

A UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS PARA A ESTIMAÇÃO DOS PREÇOS DA PETROBRÁS PN NA BOVESPA

Marco Antônio dos Santos Martins*

Frederike Mette**

Guilherme Ribeiro de Macedo***

Sinopse: A crescente sofisticação das operações no mercado financeiro aumentou muito a exposição do risco de algumas operações. Isso requer a utilização de tecnologias avançadas para modelar e estimar a série de preços dos ativos. Uma das abordagens que vem ganhando importância na modelagem de preços e de volatilidade é a de Redes Neurais Artificiais (RNA). O presente artigo tem por objetivo estimar, por meio de RNA, os preços para as ações da Petrobrás PN, utilizando uma série de preços diários compreendida no período de 2 de janeiro de 2001 até 9 de maio de 2008, representando 1821 observações diárias. Após a estruturação e o treinamento da RNA no *software* Matlab 7.6.0. R2008a, calculou-se o erro quadrado médio (RMSE) e estimaram-se as cotações da Petrobrás PN, comparando as estimações com os preços efetivamente ocorridos. Os resultados obtidos pela estimação, quando comparados com a cotação efetiva da Petrobrás para os dias seguintes, demonstraram um alto grau de aderência do modelo com RNA para períodos curtos de estimação. No entanto, esses resultados merecem outros testes com janelas de tempo diferentes, incluindo momentos de maior *stress* nos preços, e com outras ações menos aderentes à carteira de mercado, visando aumentar o nível confiabilidade do modelo.

Palavras-chave: Redes neurais artificiais. Petrobrás. Estimação de preços.

1 INTRODUÇÃO

Ao longo dos últimos anos, o avanço das técnicas computacionais reduziu muito a construção, manutenção e manipulação de banco de dados com séries de preços de ativos. Em contrapartida, evoluiu também o grau de sofisticação das operações oferecidas pelo mercado financeiro aos investidores, aumentando as possibilidades de ganhos juntamente com o

* Doutorando em Administração UFRGS. Professor da UNIFIN. (mmartins@jminvest.com).

** Mestra em Administração UFRGS. Professora da ESPM e UNISC. (frederikemette@yahoo.com.br).

*** Doutorando em Administração UFRGS. Professor Substituto da UFRGS. (ribeiroguilherme@gmail.com).

crescimento do nível de risco de alguns ativos. Nesse contexto, ocorre um natural estímulo à aplicação empírica dos modelos que se propõem a modelar e estimar volatilidade e previsão de preços de ativos.

Dessa maneira, uma das abordagens que vem ganhando importância, dentro do campo da econometria, na previsão dos preços de ativos, é a de redes neurais artificiais (RNA). As redes neurais artificiais reproduzem o funcionamento do cérebro de maneira simplificada. De acordo com Kohonen (1988), as noções sobre o funcionamento da memória como, por exemplo, princípios associativos ou capacidade de aprendizado, inspiram os modelos de redes neurais artificiais. A utilização de técnicas de representação do conhecimento para prever preços de ativos tem demonstrado resultados positivos à medida que as redes neurais artificiais podem tratar o assunto de maneira mais simplificada do que os métodos econométricos não lineares e podem captar os efeitos mais qualitativos, e não apenas quantitativos.

O presente artigo tem por objetivo estimar, por meio da RNA, os preços para as ações da Petrobrás PN, utilizando uma série de preços diários compreendida no período de 2 de janeiro de 2001 até 9 de maio de 2008, representando 1821 observações diárias. O trabalho está estruturado em cinco seções, sendo a primeira dedicada a uma rápida revisão teórica sobre o método de redes neurais artificiais, com sua conceituação e um pequeno histórico da evolução dos estudos com redes neurais artificiais, que visa fornecer uma pequena intuição da modelagem; a segunda é dedicada à defesa da viabilidade da aplicação das redes neurais artificiais ao mercado de ações, em que se explica a adequação de sua utilização para estimar os preços das ações; a terceira seção encontra-se o detalhamento da amostra e a estruturação do modelo de rede neural no software Matlab 2.0.6. 2008.6; na quarta seção estão os resultados da aplicação do modelo e a respectiva análise; e a última seção é dedicada às considerações finais.

2 REVISÃO TEÓRICA

Em 1943, Mclulloch e Pitts (*apud* MÁSSON; WANG, 1990) formalizaram o primeiro modelo de redes neurais artificiais, apresentando uma estrutura que abstraía a complexidade da atividade neural em sistemas neurais reais, assim como complicadas características encontradas no corpo de neurônios biológicos, formando a base para a maioria dos modelos conexionistas desenvolvidos posteriormente.

