

Previsão do Índice da Bolsa de Valores do Estado de São Paulo utilizando Redes Neurais Artificiais

Redes Neurais Artificiais – Prof. Wilian Soares

João Vitor Squillace Teixeira

Ciência da Computação
Universidade Federal de Lavras – UFLA,
Lavras – MG, Brasil 2012

Resumo

Este trabalho visa apresentar uma abordagem de previsão do índice da Bolsa de Valores do Estado de São Paulo (Ibovespa) para o ano de 2011. Para a previsão será utilizada uma rede neural com arquitetura MLP (*Multilayer Perceptron*) implementada a partir do algoritmo *Backpropagation* utilizando software Scilab. O objetivo desse estudo de previsão é mostrar como a rede neural se comporta e como ela pode ser de grande valia para previsões com grandes quantidades de dados.

Palavras-Chave: *Perceptron de multiplas camadas; redes neurais artificiais; Bolsa de valores; Ibovespa.*

Abstract

This paper presents an approach for predicting the index of the Stock Exchange of São Paulo (Bovespa) for the year 2011. For the prediction will be used a neural network architecture with MLP (Multilayer Perceptron) deployed from the Backpropagation algorithm using Scilab software. The objective of this study for forecasting work is to show how the neural network behaves and how it can be valuable for forecasting with large amounts of data.

Keywords: *multilayer perceptron; artificial neural network; stock exchange; Bovespa.*

1. Introdução

Atualmente com o grande aumento da dissiminação de informações e fácil obtenção de dados, a informação se propaga em uma velocidade que anos atrás seria algo inimaginável, tendo isso em vista, o estudo de redes neurais artificiais tem ganhado espaço cada dia mais, esses dados podem ser utilizados para a otimização de diversos serviços e estudos resultando em grandes melhorias em diversas áreas de ciência e tecnologia.

As redes neurais artificiais foram desenvolvidas com o objetivo de assemelhar-se a mesma forma de aquisição de conhecimento e de aprendizagem que o cérebro humano, nessa assemelhação o fato mais importante é o de conseguir trabalhar com dados complexos e não lineares.

Nos dias atuais com as novas técnicas computacionais que acompanham dados em tempo real, a rede neural tem encontrado aplicações de grande importância em várias áreas que trabalham com séries temporais complexas, dentre elas temos como exemplos: a previsão de clima, área financeira, tráfego da internet entre outras.

Sobre outro paradigma temos o mercado de ações, este é uma área de alta complexidade onde muitos modelos matemáticos tem sido desenvolvidos, entretanto está sendo notado que a técnica de rede neurais pode produzir com sucesso um modelo eficiente na previsão da mesma. Um fator importante no mercado de ações é índice gerado pela média geral das cotações das ações chamado Ibovespa (Índice da bolsa de valores do estado de São Paulo), sua avaliação pode ajudar a identificar seu comportamento e auxiliar nas transações do processo de decisão de investimento.

2. Descrição do Problema


O trabalho visa criação de uma rede neural para fazer previsões do Ibovespa (índice da bolsa de valores do estado de São Paulo) para o ano de 2011.

A bolsa de valores é muito imprevisível, podendo ter grandes variações de valores ao decorrer de apenas um dia, se tratando de meses ou anos seu comportamento pode ser ainda mais instável. Entretanto, apesar das dificuldades, um padrão pode ser “definido” através do comportamento de cotações anteriores e com o

auxilio de uma rede neural (atraves do aprendizado do seu comportamento) está tentando criar um padrão futuro do mesmo.

2.1. Neuronio Artificial

Redes neurais artificiais são modelos matematicos que assemelham-se a estruturas cerebrais possuindo a capacidade de aprendizado e generalização. Os neuronios artificiais são basicamente os processadores da rede neural, formados pelos chamados pesos sinapticos, função de soma e função de ativação.



[X_n] – Entradas
[W_n] – Pesos Sinápticos
[Σ] – Função Soma
[$f(u_k)$] – Função de Ativação
[y] – Saída

Fig 1.1 neurônio artificial

2.2. Topologia

As redes neurais são construídas utilizando determinadas topologias, sendo cada uma delas específica para cada tipo de problema. Os chamados perceptrons são as redes que possuem apenas uma camada de entrada, onde os dados são logo processados e encaminhados diretamente para saída após passar pela função de ativação.

