

UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE PREÇOS DE FRUTAS E HORTALIÇAS

USE OF ARTIFICIAL NEURAL NETWORKS TO FORECAST FRUITS AND VEGETABLES PRICES

Celso Correia de SOUZA

Universidade Anhanguera Uniderp – Campo Grade, MS
csouza939@gmail.com

José Francisco REIS NETO

Universidade Anhanguera Uniderp – Campo Grade, MS
jfreisneto@terra.com.br

Leandro Oliveira ARAUJO

Universidade Anhanguera Uniderp – Campo Grade, MS
leandro.chidori@hotmail.com

Heder Saito NUNES

Universidade Anhanguera Uniderp – Campo Grade, MS
hedsaito@hotmail.co.jp

Laís Rodrigues CONCEIÇÃO

Fundação de Apoio ao Desenvolvimento do Ensino, Ciência e Tecnologia (MS)- FUNDECT / CNPq
laisrodriguesbnt@gmail.com

Recebido em 11/2013 – Aprovado em 08/2014

Resumo

As redes neurais artificiais (RNA) têm sido usadas com vantagens em análises de séries temporais, pois são de fácil tratamento matemático e fornecem resultados mais rápidos, facilitando as tomadas de decisões. Atualmente, no campo dos negócios, as RNA estão se tornando cada vez mais populares, atuando como uma ferramenta de grande importância como auxiliar na interpretação do mercado. Muitos sistemas que utilizam redes neurais têm funcionado bem na identificação de padrões complexos, aprendendo pela experiência, concluindo sobre algo e realizando previsão. Este artigo trata da aplicação de RNA para a previsão de preços de frutas e hortaliças. As redes foram treinadas utilizando dados sobre séries temporais de preços de frutas e hortaliças, do banco de dados do Núcleo de Estudos e Pesquisas Econômicas e Sociais (NEPES). Os resultados obtidos foram muito promissores e animadores, pois foi possível fazer a previsão de preços desses alimentos ao longo do tempo, se candidatando como uma boa ferramenta de ajuda aos empresários do setor de hortifrúti.

Palavras-Chave: Inteligência Artificial, Séries Temporais, Redes Neurais MLP, Neurônio Artificial, Setor de Hortifrúti.

Abstract

Artificial Neural Networks (ANN) has been used with advantage in time series analysis, because they are easy mathematical treatment and provide faster results, facilitating decision making. Currently, in the business field ANN are becoming increasingly popular, serving as an important tool to aid in the interpretation of the market. Many systems using neural networks have worked well in identifying complex patterns, learning through experience, concluding about something and making prediction. This article deals with the application of ANN to forecast prices of vegetables, fruits and vegetables. The networks were trained using time series data on prices of vegetables, fruits and vegetables, the database of Núcleo de Estudos e Pesquisas Econômicas e Sociais (NEPES). The results were very promising and encouraging because it was possible to forecast prices for those foods over time, applying as a good tool to help entrepreneurs in the grocery industry.

Keywords: Artificial Intelligence, Series, MLP Neural Networks, Artificial Neuron, Sector Hortifruti.

1 INTRODUÇÃO

O campo das políticas públicas de alimentação e nutrição, a promoção do consumo de hortaliças, frutas e verduras ocupa posição de destaque dentre as diretrizes de promoção de alimentação saudável.

A Estratégia Global sobre Alimentação Saudável, Atividade Física e Saúde, elaborada pela Organização Mundial da Saúde - OMS, recomenda o aumento do consumo de hortaliças, frutas e verduras dentre as recomendações para prevenção de doenças crônicas.

No cenário nacional, o Ministério da Saúde do Brasil recomenda o consumo diário de no mínimo três porções de frutas e três porções de hortaliças

e legumes em seu Guia Alimentar, enfatizando a importância de variar o consumo desses alimentos nas refeições ao longo da semana (FIGUEIREDO, JAIME e MONTEIRO, 2008).

Esses alimentos são importantes na composição de uma dieta saudável, pois são fontes de micronutrientes, fibras e de outros componentes com propriedades funcionais. Ademais, frutas e hortaliças têm baixa densidade energética.

De acordo com as evidências apresentadas pelo Relatório Mundial da Saúde de 2003, estima-se que até 2,7 milhões de vidas poderiam ser salvas anualmente em todo o mundo, se o consumo de hortaliças e frutas fosse adequado (GOMES, 2007).

Fica evidente que o consumo de frutas, verduras e hortaliças deve ser algo do cotidiano, sendo de tal importância que se deve fazer um orçamento levando em conta o custo destes alimentos.

Acontece que esses produtos são altamente perecíveis e sujeitos às variações climáticas e sazonalidade, dificultando a previsão a longo prazo dos preços de mercado desses alimentos.

Assim, o advento de uma ferramenta computacional para ajudar nas tomadas de decisão por parte do empresário, certamente haverá uma melhor oferta desses produtos, conseqüentemente, melhores preços ao consumidor, incentivando o consumo de produtos saudáveis a um custo compatível.

Desse modo, a utilização de RNAs, com o seu alto poder computacional, se torna uma ótima ferramenta, capaz de determinar, com uma aproximação fantástica, os preços de hortaliças, frutas e legumes ao longo do tempo.

Após treinada, as RNAs podem fornecer ótimas previsões, podendo influenciar positivamente na estabilidade ou mesmo até queda de preços desses produtos.