Alguns históricos sobre a área costumam “pular” os anos 1960 e 1970 e apontar um reinício da área com a publicação dos trabalhos de Hopfield (1982), relatando a utilização de redes simétricas para otimização, e de Rumelhart, Hinton e Williams, que introduziram o poderoso método *Backpropagation*.

Entretanto, para se ter um histórico completo, devem ser citados alguns pesquisadores que realizaram, nos anos 60 e 70, importantes trabalhos sobre modelos de redes neurais em visão, memória, controle e auto-organização, como: Amari, Anderson, Cooper, Cowan, Fukushima, Grossberg, Kohonen, von der Malsburg, Werbos e Widrow.

No entanto, o correto é que, entre os anos 1960 e 1970, o assunto evoluiu num ritmo bem menor. A partir dos anos 1980, com o avanço da tecnologia, as redes neurais artificiais passaram a atrair substancial atenção novamente, sendo que, no início dos anos 1990, Rumelhart, Hinton e Williams criam o algoritmo *Backpropagation*, levando a uma explosão de interesse em redes neurais.

Este algoritmo foi aplicado em uma grande variedade de problemas, como na identificação da estrutura de proteínas, hifenização de palavras em inglês, reconhecimento da fala, compreensão de imagens e previsão de séries temporais. O sucesso desse algoritmo estimulou o desenvolvimento de muitas pesquisas em redes neurais artificiais e de uma variedade de modelos cognitivos.

Para Mueller (1996), as redes neurais artificiais são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência. É importante salientar que o termo “inspirado” deve ser enfatizado, pois, de fato, uma complexa rede neural artificial ainda é um mecanismo extremamente simples quando comparado ao cérebro, pois o cérebro de um pequeno mamífero pode ter muitos bilhões de neurônios.

O sistema nervoso é formado por um conjunto extremamente complexo de células, os neurônios. Eles têm um papel essencial na determinação do funcionamento e do comportamento do corpo humano e do raciocínio. Os neurônios são formados pelos dendritos, que são um conjunto de terminais de entrada, pelo corpo central e pelos axônios, que são longos terminais de saída.

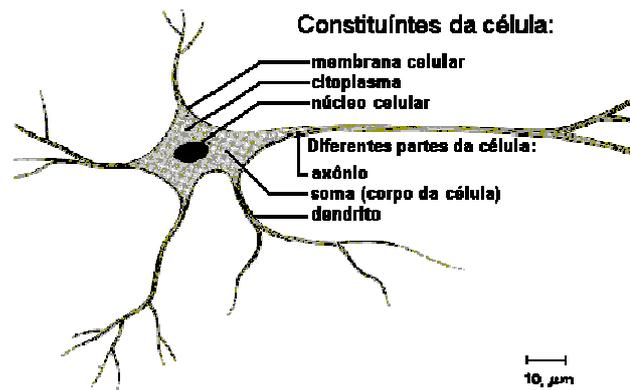


Figura 1 – Esquema dos Constituintes da Célula Neural

Fonte: HEBB, 1949.

Os neurônios se comunicam por intermédio de sinapses. Sinapse é a região onde dois neurônios entram em contato e pela qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio A, em um determinado momento, são processados e, atingindo um dado limiar de ação, o neurônio A dispara, produzindo uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de outro neurônio B. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio B. Esse processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 10^{11} neurônios, e o número de sinapses é de mais de 10^{14} , possibilitando a formação de redes muito complexas.

De acordo com Beale e Jackson (1990), a abordagem de redes neurais artificiais consiste em capturar os princípios básicos de manipulação de informação do cérebro humano e aplicar esse conhecimento na resolução de problemas que exigem aprendizado a partir da experiência.

O mesmo autor destaca que as redes neurais artificiais se fundamentam nos estudos sobre a estrutura do cérebro humano para tentar emular sua forma inteligente de processar informações. Wasserman (1989) destaca que, apesar da complexidade do funcionamento do cérebro, já se sabe que a modelagem do conhecimento contido em um problema específico pode ser representada por inter-conexões entre células nervosas. Estruturalmente, a rede neural artificial, também conhecida por modelo conexionista de computação, se assemelha à rede neural biológica, pela composição de seus neurônios e pela conexão entre eles.