Outra topologia bastante utilizada são os perceptrons de múltiplas camadas, que possuem o que podemos chamar de camadas intermediárias. Os dados serão processados por diferentes quantidades de neurônios podendo resolver problemas

mais complexos, já com duas camadas intermediárias podendo resolver sistemas linearmente não-separáveis.




Fig 1.2 *perceptron*




Fig 1.3 *multilayer perceptron*

2.3. Treinamento

Uma rede neural possui dois tipos de treinamento. O primeiro deles é o supervisionado, onde a rede possui um “professor” que verifica os dados reais e os confere com os dados de saída do aprendizado retornando o valor de um erro para a rede. O segundo tipo de treinamento é o não-supervisionado, onde não existe um “professor” e a rede então aprende através de exemplos de dados semelhantes para definir seu aprendizado.

Para os perceptrons de de multiplas camadas um bom algoritmo de treinamento é o *backpropagation* do tipo supervisionado que acontece em duas etapas, a primeira é onde é feita a recepção dos dados indo em direção a camada de saída, e a segunda etapa é quando ocorre a transição inversa dos dados, onde é calculado o erro da rede e alteração dos pesos.

3. Solução proposta utilizando Redes Neurais Artificiais

O software para a resolução do problema utilizando redes neurais foi o Scilab. Este é um software científico computacional, que apresenta um *toolbox* chamado ANN com funções voltadas especialmente para redes neurais.

Os dados utilizados para o treinamento e teste da rede neural estão disponíveis no site da BMF Bovespa (<http://www.bmfbovespa.com.br>). Foram utilizadas as cotações diárias do fechamento do Ibovespa no período de janeiro de 1998 até dezembro de 2011 totalizando 3463 dados.

A divisão dos dados foi de aproximadamente 92,83% (3215 dados) de treinamento e 7,16% (248 dados) para teste, resultando apenas na previsão do ano de 2011.

Para o treinamento teve de ser feita a normalização dos dados, ela se faz necessária pois a resposta da função de ativação utilizada varia entre zero e um, portanto deve-se dividir os valores pelo maior valor da série para normalizá-los e assim poderem ser calculados corretamente. Após encontrada as respostas da saída, faz-se necessário a desnormalização multiplicando pelo valor máximo da série não normalizada.

Os dados para treinamento podem ser visto na figura 3.1, ele corresponde a série temporal das cotações diárias (exceto finais de semana e feriados) de janeiro de 2008 à dezembro de 2010.




Fig 3.1 Dados para treinamento

Na figura 3.2 podem ser visto os dados para teste de janeiro de 2011 até dezembro de 2011. Os dados de teste são necessários para compara-los com a previsão da rede e assim o erro dentre eles ser calculado.





Fig 3.2Dados para teste da previsão

O modelo escolhido para a realização da previsão foi o *feedforward* com algoritmo backpropagation presente no toolbox ANN do Scilab. Este modelo de rede permite fazer a previsão de forma eficiente. Foram selecionados para os testes apenas os parâmetros e a função de ativação, que no caso foi a sigmoideal.

Um dos parâmetros ajustados foi a janela, esta é uma técnica comumente utilizada em redes neurais. Ela é definida a partir dos seus dados de entrada e serve para prever o dado seguinte. Esse dado seguinte será utilizado na próxima iteração como parte da entrada e o primeiro dado da janela anterior será dispensado, a janela pode ser vista na figura 3.3.

Para o treinamento foi utilizado apenas um computador treinando-o com parâmetros diferentes: PC 1: Dual Core 1,87GHz, 3GB RAM. Dentre os parâmetros variados temos: a quantidade de neurônios na camada de entrada (janela/atraso), primeira camada intermediária, segunda camada intermediária, o valor do momento,

taxa de aprendizado e as épocas. Os pesos iniciais foram dados aleatoriamente para a rede de modo que ela conseguisse iniciar o processo diferentemente de zero.