O estudo das RNAs busca o desenvolvimento de algoritmos computacionais de alto desempenho baseados nos conceitos da inteligência do ser humano, com a finalidade de se obter sistemas computacionais inteligentes capazes de resolver problemas simples e complexos.

As RNA, tecnologia desenvolvida muito recentemente, tem apresentado soluções interessantes a problemas de várias áreas, como finanças, *marketing*, vendas e compras, como afirmou ALMEIDA (1995 p.47).

Os pioneiros nesse estudo foram o neurologista McCulloch e o matemático Walter Pitts que, em 1943 conseguiram representar o primeiro neurônio artificial, copiando a ideia funcional da rede neural biológica que dispara impulsos sinápticos, quando a soma dos impulsos de outros neurônios atinge o seu limiar de disparo (sinapse).

O *multilayer perceptron* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de um único neurônio. Utilizou-se nesse trabalho a rede neural artificial do tipo MLP progressiva back-propagation.

O objetivo deste trabalho de pesquisa foi a utilização das RNAs, em particular, para previsão de preços de hortaliças, frutas e verduras ao longo do tempo.

2 REFERENCIAL TEÓRICO

Nesta seção far-se-á um breve estudo sobre as RNAs, descrevendo um pouco sobre a sua história recente, as aplicações nas mais diversas áreas do conhecimento humano, ao mesmo tempo em que se faz uma análise do seu equacionamento matemático.

2.1 REDES NEURAIS ARTIFICIAIS

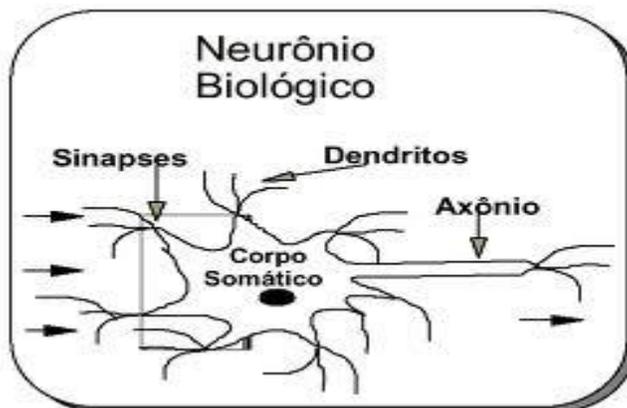
As RNAs, teoria ligada à Inteligência Computacional (IC), busca, através de técnicas inspiradas na Natureza, o desenvolvimento de sistemas inteligentes artificiais que imitem alguns aspectos do comportamento humano, tais como: percepção, raciocínio, aprendizado, evolução e adaptação.

As principais ideias sobre RNAs vieram através do trabalho do neurologista McCulloch e o matemático Walter Pitts, que, em 1943, conseguiram representar o primeiro neurônio artificial, copiando a ideia funcional da rede neural biológica, que dispara impulsos sinápticos quando a soma dos impulsos sinápticos recebidos de outros neurônios atinge o seu limiar de excitação (threshold) (KOVÁCS, 1996; HAYKIN, 2001).

Segundo Braga e Ludemir (2010), um neurônio biológico é composto por dendritos que têm por função receber os estímulos elétricos (informações) transmitidos por outros neurônios e encaminhá-los ao corpo do neurônio, também chamado de corpo somático, que é responsável por coletar, combinar e armazenar essas informações até atingir um limiar de excitação (*threshold*), quando, finalmente, acontece uma descarga elétrica através do *axônio*, que é constituído de uma fibra tubular que pode alcançar até alguns metros, e é responsável por transmitir os estímulos elétricos para outros neurônios (Figura 1).

As descrições do modelo matemático de um neurônio biológico resultaram no modelo de um neurônio artificial, devido a McCulloch e Pitts (Figura 2), composto pelos terminais de entrada (dendritos), corpo do neurônio, representada pelo par (\sum, θ) e do axônio, representado pela saída y .

Figura 1: Representação de um neurônio biológico destacando os seus principais componentes



Fonte: Google (2012)

Figura 2: Modelo de neurônio artificial



Fonte: Braga e Ludemir (2010)

Os terminais de entrada do neurônio artificial, que representam os dendritos no neurônio biológico, com valores x_1, x_2, \dots, x_n , são afetadas por pesos w_1, w_2, \dots, w_n , cujos valores podem ser positivos ou negativos. A equação (1) representa uma combinação linear u desses parâmetros, obtida através da função soma do neurônio artificial.

$$u = \sum_{i=1}^n w_i x_i = w_1 x_1 + w_2 x_2 + \dots + w_n x_n \quad (1)$$

O valor de u cresce até atingir o limiar de excitação θ (threshold), produzindo a saída

$y = f(u)$, denominada de função de ativação (BRAGA e LUDERMIR, 2010), descarregado u , que atinge valores muito próximos de zero, e o processo se repete. É esse também o comportamento de um neurônio biológico, guardadas as devidas proporções.

A função de ativação u do neurônio, que gera a saída $y = f(u)$, é uma combinação linear dos vetores peso $\vec{W} = (w_1, w_2, \dots, w_n)^T$ e entrada $\vec{X} = (x_1, x_2, \dots, x_n)^T$, pode ser representada, de seu modo mais simples, por uma função degrau, equação (2), função essa que representa

aproximadamente o comportamento do neurônio biológico.

$$y = f(u) = \begin{cases} 1 & \text{se } u \geq \theta \\ 0 & \text{se } u < \theta \end{cases} \quad (2)$$

Vários desses neurônios artificiais, associados de forma especial, têm em seu funcionamento a representação do comportamento inteligente do ser humano.