Hecht (1998) define mais formalmente uma rede neural como:

[...] um modelo conexionista é uma estrutura de processamento de informações distribuída e paralela. Ela é formada por unidades de processamento, comumente chamadas de nós, neurônios ou células, interconectadas por arcos unidirecionais, também chamados de ligações, conexões ou sinapses. Os nós possuem memória local e podem realizar operações de processamento de informação localizada. Cada célula possui uma única saída (axônio), a qual pode se ramificar em muitas ligações colaterais (cada ramificação possuindo o mesmo sinal de saída do neurônio). Todo o processamento que se realiza em cada unidade deve ser completamente local, isto é, deve depender apenas dos valores correntes dos sinais de entrada que chegam dos neurônios através das conexões. Estes valores atuam sobre os valores armazenados na memória local da célula.

As redes neurais artificiais são formadas por neurônios e conexões entre eles. O neurônio representa uma região onde informações são processadas. Seus três elementos básicos são: os pesos sinápticos, a função de soma e a função de transferência, conforme Figura 2.

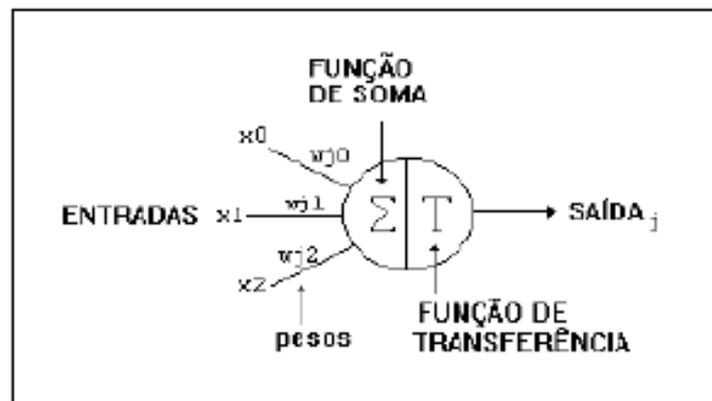


Figura 2 – Neurônio Artificial

Fonte: TAFNER, 1998.

Explicando de outra forma, uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. Essas unidades geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede.

Mueller (1996) ressalta que a operação de uma unidade de processamento, proposta por McCulloch e Pitts em 1943, pode ser resumida da seguinte maneira: sinais são apresentados à entrada; cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade; é feita a soma ponderada dos sinais que produz um nível de

atividade; se esse nível de atividade exceder um certo limite (*threshold*), a unidade produz uma determinada resposta de saída.

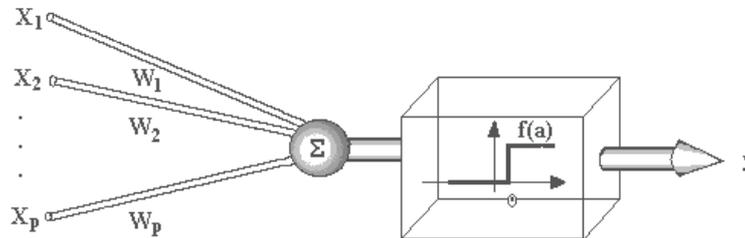


Figura 3 – Neurônio Artificial Projetado por McCulloch

Fonte: HEBB, 1949.

Supondo que se tenha p sinais de entrada X_1, X_2, \dots, X_p e pesos w_1, w_2, \dots, w_p e limitador t ; com sinais assumindo valores booleanos (0 ou 1) e pesos valores reais.

Nesse modelo, o nível de atividade a é dado por:

$$a = w_1X_1 + w_2X_2 + \dots + w_pX_p$$

A saída y é dada por

$$y = 1, \text{ se } a \geq t \text{ ou}$$

$$y = 0, \text{ se } a < t.$$

A maioria dos modelos de redes neurais possui alguma regra de treinamento, em que os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem por meio de exemplos. Arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior.

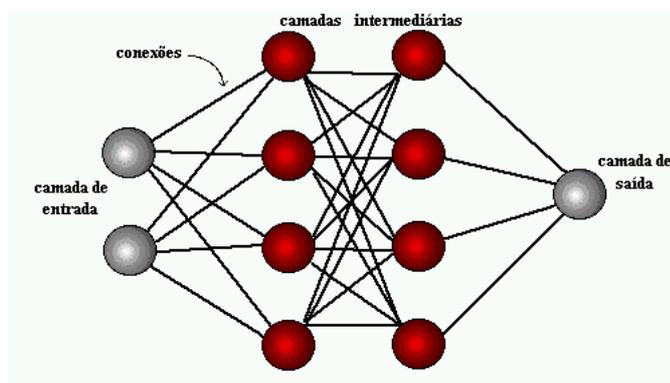


Figura 4 - Organização em Camadas

Fonte: THE MATHWORKS, 2008.

