

**FACULDADES INTEGRADAS DE TAQUARA  
CURSO DE SISTEMAS DE INFORMAÇÃO**

**USO DE REDES NEURAIS PARA CÁLCULO DE SEGUIDORES DE TENDÊNCIAS  
NO MERCADO DE AÇÕES**

**JACOB DE QUADROS STEIN**

**Taquara**

**2010**

**JACOB DE QUADROS STEIN**

**USO DE REDES NEURAIIS PARA CÁLCULO DE SEGUIDORES DE TENDÊNCIAS  
NO MERCADO DE AÇÕES**

Trabalho de Conclusão apresentado ao Curso de Sistemas de Informação das Faculdades Integradas de Taquara, como requisito parcial para obtenção do grau de bacharel, sob orientação do Prof. Ms. Émerson Barbiero Hernandez.

**Taquara**

**2010**

## RESUMO

Atualmente, percebe-se uma busca cada vez maior da sociedade por boas fontes de investimento, que tragam um retorno satisfatório em relação ao valor aplicado. A partir disso, o mercado de ações surge como uma alternativa para os investidores, sejam eles empresas ou pessoas físicas. Contudo, é necessário um conhecimento considerável do mercado financeiro para que seja possível obter uma boa lucratividade ao investir em ações, o que traz dificuldades para pessoas que não estejam ligadas a esta área. Baseando-se nisso, este trabalho tem como objetivos estudar o funcionamento do mercado de ações e das redes neurais, para após, tentar desenvolver uma alternativa diferente dos métodos atuais de análise técnica do mercado, através de recursos de Inteligência Artificial, utilizando Redes Neurais Artificiais para tentar detectar bons momentos de compra e venda de ações.

**Palavras-chave:** Inteligência Artificial, Redes Neurais Artificiais, Mercado de Ações, Análise Técnica.

## LISTA DE FIGURAS

Figura 1 – Gráfico de Linhas .....	18
Figura 2 – Gráfico de Volume.....	18
Figura 3 – Gráfico de Barras .....	19
Figura 4 – Gráfico de ponto-figura.....	20
Figura 5 – Gráfico de <i>candlesticks</i> .....	20
Figura 6 – Gráfico de médias móveis.....	21
Figura 7 – Modelo de neurônio .....	25
Figura 8 – Rede de camada única.....	26
Figura 9 – Rede de múltiplas camadas .....	27
Figura 10 – Rede recorrente de camada única.....	28
Figura 11 – Modelo de rede de Hopfield.....	28
Figura 12 – Desktop Trader.....	31
Figura 13 – Trader Data.....	32
Figura 14 – <i>Screenshot</i> do programa JOONE .....	33
Figura 15 – Gráfico função sigmoide .....	34
Figura 16 – Gráfico função tangente hiperbólica .....	36

## LISTA DE TABELAS

Tabela 1 – Padrão de saída - primeira simulação .....	35
Tabela 2 – Padrão de saída - segunda simulação.....	37
Tabela 3 – Valores de entrada .....	38
Tabela 4 – Padrão de saída - RNA .....	42
Tabela 5 – Dados a partir de 11/06/08.....	44
Tabela 6 – Dados a partir de 14/03/2008.....	45
Tabela 7 – Dados a partir de 10/02/2009.....	45

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>8</b>
<b>2</b>	<b>REVISÃO TEÓRICA.....</b>	<b>9</b>
<b>2.1</b>	<b>Mercado financeiro e sistema financeiro nacional.....</b>	<b>9</b>
<b>2.2</b>	<b>Mercado de Capitais.....</b>	<b>10</b>
<b>2.3</b>	<b>Mercado de Ações.....</b>	<b>11</b>
2.3.1	Mercado à vista.....	12
2.3.2	Mercado a termo.....	13
2.3.3	Mercado de Opções.....	12
2.3.4	Mercado Futuro.....	13
2.3.5	Bovespa e Ibovespa.....	13
2.3.6	Bolsa de Mercadorias e Futuros – BM&F.....	14
2.3.7	Dow Jones.....	15
<b>2.4</b>	<b>Análise Fundamentalista.....</b>	<b>15</b>
<b>2.5</b>	<b>Análise Técnica.....</b>	<b>16</b>
2.5.1	Teoria Dow.....	16
2.5.2	Teoria de Ondas de Elliot.....	17
2.5.3	Gráfico de linha.....	18
2.5.4	Gráfico de volume.....	18
2.5.5	Gráfico de barras.....	19
2.5.6	Gráfico ponto-figura.....	20
2.5.7	Gráfico <i>Candlesticks</i> .....	20
2.5.8	Médias Móveis.....	21
<b>2.6</b>	<b>Inteligência Artificial.....</b>	<b>22</b>
<b>2.7</b>	<b>Redes Neurais Biológicas.....</b>	<b>23</b>
<b>2.8</b>	<b>Redes Neurais Artificiais.....</b>	<b>24</b>
2.8.1	Modelo geral de neurônio.....	25
2.8.2	Redes diretas de camada única.....	26
2.8.3	Redes diretas de múltiplas camadas.....	27

2.8.4	Redes recorrentes .....	28
2.8.5	Aprendizagem supervisionada .....	29
2.8.6	Aprendizagem não supervisionada .....	29
2.8.7	Algoritmo de retropropagação .....	30
<b>2.9</b>	<b>Tecnologias .....</b>	<b>30</b>
<b>2.10</b>	<b>Softwares e trabalhos similares .....</b>	<b>30</b>
<b>3</b>	<b>SIMULAÇÕES COM JOONE .....</b>	<b>33</b>
<b>4</b>	<b>ALGORITMOS BASEADOS EM RNAS.....</b>	<b>38</b>
<b>4.1</b>	<b>Rede baseada em previsão de crescimento .....</b>	<b>38</b>
<b>4.2</b>	<b>Redes para compra e venda .....</b>	<b>42</b>
<b>5</b>	<b>CONCLUSÃO .....</b>	<b>47</b>
	<b>REFERÊNCIAS.....</b>	<b>49</b>

## 1 INTRODUÇÃO

O ser humano tem a tendência de sempre buscar a realização pessoal. Nessa busca, a realização financeira representa uma grande fatia. Devido a este fato muitas pessoas buscam aplicar parte do dinheiro que ganham em diversos tipos de fontes de investimento com o objetivo de aumentar sua renda.