4. Resultados

Os parametros foram alterados diversas vezes para a obtenção de um erro que fosse aceitável, por se tratar de muitos dados o treinamento é muito demorado e consequentemente o numero de testes foi limitado. A tabela 4.1 contem os melhores parametros utilizados e os resultados obtidos:

Tabela 4.1: Parametros da arquitetura da RNA

	PC 1	PC 1	PC 1	PC 1	PC 1	PC 1
Parâmetros	A	B	C	D	E	F
Camada de Ent.	10	10	3	24	15	5
C. Oculta 1	20	20	6	48	30	10
C. Oculta 2	10	10	9	12	-	-
Camada de Saída	1	1	1	1	1	1
Taxa de Aprendizado	0,02	0,02	0,17	0,2	0,3	0,2
Momento	0,9	0,9	0,6	0,5	0,9	0,9
Épocas	1500	3000	5000	500	1000	3000
Resultados Obtidos						
Tempo	51,37 min.	121,428 min.	245,2181 min.	18,75 min.	146,733 min.	67,39 min.
EQ Treinamento (Soma)	0,685722	0,97512	0,377362	2,31544	1,9457	0,533622
EQM Previsão	0,005922	0,004822	0,000271	0,009500	0,009500	0,004500

A figura 4.1 refere-se ao treinamento da rede que teve o menor erro de previsão, de acordo com a tabela 4.1 representado pelo parâmetro C.

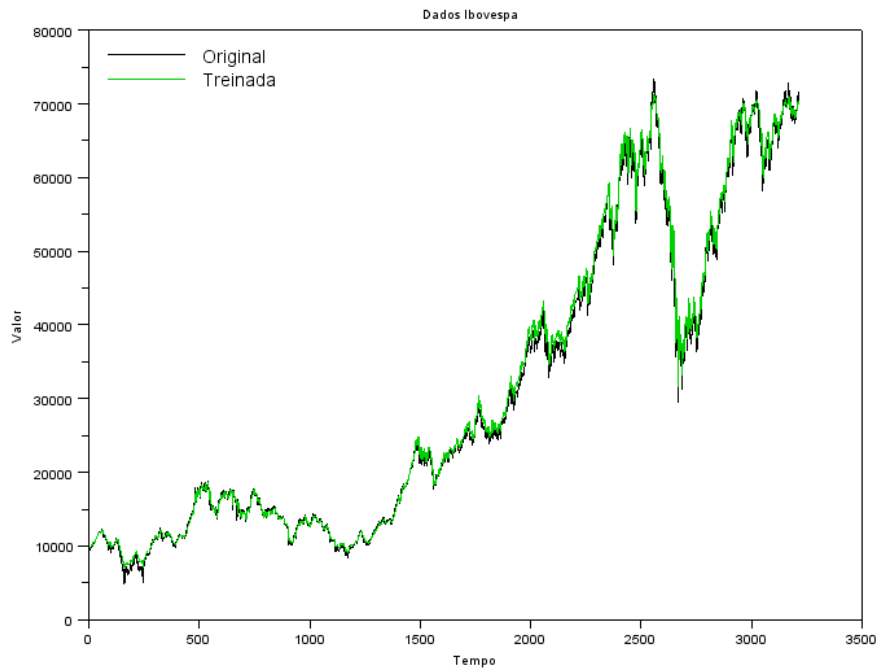


Fig 4.1Treinamento da rede a partir dos dados

Na figura 4.2 pode-se observar o erro quadrático do treinamento em relação às épocas.




Fig. 4.2Erro quadrático do treinamento

Para os testes foram utilizado os pesos sinapticos obtidos pelo treinamento, com variações de no máximo 2%. Na figura 4.3 segue a previsão da rede em relação as cotações reais do ano de 2011.