Usualmente as camadas são classificadas em três grupos:

- **Camada de Entrada:** onde os padrões são apresentados à rede.
- **Camadas Intermediárias ou Escondidas:** onde é feita a maior parte do processamento, por meio de conexões ponderadas; podem ser consideradas como extratoras de características.
- **Camada de Saída:** onde o resultado final é concluído e apresentado.

Beale e Jackson (1990) descrevem que as redes neurais podem ser dispostas em uma única camada, configuração mais simples de uma rede neural, ou em múltiplas camadas, sendo que uma rede neural é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento.

Másson e Wang (1990), por sua vez, descrevem que a topologia de uma rede neural artificial pode ser expressa por um grafo dirigido com pesos $G = (V, A, W)$, onde V corresponde a um conjunto de vértices, A a um conjunto de arcos dirigidos e W a um conjunto de pesos para esses arcos. Cada vértice no grafo representa uma unidade de processamento. Os arcos do grafo são chamados de conexões e representam as sinapses entre os neurônios artificiais.

Ainda de acordo com Másson e Wang (1990), a cada conexão no grafo está associado um peso $w_{ij}^{(l)}$, em analogia às sinapses de um modelo conexionista biológico, representando a força de ligação entre as unidades de processamento $v_i^{(l)}$ e $v_j^{(l-1)}$, onde i e j correspondem à posição — respectivamente nas camadas l e $l-1$ —, que essas unidades ocupam na rede.

Em síntese, Beale e Jackson (1990) definem que o domínio do conhecimento de um problema é representado em um modelo conexionista por meio das unidades de processamento, que abstraem a estrutura e o comportamento dos neurônios biológicos, como anteriormente definido.

Uma unidade de processamento $v_i^{(l)}$ possui entradas $x_1^{(l-1)}, x_2^{(l-1)}, \dots, x_n^{(l-1)}$, que correspondem aos estados dos neurônios $v_j^{(l-1)}$ com os quais está conectada.

Másson e Wang (1990) formalizam que a partir dessas entradas e do conjunto de pesos sinápticos $w_{ij}^{(l)}$, que refletem a força da unidade $v_j^{(l-1)}$ sobre a unidade $v_i^{(l)}$, é calculado o potencial *net* do neurônio $v_i^{(l)}$. Esse potencial no tempo t é determinado por uma *regra de propagação*, que geralmente equivale à soma linear da multiplicação das entradas pelos pesos conforme a equação:

$$net_i^{(l)}(t) = \sum_{j=1}^{n^{(l-1)}} w_{ij}^{(l)} x_j^{(l-1)}(t) - \theta_i^{(l-1)}(t)$$

Másson e Wang (1990) destacam que a propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e, com isso, melhorar seu desempenho. Isso é feito por meio de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Mueller (1996) destaca que o algoritmo de aprendizado é um conjunto de regras bem definidas para a solução de um problema de aprendizado.

Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais, esses algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

Outro fator importante é a maneira pela qual uma rede neural se relaciona com o ambiente. Nesse contexto, existem os seguintes paradigmas de aprendizado:

- **Aprendizado Supervisionado:** quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada.
- **Aprendizado Não Supervisionado (auto-organização):** quando não existe um agente externo indicando a resposta desejada para os padrões de entrada.
- **Reforço:** quando um crítico externo avalia a resposta fornecida pela rede.

Denomina-se “ciclo” uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos em um ciclo pode ser executada de dois modos:

- 1) **Modo Padrão:** a correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções.
- 2) **Modo Batch:** apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir desse erro fazem-se as correções dos pesos.