Devido a esse fato, o estudo de RNAs faz parte de um tópico especial da teoria denominada de Inteligência Artificial, compartilhada com algoritmos genéticos, lógica *fuzzy*, entre outras.

Segundo Haykin (2001), Rosemblat, em 1950, criou o primeiro modelo de RNAs, que consistia de uma rede de múltiplos neurônios artificiais dispostos em três camadas, denominadas de *perceptron* ou discriminador linear.

Os *perceptrons* são organizados em camadas de entrada e saída, onde os pesos das conexões são adaptados a fim de se atingir a eficiência sináptica, e pode ser usada no reconhecimento de caracteres, uma das várias aplicações de RNAs.

Um *perceptron* pode aprender conceitos através de exemplos e a responder, quando apresentado a ele novo exemplo, se o mesmo é verdadeiro, com 1, ou falso, com 0, baseado nos exemplos apresentados inicialmente.

Uma passagem inteira de um vetor de entrada para treinamento é denominada época. As épocas são repetidas até que se alcance algum critério de parada.

Se os padrões de entradas forem separáveis linearmente, o algoritmo tem garantido a sua convergência, isto é, os pesos são convenientemente ajustados no sentido de se

obter a classificação correta dos pesos (HAYKIN, 2001).

De acordo com Braga e Ludermir (2010), para o treinamento, cada padrão de entrada é apresentado ao *perceptron* e seus pesos devem ser ajustados seguindo a regra criada por Rosenblatt em 1958.

Assim sendo, tem-se x_i o i -ésimo padrão de treinamento apresentado à entrada, y_i a resposta do *perceptron* e y_d o valor desejado como resposta. Se $y_i = y_d$, nenhum ajuste de pesos ocorrerá no algoritmo de treinamento do neurônio.

Caso contrário, duas possibilidades devem ser consideradas pelo algoritmo: i) $y_d = 1$ e $y_i = 0$ e; ii) $y_d = 0$ e $y_i = 1$.

Em ambos os casos o algoritmo precisa ajustar os pesos do *perceptron* para que a saída do mesmo se iguale à saída desejada. Nos dois casos os pesos reajustados são dados pela equação (3),

$$w_{i+1} = w_i + \Delta w_i \quad (3)$$

onde $\Delta w_i = \eta e_i x_i$, sendo η um escalar positivo, também, conhecido como taxa de aprendizagem do *perceptron*, que indica o quanto o vetor de pesos será modificado na direção e sentido do vetor de entradas x_i e $e_i = y_d - y_i$, o erro da saída desejada para a saída obtida, obtendo-se a equação (4) para a atualização dos pesos.

$$w_{i+1} = w_i + \eta e_i x_i \quad (4)$$

Para Vieira e Roisenberg (2010), as redes de uma só camada resolvem apenas problemas linearmente separáveis, sendo que a solução de

problemas não linearmente separáveis passa pelo uso de redes com uma ou mais camadas intermediárias, ou escondidas. Uma rede com uma camada intermediária pode implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função.

Existiam duas limitações dos *perceptrons* que fizeram com que fossem interrompidas as pesquisas sobre o tema durante as décadas de 1960 a 1970: a primeira é que os valores de saída de um *perceptron* só pode ser verdadeiro ou falso (1 ou 0); e segundo, que o *perceptron* só pode classificar grupos de vetores se eles forem linearmente separáveis (VIEIRA e ROISENBER, 2010).

Com a publicação dos trabalhos do físico e biólogo Hopfield em 1982 relatando a utilização de redes binárias simétricas para otimização através de um algoritmo de aprendizagem, com realimentação, que estabilizava essa rede, as pesquisas na área foram retomadas e Rumelhart, Hinton e Williams, em 1986, introduziram o poderoso método de treinamento de RNAs denominado “Back-Propagation (BP)” (HAYKIN, 2001).

As RNAs são constituídas de um sistema de neurônios artificiais ligados por conexões sinápticas e divididos em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou hidden (ocultos) e

neurônios de saída, que se comunicam com o exterior.

A forma de arranjar os *perceptrons* em camadas é denominada *Multilayer Perceptron (MLP)*. O *MLP* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de rede utilizando um neurônio somente.

Utilizou-se nesse trabalho a rede neural artificial do tipo *MLP* com o treinamento com retropropagação (back-propagation), Figura 3.

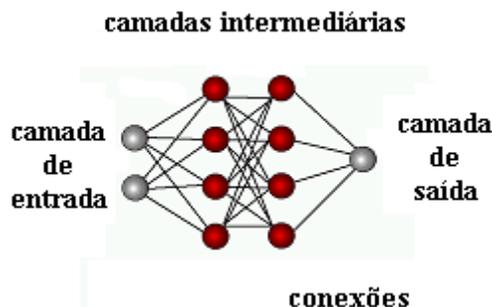
As RNAs se aplicam basicamente a problemas em que existem dados experimentais ou gerados por meio de modelos, dos quais a rede adaptará os seus pesos visando à execução de uma determinada tarefa. No entanto, a forma mais comum de utilização das RNAs é o aprendizado por meio de um conjunto de exemplos de entrada.