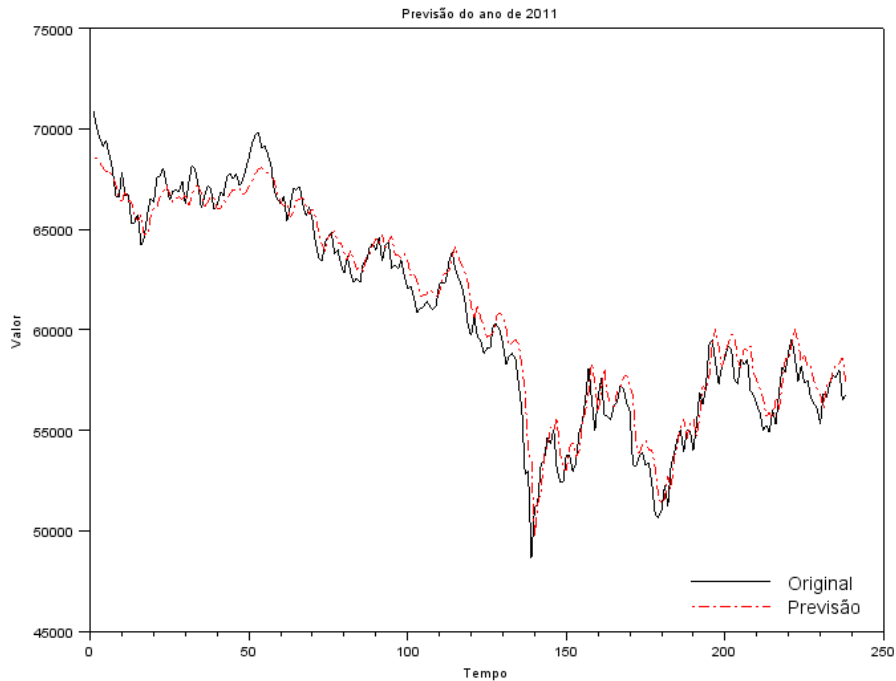


Fig 4.3 Dados do Ibovespa 2011 e previsão da rede

A partir dos resultados obtidos e do processo de treinamento foi possível identificar alguns pontos fundamentais em um estudo de redes neurais: numero de dados, escolha do computador e escolha dos parametros.

Primeiramente, e o mais importante, são os números de dados a serem trabalhados, como neste trabalho o numero de dados era alto não houve grandes problemas, dado que a rede chegou na maioria das vezes a um erro menor do que 2%, entretanto o tempo consumido para os treinamentos foi grande por se tratar de tamanha quantidade de dados.

As configurações do computador são essenciais para uma otimização do tempo de treinamento e na escolha dos parametros da rede. A velocidade de treinamento variou de acordo com a alteração da janela, do momento e da quantidade de camadas

escondidas. No caso da janela quanto menor era seu tamanho mais rápido era o treinamento, no caso do momento quanto maior, mais rápido era o treinamento.

Os resultados independiam das alterações dos parâmetros podendo ser concluído que nem sempre é necessário grandes quantidades de neurônios nas camadas escondidas, ou no tamanho da janela para se ter erros satisfatórios.

A maior dificuldade foi a escolha dos parâmetros, dado que mudanças mínimas resultavam em variações de erros grandes, chegando por fim a consideração de que a criação de uma forma para mudar os parâmetros automaticamente otimizaria a obtenção de resultados de forma eficiente.

5. Conclusão

Os resultados obtidos revelam que as redes neurais artificiais apresentam previsões de forma eficiente, uma vez que os erros foram relativamente baixos.

Erros baixos independem se os valores dos parâmetros são altos, podendo ser concluído que nem sempre é necessário altas quantidades de neurônios nas camadas de entrada ou camadas escondidas para se obter erros menores. Do mesmo modo, vale para as taxas de aprendizado ou do valor do momento. Portanto várias outras arquiteturas podem ser testadas podendo ser encontrados erros ainda mais satisfatórios dos que os atuais.

A maior dificuldade na construção de uma rede neural é a definição dos seus parâmetros, pois para cada problema específico tem-se resultados diferentes. A partir do momento que os parâmetros são ajustados de modo que o erro seja o mais baixo possível, a rede está configurada e poderá ser utilizada para resolver problemas da mesma origem do treinamento.

6. Referências

HRISTEV, Rurick M. **Matrix Techniques in Artificial Neural Networks**, University of Canterbury 2000

CERQUEIRA, Eduardo O.; ANDRADE, João C.; POPPI, Ronei J.; MELLO, Cesar. **Redes Neurais E Suas Aplicações Em Calibração Multivariada**, UNICAMP 2001

CASTRO, Cristiano Leite de. **Sistema Inteligente para Previsão on-line do Índice Ibovespa baseado em Redes Neurais Artificiais**, UFMG 2003

FARIA, Elisângela Lopes de; ALBUQUERQUE, Marcelo Portes; ALFONSO, Jorge Luis González. **Previsão do Mercado de Ações Brasileiro utilizando Redes Neurais Artificiais**, CBPF-NT-002/2008

BISHOP, Christopher M. **Neural Networks for Pattern Recognition**, 1ª ed. 2006

BRAGA, Antônio de Pádua ; CARVALHO, André Ponce de Leon F. de ; LUDEMIR, Teresa Bernarda. **Redes Neurais Artificiais: Teoria e Aplicações**, 2ª ed. 2007.