Para verificar a aderência do modelo Mueller (1996), apresenta-se um conjunto de treinamento $D = (d_i^\lambda, o_i^\lambda) : i = 1, \dots, N$, onde d_i^λ são os vetores de entrada, o_i^λ os correspondentes vetores de saída e o número de vetores do conjunto de treinamento,

ressaltando que o objetivo do treinamento está a ensinar à rede o mapeamento de todo vetor de entrada para o respectivo vetor de saída, isto é, estabelecer $(w, d_i^1) = d_o^1, 1$, pela configuração de valores apropriados para os pesos das conexões da rede. Ele segue apresentando que o ajustamento desses pesos é realizado sempre que a saída desejada do e a saída real x não forem coincidentes. Tal ajuste é realizado pela aplicação do método gradiente decrescente (equação (4.6)).

$$w_{ij}^{(l)}(t+1) = w_{ij}^{(l)}(t) + \Delta w_{ij}^{(l)}$$

com $\Delta w_{ij}^{(l)} = -\eta \frac{\partial E}{\partial w_{ij}^{(l)}}$, onde w_{ij} é a taxa de aprendizagem e Δw_{ij} , a medida do erro.

O erro é definido como uma soma sobre todos os padrões de treinamento, conforme a equação:

$$E = \sum_{\lambda=1}^{\Lambda} E^{\lambda}$$

Finalmente, como medida de erro para um padrão de treinamento específico tem-se

$$E^{\lambda} = \frac{1}{2} \sum_j (d_{o,j}^{\lambda} - x_{o,j}^{\lambda})^2$$

onde $d_{o,j}^{\lambda}$ é o j-ésimo componente do vetor de saída d_o^{λ} . O aprendizado é reduzido, portanto, à minimização da medida de erro.

3 ADEQUAÇÃO AO MERCADO DE AÇÕES

Mueller (1996) ressalta que é cada vez maior e diversa a aplicação de técnicas de modelagem de redes neurais artificiais no reconhecimento de padrões, com as redes neurais artificiais se constituindo em uma poderosa ferramenta, por sua capacidade de “aprender” padrões por meio de treinamento, o que torna seu uso importante no desenvolvimento da Inteligência Artificial.

Em termos de vantagens, Mueller (1996) destaca que a principal vantagem de uma rede neural é a sua capacidade de aproximar relações funcionais, particularmente quando as relações não são bem definidas e/ou não-lineares, o que torna difícil a utilização de métodos convencionais para a tentativa de prever as variações futuras dessas relações.

Assim, os preços dos ativos negociados diariamente possuem características de séries

temporais, sendo caracterizados por uma sequência de medições relativas a determinado evento, organizadas cronologicamente e que aparentemente não seguem nenhuma lei ou tendência. No entanto, em séries temporais relacionadas a fenômenos econômicos ou físicos, podemos notar certas características que se repetem após certo período de tempo (sazonalidade) e outras que se mantêm durante o intervalo considerado (tendências), mesmo que não obedeçam a padrões lineares.

Para Mueller (1996), a propriedade de ajustamento instantâneo das informações públicas aos preços das ações em um mercado eficiente implica independência entre as variações de preços sucessivos na sequência das negociações. Um mercado que apresenta tal comportamento é, por definição, um mercado *random walk*. De acordo com o modelo *random walk*, uma série de mudanças de preços não tem memória e, portanto, a história passada da série não pode ser usada para prever o futuro de uma maneira significativa.

O autor ressalta que, apesar da força da *hipótese do mercado eficiente*, ela ainda é uma teoria e qualquer teoria pode ser refutada com evidência apropriada. Todavia, embora não existam evidências empíricas que validem a hipótese forte de eficiência de mercado, vários trabalhos conseguem detectar com razoável grau de robustez a hipótese de eficiência fraca e semi-forte para o mercado de capitais.

Ainda citando Mueller (1996), os estudos empíricos sobre o mercado demonstraram que o movimento das cotações das ações não segue o modelo *random walk*.

Ocorre que em vários testes realizados no mercado, tanto aqui no Brasil como no exterior, verificou-se [...] que os preços das próximas negociações são fortemente dependentes dos preços das negociações anteriores, sendo possível, então, prever tendências de preços a partir da observação dos movimentos passados.

É a partir dessa constatação que a modelagem de redes neurais artificiais se torna uma ferramenta importante na investigação de regularidades no preço das ações mascaradas pelas oscilações do mercado. Assim, este trabalho tem por objetivo fazer com que a rede neural aprendesse características temporais para a série de preços da Petrobrás PN.

4 DADOS DA AMOSTRA E METODOLOGIA

Esta seção é dedicada à construção do modelo RNA para estimação dos preços das ações da PN da Petrobrás. Assim, será descrita detalhadamente a estruturação do modelo estimado no *software* Matlab 7.6.0.324 R2008a.

