt. Tese de mestrado apresentada a UFPR

SATYADAS, A. ; CHEN, H. C., (1994). An application of intelligent neural network to time series business fluctuation prediction. IEEE, pp. 3640-3645,.

THE MATHWORKS, Inc (2000). Neural Network Toolbox, User's Guide for Use with Matlab.