As tarefas principais das RNAs são: classificação de dados, categorização de variáveis, aproximação de funções, previsão sobre séries temporais e otimização de modelos matemáticos (TATIBANA e KAETSU, 2010).

3 MATERIAL E MÉTODOS

Essa pesquisa deve ser classificada como bibliográfica, pois, inicialmente, foi feito um

Figura 3: Estrutura de uma Rede Neural Artificial com retropropagação



levantamento bibliográfico dos assuntos que envolvem o tema em estudo; em seguida, uma revisão bibliográfica desses assuntos para a fixação dos conceitos que foram utilizados.

Também, deve ser classificada como exploratória descritiva, pois, procurou-se, através de dados de preços de verduras, hortaliças e frutas, descobrir e observar fenômenos, procurando descrevê-los, classificá-los e interpretá-los, ao mesmo tempo em que procurou explorar, no problema de pesquisa, os motivos das grandes variações sazonais e climáticas de preços desses alimentos.

Os dados utilizados nesta pesquisa foram os preços praticados no varejo de Campo Grande, MS de verduras, hortaliças e frutas, do banco de dados do Núcleo de Estudos e Pesquisas Econômicas e Sociais – NEPEs da Universidade Anhanguera Uniderp, responsável pelo cálculo mensal da inflação desta cidade.

Utilizou-se, nesta pesquisa, o modelo de RNAs (*MLP*) para a previsão de preços de hortaliças, frutas e verduras ao longo do tempo rede esta treinada com o algoritmo de aprendizagem com retropropagação dos erros.

3.1 REDES NEURAIS ARTIFICIAIS MULTICAMADAS (*MULTILAYER PERCEPTRON - MLP*)

Redes MLP apresentam uma poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias, ao contrário destas, redes *MLPs* podem tratar com dados que não são linearmente separáveis (RAUBER, 2012).

As funções de saídas dessas redes precisam ser diferenciáveis para que o gradiente possa ser calculado, direcionando o ajuste dos pesos. O objetivo do algoritmo de treinamento é minimizar o erro quadrático médio (MSE) entre a saída de rede e a saída desejada.

A função de ativação mais utilizada é a *sigmoidal* logística cuja orientação é determinada pela direção do vetor de pesos $\vec{W} = (w_1, w_2, \dots, w_n)^T$. O valor do termo de polarização corresponde ao peso w_0 , que determina a localização da função sigmoidal, ou seja, define a posição da função sigmoidal com relação ao eixo das ordenadas.

3.2 FUNCIONALIDADE

Em uma rede multicamadas o processamento realizado por cada neurônio é definido pela combinação dos processamentos pelos neurônios da camada anterior que estão conectados a ele.

Quando se move da primeira camada intermediária em direção a camada de saída, as funções implementadas se tornam cada vez mais complexas. Estas funções definem como é realizada a divisão do espaço de decisão.

Deve ser observado, contudo, que em alguns casos a utilização de duas ou mais camadas intermediárias pode facilitar o treinamento da rede.

A utilização de um grande número de camadas intermediárias não é recomendada. No entanto, cada vez que o erro medido durante o treinamento é propagado para a camada anterior, ele se torna menos útil ou preciso.

A única camada que tem uma noção precisa do erro cometido pela rede é a camada de saída. A última camada intermediária recebe apenas uma *estimativa* sobre o erro. A penúltima camada intermediária é uma estimativa da estimativa, e assim por diante (RAUBER, 2012).

3.3 TREINAMENTO DE REDES MLP (BACK-PROPAGATION)

O algoritmo *back-propagation* foi um dos principais responsáveis pelo ressurgimento do interesse por RNAs. É um algoritmo supervisionado que utiliza pares (entradas, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede.

O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de *fase forward* e *fase backward*. A *fase forward* é utilizada para definir a saída da rede para um dado padrão de entradas, ao mesmo tempo em que, atualiza os pesos de suas conexões.

Embora o erro total E seja definido pela soma dos erros dos neurônios de saída para todos os padrões, será considerado, sem perda de generalidade, que a minimização do erro para cada padrão individualmente levará à minimização do erro total. Assim, o erro pode ser definido pela equação (5).

$$E = \frac{1}{2} \sum (y_i^d - y_i)^2 \quad (5)$$

onde y_i representa a resposta do *perceptron* ao i -ésimo padrão de treinamento e y_i^d o valor desejado como resposta para esse mesmo padrão.

A regra delta sugere que a variação dos pesos seja definida de acordo com o gradiente descendente do erro com relação ao peso, ou seja, que a variação do peso para um dado padrão seja definida pela equação (6).

$$\Delta w_{ji} = \alpha - \frac{\partial E}{\partial w_{ji}} \quad (6)$$

Agora, é necessário definir como camada um dos pesos de cada neurônio da rede de vê ser ajustado de forma a diminuir o erro total gerado pela rede. Utilizando a regra da cadeia, tem-se.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial u} \frac{\partial u}{\partial w_{ji}}$$

$$(7) \text{ Onde } u_j = \sum_{i=1}^n x_i w_{ji} \text{ e}$$

$$\frac{\partial u}{\partial w_{ji}} = \frac{\partial \sum_{i=1}^n x_i w_{ji}}{\partial w_{ji}} = x_i \quad (8)$$