A primeira etapa do trabalho consiste em obter a série de preços em reais ajustada pelos proventos distribuídos da Petrobrás PN, negociadas no mercado à vista da Bolsa de Valores de São Paulo - Bovespa, entre o período de 2 de janeiro de 2001 e 9 de maio de 2008, extraídos do *software* Economática. Na sequência, os dados são exportados para a planilha Microsoft Excel, onde são apresentados em duas colunas: coluna A, contendo as datas; e a Coluna B, contendo a série de preços da Petrobrás PN em reais. Apenas para fins de ilustração, apresenta-se a seguir o gráfico com a evolução dos preços.

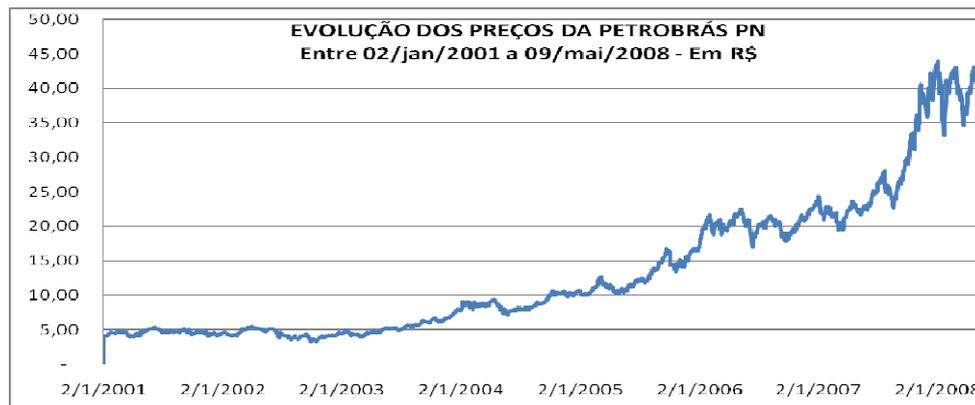


Gráfico 1 – Evolução dos Preços da Petrobrás PN

Fonte: Elaborado pelos autores.

Após a organização dos dados da amostra, passa-se a executar o comando de rotinas para que o Matlab 7.6.0.324 R2008 possa executar a estruturação do modelo. A rotina escolhida é a que está configurada para séries de tempo não estacionárias, em que a proposição de estrutura, conforme instruções do *help* do Matlab 7.6.0.324 R2008, é a seguinte:

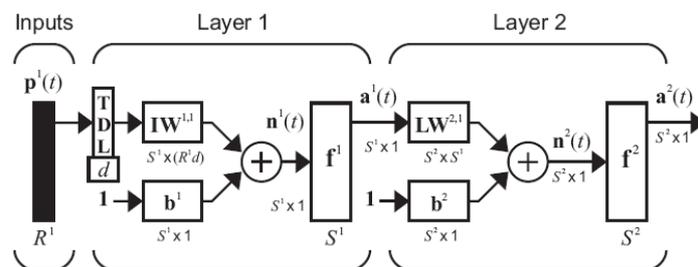


Figura 5 – Circuito de múltiplos neurônios

Fonte: Fonte: THE MATHWORKS, 2008.

Assim, introduzem-se os dados sob a forma de matriz e inverte-se a matriz mediante a importação do Microsoft Excel, com os seguintes comandos:

```
>>A= [3,96 4,18:.....45,00 45,67]
```

```
>>A=A'
```

```
>>A = cons2seq(A)
```

A próxima sequência se refere à criação da RNA e seu treinamento propriamente dito, informando a quantidade de neurônios, no caso 5, e os parâmetros para estimação e de treinamento, no caso 8; Também é informado o número de interações, no caso 50. :

```
>> ftdnn_net = newfftd(A,A,[1:8],5);
```

```
>>ftdnn_net.trainParam.show = 10;
```

```
>>ftdnn_net.trainParam.epochs = 50;
```

```
>> p = A(9:end);
```

```
t = A(9:end);
```

```
Pi=A(1:8);
```

O próximo passo consiste em treinar e simular a rede e calcular o erro quadrado médio (RMSE).

```
ftdnn_net = train(ftdnn_net,p,t,Pi);
```

```
>> yp = sim(ftdnn_net,p,Pi);
```

```
yp = cell2mat(yp);
```

```
e = yp-cell2mat(t);
```

```
rmse = sqrt(mse(e))
```

```
rmse = 0.3475
```

Para ilustrar, a seguir apresenta-se a tela de treinamento e estimação da RNA:

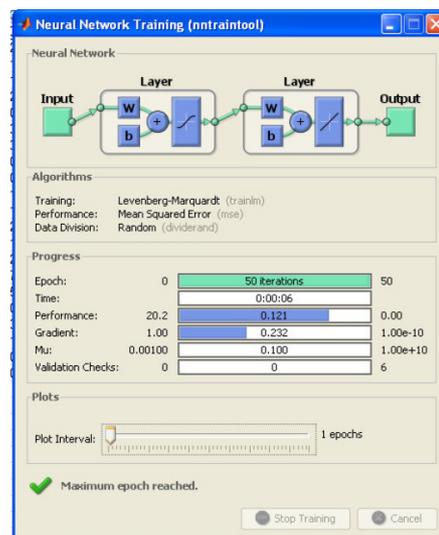


Figura 6 - Tela de Treinamento e Estimação da RNA

Fonte: THE MATHWORKS, 2008.

Após a apresentação do RMSE, testa-se a aderência do modelo pela estimação “oito passos a frente”:

```
>> plot(e)
>> Q = [ 42.55 42.65 43.10 42.51 41.60 42.15 42.59 40.90]
>> Q = Q'
>> Q = con2seq(Q)
>> yi = sim(ftdnn_net,Q)
yi = [0.1796] [36.9672] [33.3286] [44.5264] [40.0570] [33.0240]
[42.6133] [45.1307]
```

Após a execução da rotina, o Matlab 7.6.0.324 gera as estimações para o período da amostra com os respectivos erros, resultando o seguinte gráfico:

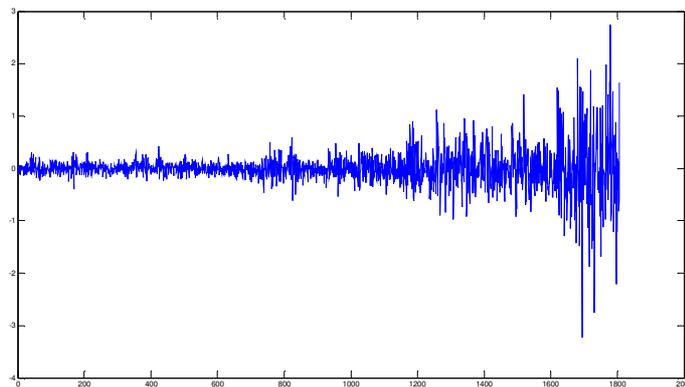


Figura 7 – Estimações da Amostra com os Respetivos Erros

Fonte: THE MATHWORKS, 2008.

5 ANÁLISE DOS RESULTADOS

A partir dos dados apresentados, pode-se observar que o modelo consegue apresentar um grau de aderência bastante robusto com um baixo RMSE. Naturalmente, à medida que a estimação se afasta muito da amostra, o RMSE aumenta de valor. Além disso, consegue-se nas projeções “oito passos a frente”, se comparados com a realidade efetiva, a confirmação da aderência do modelo, conforme a ilustração da Tabela 1 e do Gráfico 2.

Tabela 1
Comparativo Estimado X Realizado

| Comparativo Estimado X Realizado | | |
|----------------------------------|----------|-----------|
| Realizado | Estimado | Diferença |
| 40,90 | 17,96 | 22,94 |
| 42,20 | 36,97 | 5,23 |
| 43,00 | 33,33 | 9,67 |
| 43,85 | 44,53 | (0,68) |
| 45,00 | 40,06 | 4,94 |
| 44,85 | 33,03 | 11,82 |
| 45,00 | 42,61 | 2,39 |
| 45,67 | 45,13 | 0,54 |

Fonte: Elaborada pelos autores.

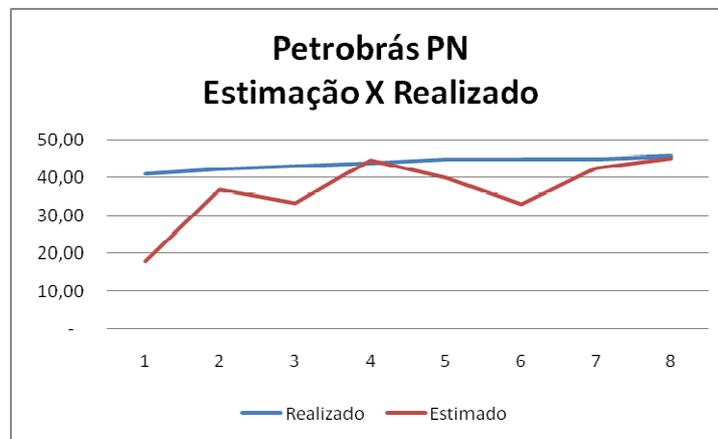


Gráfico 2 – Petrobrás PN – Estimado X Realizado

Fonte: Elaborado pelos autores.