A primeira derivada, aquela do lado direito da igualdade da equação da equação (7), mede o erro do neurônio j , e, geralmente, é abreviada para δ_j , sendo

$$\delta_j = \frac{\partial E}{\partial u_j} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial u_j} \quad (9)$$

com

$$\frac{\partial y_j}{\partial u_j} = \frac{\partial f(u)}{\partial u} = f'(u_j) \quad (11)$$

Já o cálculo de $\frac{\partial E}{\partial y_j}$, que utiliza o erro, vai

depende da camada onde o neurônio j se encontra. Se o neurônio estiver na última camada o seu erro pode ser facilmente definido utilizando a Equação (12).

$$\frac{\partial E}{\partial y_j} = \frac{\partial \left(\frac{1}{2} \sum_{i=1}^n x_i w_{ji} \right)}{\partial y_j} = (y_j^d - y_j)$$

(12)

Que é a mesma fórmula da regra delta original. Substituindo-se as expressões (11) e (12) em (10), obtém-se a equação (13)

$$\delta_j = (y_j^d - y_j) f'(u_j)$$

(13)

Caso o neurônio j seja um neurônio intermediário, utiliza-se a regra da cadeia para escrever a equação (14).

$$\frac{\partial E}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial u_l} \frac{\partial u_l}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial u_l} \frac{\partial \sum_{i=1}^n w_{il} y_i}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial u_l} w_{jl}$$

(14)

onde:

$$\sum_{l=1}^M \frac{\partial E}{\partial u_l} w_{jl} = \sum_{l=1}^M \delta_l w_{jl}$$

(15)

Substituindo mais uma vez os dois termos do lado direito da equação (13) obtém-se que, para os neurônios das camadas intermediárias o erro é definido pela equação (16).

$$\delta_j = f'(u_j) \sum_{l=1}^M \delta_l w_{lj}$$

(16)

Pode-se assim generalizar a fórmula de ajuste de pesos proposta na equação (9) para a equação (17).

$$\Delta w_{ji} = n \delta_j x_i$$

(17)

Ou

$$w_{ji}(t+1) = w_{ji}(t) + n \delta_j(t) x_i(t)$$

(18)

Se o neurônio for de saída, o erro δ_j será definido pela equação (13), caso contrário, δ_j será dado pela equação (16).

Como já citado, o objetivo do treinamento da rede é ajustar os pesos, de modo que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas. Antes de se iniciar o processo de treinamento, todos os pesos devem ser inicializados randomicamente com valores pequenos, garantindo dessa forma que a rede não ficará saturada com grandes valores de pesos e prevenindo-se contra certas patologias de treinamento.

O treinamento pode ser dividido em passos da seguinte forma (ABELÉM, 1994):

- 1- Selecionar o próximo par do conjunto de treinamento e aplicar o vetor de entrada à rede;
2. Calcular a saída da rede;
- 3 Calcular o erro entre a saída da rede e a saída-alvo;
- 4- Ajustar os pesos da rede de maneira a minimizar o erro; e
- 5- Repetir o passo 1 até o passo 4 para cada vetor do conjunto de treinamento, até o erro se tornar aceitavelmente baixo para o conjunto inteiro.

Pode-se observar que os passos 1 e 2 constituem a etapa de propagação para frente, em que o sinal de entrada é transmitido através da rede da entrada até a saída.

Os passos 3 e 4, por sua vez, constituem-se na etapa de retropropagação, na qual o erro calculado é propagado de volta através da rede para ajustar os pesos.

3.4 DIFICULDADES NO TREINAMENTO

Apesar do grande sucesso das aplicações do algoritmo de retropropagação e da sua enorme popularidade, alguns problemas ainda o acompanham, entre os quais citamos: o longo período de treinamento, principalmente para problemas complexos, em que não há garantias de que, depois deste tempo, o treinamento tenha sido feito com sucesso; mínimos locais, já que a superfície do erro geralmente é cheia de vales e desníveis e o algoritmo emprega um tipo de gradiente descendente, existindo sempre a possibilidade de ficar preso em um mínimo local; paralisia da rede, pois durante o treinamento os pesos podem ser ajustados para valores muito grandes, os quais vão levar a derivada da função de ativação a zero (no caso de funções "squashing"), impedindo a rede de aprender o conjunto de treinamento.

Devido às deficiências do algoritmo de retropropagação, inúmeras variações têm sido propostas nos últimos anos, embora, até agora, nenhuma tenha solucionado de forma definitiva e confiável os problemas do "Backpropagation".

4 RESULTADOS E DISCUSSÃO

Utilizou-se a rede neural do tipo MLP para fazer previsões dos preços de hortaliças, frutas e verduras, utilizando-se no treinamento da rede as informações contidas no banco de dados do NEPES sobre os preços desses hortifrutis, no período de 2006 a 2011. A série do Quadro 1 se refere aos preços médios mensais da alface lisa no mercado varejista de Campo Grande, no período de 2006 a 2011.

De acordo com NEPES (2012), no período de janeiro de 2006 a dezembro de 2011 houve uma inflação acumulada de 30% no comércio varejista da cidade de Campo Grande, o que levou a realizar o deflacionamento os valores, pois ao eliminar o efeito da inflação no período se aproxima mais da realidade do que ocorreu no comércio varejista neste período, tendo como base 31 de dezembro de 2011.