Assim, mesmo considerando as limitações do modelo em relação ao tamanho da amostra, é possível constatar que a utilização das redes neurais como instrumento de previsão para o comportamento do preço das ações da Petrobrás PN apresenta um alto grau de consistência.

6 CONSIDERAÇÕES FINAIS

A aplicação de redes neurais artificiais na previsão de preços de ações, testada empiricamente com uma amostra de preços das ações preferências nominativas da Petrobrás, negociada no mercado à vista na Bovespa, durante o período de 2 de janeiro de 2001 até 9 de maio de 2008, gerou resultados satisfatórios em termos de estimação, tanto em termos de

baixo nível de RMSE como de comparação dos valores previstos com o efetivamente realizado.

Tais resultados são confirmados por outros trabalhos, pois a literatura tem dedicado espaço relativamente grande para a aplicação das RNA na previsão de séries temporais, pois as mesmas possuem comportamentos em que as propriedades de convergência, generalização e aprendizado das redes neurais podem gerar resultados muito satisfatórios quando comparados com outros modelos.

Em contrapartida, os resultados do presente trabalho possuem limitações que podem ser minimizadas mediante a aplicação dos modelos de RNA comparados com os modelos ARCH e GARCH, bem como por meio da utilização de uma lista de ações diferentes, incluindo não só ações de alta liquidez, como também ações de baixa liquidez. Adicionalmente, a robustez do modelo poderia ser testada à medida que se utilizassem janelas móveis de tempo.

USE OF ARTIFICIAL NEURAL NETWORKS FOR ESTIMATIONS OF RATES ON BOVESPA PETROBRAS PN

Abstract: The increasing sophistication of some operations in the finance market had increased a lot the exposure of the risk from some operations. So, it requests the use of some advanced technologies to model and to esteem series of asset prices. One of the approaches that are receiving importance in the modeling of prices and volatility is the Artificial Neural Networks. The main purpose of this article is to esteem, through ANN, the prices of Petrobrás PN using a series of daily prices between January 2, 2001 and May 9, 2008. This series represents 1821 daily observations. After the ANN was modeled in the software Matlab 7.6.0. R2008a, it was calculated the RMSE, estimated the Petrobrás PN prices and compared the estimated and real prices of the selected asset. The conclusion was that, comparing the estimated prices to the real prices of Petrobrás in the analyzed period, there is a high degree of adherence of the model to ANN in short term. However these studies could have other tests where they will consider different windows of time, including moments with huge stress in the prices and others with fewer adherences in the market, aiming to increase the reliability level of the model.

Keywords: Artificial neural networks (ANN). Petrobrás. Estimation of prices.

REFERÊNCIAS

- BEALE, R.; JACKSON, T. **Neural computing**: an introduction. Bristol: Adam Hilger, 1990.
- ECONOMÁTICA. Disponível em: <www.economatica.com.br>. Acesso em: 19 mar. 2009
- HEBB, D. O. **The organization of behavior**. New York: John-Wiley & Sons Inc, 1949.
- KOHONEN, T. An introduction to neural computing. **Neural Networks**, v. 1, p. 3-16, 1988.
- MÁSSON, E.; WANG, Y. Introduction to computation and learning in artificial neural networks. **European Journal of Operational Research**, North-Holand, 47, 1990.
- MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. Dissertação (Mestrado em Engenharia da Produção) - Pós-Graduação na Engenharia da Produção, Universidade Federal de Santa Catarina, Florianópolis, 1996.
- TAFNER, M. A. As redes neurais artificiais: aprendizado e plasticidade. **Cérebro Mente**, São Paulo, v. 5, 1998.
- TAFNER, M. A.; XEREZ, M.; FILHO, I. R. **Redes neurais artificiais**: introdução e princípios de neurocomputação. Blumenau: EKO, 1995.
- THE MATHWORKS, **Software matemático Matlab R2008a**, versão 2.0.6, 2008. 1 CD-ROM.
- WASSERMAN, P. D. **Neural computing**: theory and practice. New York: Van Nostrand Reinhold, 1989.