O Quadro 2 apresenta os valores do Quadro 1, eliminando-se os efeitos da inflação acumulada nos valores da alface lisa, bem como as médias aritméticas mensais dos preços dessa hortaliça (GUJARATI, 2006).

Quadro 1: Preços médios mensais da alface lisa no comércio varejista de Campo Grande, no período de 2006 a 2011

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
2006	1,57	1,74	2,27	2,06	1,27	1,11	1,20	1,62	1,16	1,23	1,43	1,52
2007	1,96	2,18	1,74	1,89	1,88	1,78	1,10	1,65	1,16	1,22	1,32	1,47
2008	1,61	1,52	1,81	1,83	1,82	1,71	1,73	1,53	1,28	1,61	1,92	1,80
2009	2,48	2,59	2,79	2,21	2,15	2,06	2,36	2,25	2,09	2,43	2,28	2,47
2010	2,50	2,71	2,78	2,69	2,64	2,70	1,90	2,23	2,48	2,49	2,21	2,32
2011	2,44	2,39	2,91	2,79	2,51	2,64	2,71	2,42	1,78	2,24	1,81	2,10

Quadro 2: Preços médios mensais deflacionados, base dezembro de 2011, da alface lisa no mercado varejista da cidade de Campo Grande, no período de 2006 a 2011

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
2006	2,04	2,24	2,93	2,66	1,63	1,43	1,55	2,09	1,49	1,58	1,84	1,94
2007	2,49	2,74	2,19	2,37	2,35	2,22	1,37	2,06	1,44	1,51	1,63	1,80
2008	1,97	1,85	2,21	2,22	2,20	2,06	2,06	1,82	1,52	1,91	2,27	2,12
2009	2,90	3,02	3,24	2,56	2,48	2,37	2,71	2,58	2,39	2,77	2,59	2,80
2010	2,83	3,03	3,10	2,98	2,91	2,97	2,09	2,45	2,72	2,72	2,39	2,49
2011	2,60	2,51	3,04	2,90	2,57	2,70	2,77	2,47	1,81	2,27	1,83	2,11
Média	2,47	2,57	2,78	2,62	2,36	2,29	2,09	2,25	1,89	2,13	2,09	2,21
DP	0,39	0,46	0,46	0,30	0,43	0,54	0,58	0,30	0,54	0,55	0,38	0,37
CV(%)	15,84	18,07	16,66	11,29	18,20	23,37	27,53	13,27	28,36	25,86	18,07	16,76

Para a consecução do objetivo da pesquisa, aos dados deflacionados foram aplicados dois métodos para a previsão de preços dessa hortaliça: treinamento de uma rede neural artificial e uma análise de regressão múltipla (HOFFMAN e VIEIRA, 2006).

TREINAMENTO DA REDE NEURAL ARTIFICIAL

Considerou-se como matriz de entrada a matriz formada pelos valores médios mensais dos preços da alface lisa no comércio varejista de Campo Grande, MS, no período de 2006 à 2011 e, como objetivo, o vetor formado pelas médias aritméticas mensais dos preços desta hortaliça, no referido período.

A rede MLP utilizada foi constituída de 6 neurônios na camada de entrada, 18 neurônios na camada intermediária e um neurônio na camada de saída.

A rede foi treinada utilizando-se o *toolbox* do *software* Matlab, que apresentou, após realizado o treinamento o gráfico da convergência dessa

rede após 966 épocas e precisão menor do que 10^{-5} .

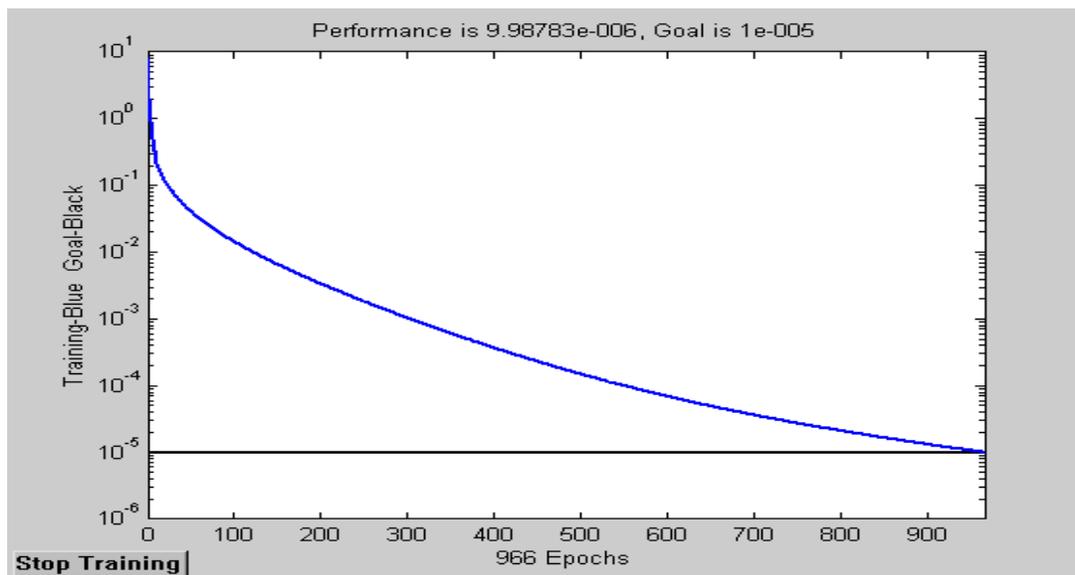
O vetor de saída, após a rede treinada, é dada por SAIDA_RN=[2,4663 2,5722 2,7816 2,6171 2,364 2,2876 2,0861 2,2567 1,8896 2,1297 2,0877 2,2112] e o veto erro ERRO =[0,0037472 - 0,0022058 -0,0016467 0,0029056 -0,004046 0,00242 0,003947 -0,0067155 0,00038908 0,00025569 0,0022615 -0,0012483], mostrando uma ótima convergência.

ANÁLISE DE REGRESSÃO LINEAR MÚLTIPLA

Na análise de regressão linear múltipla, considerou-se com variáveis independentes os anos, e como variável dependente a média aritmética.

O Quadro 3 apresenta as correlações de Pearson entre todas as variáveis.

Figura 4: Trajetória de convergência apresentada pela rede neural artificial no treinamento dos preços médios da alface lisa



Quadro 3: Correlações de Pearson entre as variáveis

	MEDIA	ANO_06	ANO_07	ANO_08	ANO_09	ANO_10	ANO_11
MEDIA	1,000	0,840	0,814	0,447	0,619	0,698	0,769
ANO_06	0,840	1,000	0,518	0,349	0,654	0,446	0,522
ANO_07	0,814	0,518	1,000	0,200	0,294	0,728	0,528
ANO_08	0,447	0,349	0,200	1,000	0,179	0,046	0,401
ANO_09	0,619	0,654	0,294	0,179	1,000	0,231	0,370
ANO_10	0,698	0,446	0,728	0,046	0,231	1,000	0,402
ANO_11	0,769	0,522	0,528	0,401	0,370	0,402	1,000

Observa-se no Quadro 3 que não existem altas correlações entre as variáveis, conseqüentemente, não existindo problemas de multicolinearidade na obtenção da equação de regressão. Na análise de variância, encontrou-se $p = 0$, indicando que a equação de regressão é altamente significativa, explicando muito bem o

fenômeno estudado .

Segundo Montgomery et al. (2001), a equação de regressão linear múltipla (*MEDIA_RLM*) encontrada é dada pela equação (19).

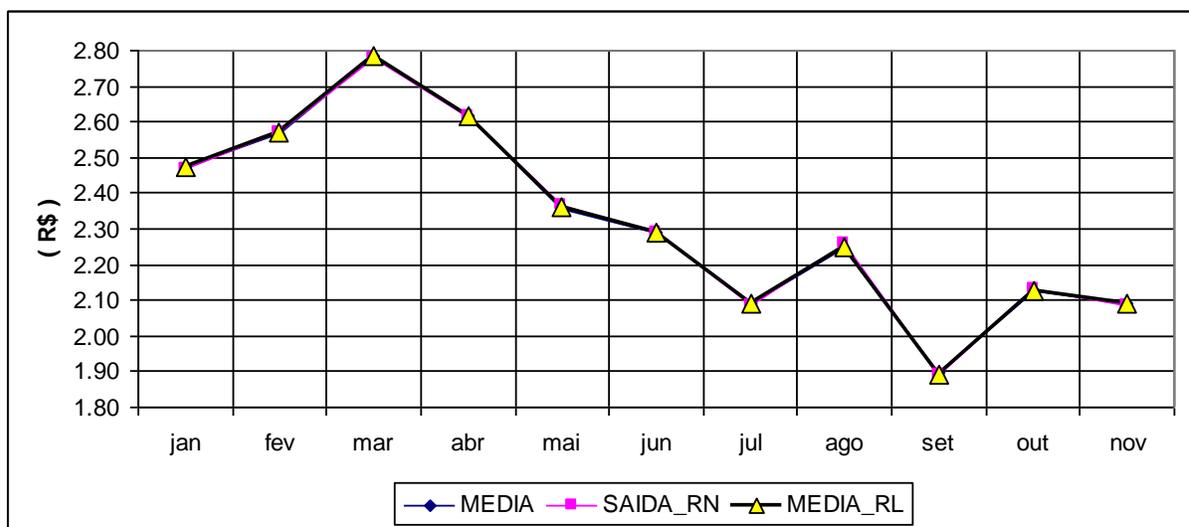
No Quadro 4 estão, de maneira resumida, a média aritmética, a saída das redes neurais

$$\begin{aligned}
 \text{MÉDIA}_{RLM} &= 0.014 + 0.168\text{Ano}_{06} + 0.173\text{Ano}_{07} + 0.165\text{Ano}_{08} + 0.163\text{Ano}_{09} + \\
 &+ 0.161\text{Ano}_{10} + 0.167\text{Ano}_{11}
 \end{aligned}
 \tag{19}$$

Quadro 4: Valores da média aritmética, da saída das redes neurais artificiais e da regressão linear múltipla dos preços médios mensais da alface lisa, de 2006 a 2011

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
MEDIA	2,473	2,566	2,785	2,616	2,358	2,290	2,093	2,245	1,895	2,128	2,091	2,209
SAIDA_RN	2,466	2,572	2,782	2,617	2,364	2,288	2,086	2,257	1,890	2,130	2,088	2,211
MEDIA_RLM	2,475	2,569	2,783	2,618	2,360	2,291	2,092	2,248	1,893	2,124	2,091	2,209

Figura 5: Representações gráficas das variáveis MÉDIA, SAIDA_RN e MÉDIA_RLM preços médios mensais de alface lisa, no período de 2006 a 2011



artificiais e os valores da regressão linear múltipla, dos preços médios mensais da alface lisa, no período de 2006 a 2011.

Na Figura 5 estão representados três gráficos gerados a partir do Quadro 4, pelas variáveis MÉDIA, SAIDA_RN e MÉDIA_RLM. As linhas dos respectivos gráficos das três variáveis em tela se sobrepõem, indicando a excelente aproximação entre essas três variáveis e o poder das duas ferramentas, redes neurais artificiais e regressão linear múltipla, utilizadas nas aproximações da média aritmética dos preços mensais da alface lisa, representada pela variável MEDIA (WOOLDRIDGE, 2006).

5 CONCLUSÃO

Os resultados desse trabalho de pesquisa podem ser considerados bons, até certo ponto, surpreendentes, visto que o seu objetivo era o de usar a ferramenta computacional redes neurais artificiais para a predição de séries temporais, tendo sido conseguido na sua totalidade.

As séries temporais preditas consistiam de um quadro de preços médios mensais de frutas e hortaliças, no período de 2006 a 2011, no mercado varejista de Campo Grande, MS. Essa ferramenta, após treinada com os dados do

problema, reproduziu com grande precisão os valores da variável objetivo, que eram as médias aritméticas mensais do preço da alface lisa.

Como as redes neurais artificiais vêm ganhando cada vez mais adeptos, com novas pesquisas, se tornando uma tecnologia promissora para o desenvolvimento de aplicações utilizando inteligência artificial.

O sucesso dessa ferramenta está ligada a sua versatilidade de aplicações nas mais diversas áreas do conhecimento, desde o desenvolvimento de sistemas especialistas até a resolução de complexos problemas de análise estatística.

É importante ressaltar que o problema de predição de séries temporais utilizando redes neurais artificiais pode ser resolvido por outras ferramentas matemáticas, destacando a análise de regressão linear múltipla, também, utilizada neste trabalho para fazer as mesmas predições, obtendo-se resultados bastante semelhantes aos das redes neurais artificiais.

REFERÊNCIAS

- ABELÉM, A. J. G. Redes Neurais Artificiais na previsão de séries temporais. Tese (Mestrado em Engenharia Elétrica) - Mestrado em Engenharia Elétrica, PUC-Rio, Rio de Janeiro. 1994.
- ALMEIDA, F. C. Desvendando o uso de redes neurais em problemas de administração de empresas. Revista de Administração de Empresas RAE, São Paulo, v. 35, n. 1, p. 46-55, 1995.
- BRAGA, A. P. e LUDERMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. LTC – Livros Técnicos e Científicos Editora S.A., 2010.
- FIGUEIREDO, I. C. R.; JAIME, P. C.; MONTEIRO, C. A. Fatores associados ao consumo de frutas, legumes e verduras em adultos da cidade de São Paulo. Revista de Saúde Pública, São Paulo, v.42, n.5, p. 777- 785, 2008.
- GOMES, F. S. Frutas, legumes e verduras: recomendações técnicas versus constructos sociais. Revista de Nutrição, Campinas, v.20 n.6, Nov/Dec 2007. <http://dx.doi.org/10.1590/S1415-52732007000600009>.
- GOOGLE – IMAGENS. Redes Neurais Artificiais. 2012. Disponível em: <https://www.google.com.br>. Acessado em: 09.jul.2012.
- GUJARATI, D. M. Econometria Básica, Campus/Elsevier, 2006.
- HAYKIN, S. Redes Neurais: Princípios e Prática. Porto Alegre: Bookman Editora, 2001.
- HOFFMAN, R. e VIEIRA, S. Análise de Regressão: Uma Introdução à Econometria, São Paulo: Hucitec, 2006.
- KOVÁCS, Z. L. Redes Neurais Artificiais: Fundamentos e Aplicações. São Paulo: Editora Collegium Cognitio, 1996.
- MONTGOMERY, D. C, PECK, E. A. and VINING, G. G. Introduction to Linear Regression Analysis. 3. ed. New York: John Wiley, 2001.
- NEPES – Núcleo de Estudos e Pesquisas Econômicas e Sociais. Boletim do Índice de Preços ao Consumidor de Campo Grande (IPC/CG). Universidade Anhanguera Uniderp – Campo Grande (MS). 2012.
- RAUBER, T. W. Redes Neurais Artificiais. Departamento de Informática UFES. Disponível em: <http://www.riopomba.ifsudestemg.edu.br/dcc/dcc/materiais>. Acesso em 9 maio de 2012.
- TATIBANA, C. Y. e KAETSU, D. Y. Uma Introdução às Redes Neurais. Universidade Estadual de Maringá-UEM, Departamento de Informática. Maringá. 2009.
- VIEIRA, R. C. e ROISENBERG, M. Redes Neurais Artificiais: Um Tutorial. Laboratório de Conexão e Ciências Cognitivas. Univ. Federal de Santa Catarina – UFSC. Florianópolis, 2010.
- WOOLDRIDGE, J. M. Introdução à Econometria: Uma Abordagem Moderna. 2ª edição. Ed. Thomson Learning, 2006.