Dentre todas as opções existentes, a mais conhecida e usada é a poupança, que garante segurança, mas com pouca lucratividade. Entre outras alternativas de renda fixa e variável, uma que tem se destacado e ganhado cada vez mais visibilidade nos últimos anos é o investimento no mercado de ações, que tem se mostrado cada vez mais interessante.

Através da compra e venda de ações das empresas é possível obter uma grande rentabilidade com a valorização das ações compradas. Por isso, é decisivo ter conhecimento a respeito do mercado financeiro, para que aplicação do capital seja feita de maneira correta e no momento certo. Detectar este período não é uma tarefa simples, pois qualquer evento, em qualquer parte do planeta, traz influências para o mercado de todo o mundo. Assim, os especialistas necessitam experiência e contam com ferramentas que ajudam a analisar a situação do mercado.

Buscou-se neste trabalho, o desenvolvimento de uma ferramenta que pudesse contribuir para essa tarefa. Para tanto, foi utilizado como base o diferencial de trabalhar de maneira dinâmica, gerando regras voláteis com o uso de redes neurais, tornando possível aprender melhores momentos para realizar as transações, através da análise do histórico do mercado, ao contrário da maioria dos *softwares* existentes que trabalham com regras de negócio fixas.

Para isso, este trabalho faz, inicialmente, uma revisão teórica, trabalhando os principais conceitos relacionados ao mercado financeiro nacional e mercado de ações, bem como as principais técnicas utilizadas para análise deste. Em seguida, no segundo capítulo, são explicados os principais conceitos de relacionados às Redes Neurais Artificiais (RNAs). No terceiro capítulo são descritas simulações de redes realizadas com o *software* JOONE. No quarto capítulo são descritos os métodos e estrutura utilizados e os resultados relacionados às redes neurais implementadas através de programação. Por fim, é feita uma conclusão com relação ao trabalho realizado.

## **2 REVISÃO TEÓRICA**

Neste capítulo é feita uma descrição dos principais conceitos relacionados ao mercado de ações e também às redes neurais, de modo a dar um maior embasamento teórico ao trabalho realizar e facilitar o entendimento de alguns conceitos utilizados.

### **2.1 Mercado financeiro e sistema financeiro nacional**

Sistema financeiro é o conjunto de instituições que se dedicam ao trabalho de propiciar condições satisfatórias para manter o fluxo de recursos entre poupadores e investidores (FORTUNA, 2005).

No mercado financeiro é onde essas transações são processadas, permitindo que um agente econômico com recursos disponíveis (superavitário) possa aplicar sua poupança em ativos financeiros emitidos pelos agentes que necessitem de recursos (deficitários) (EIZIRIK, 2008).

Com relação às instituições, elas dividem-se em dois grandes grupos: intermediários financeiros e instituições auxiliares. Os intermediários financeiros captam poupança diretamente do público por sua conta própria para, posteriormente, aplicar estes recursos junto às empresas. As instituições auxiliares têm como objetivo facilitar o contato entre poupadores e investidores (FORTUNA, 2005).

O sistema financeiro influencia o processo de formação de capital, e assim, o desenvolvimento econômico do país, por meio da contribuição para expandir o volume total de poupança do país. Torna, ainda, mais eficiente a transformação de fundos poupados em capital produtivo (EIZIRIK, 2008).

Segundo Galvão (2006), o desenvolvimento de um país depende da participação crescente de capitais, e o processo de distribuição de recursos evidencia a função econômica e social do SFN.

O Conselho Monetário Nacional é a entidade superior do sistema financeiro. É um órgão normativo responsável pela fixação das diretrizes das políticas monetária, creditícia e cambial do país. Cabe ao CMN regular o valor interno e externo da moeda, orientar a

aplicação de recursos das instituições financeiras, estabelecer meta de inflação, entre outras funções (FORTUNA, 2005).

Segundo Fortuna (2005), o Banco Central é a entidade que atua como órgão executivo do sistema financeiro, tendo a responsabilidade de cumprir e fazer cumprir a regulamentação do sistema e as normas expedidas pelo CMN.

O BC é considerado o Banco dos Bancos, sendo que por meio dele é que o Estado intervém diretamente no sistema financeiro e, indiretamente, na economia.

## **2.2 Mercado de Capitais**

O Mercado de Capitais representa um sistema de distribuição de valores mobiliários com o objetivo de viabilizar a capitalização das empresas e dar liquidez aos títulos emitidos por elas. Ele é constituído pelas bolsas de valores, sociedades corretoras, entre outras instituições financeiras (BOVESPA, 2008).

Segundo Eizirik (2008), a principal função do Mercado de Capitais é a de permitir que as empresas possam captar recursos não exigíveis para financiar seus projetos de investimento ou alongar prazos de dívidas. Como esses recursos não são considerados empréstimos, a empresa não está obrigada a devolver o valor aos investidores (exceto em alguns casos), porém deve remunerá-los, sob a forma de dividendos, caso a companhia obtenha lucros. E, partindo disso, percebe-se que os investidores não têm garantias quanto ao retorno dos investimentos, decorrendo daí a natureza do Mercado de Capitais como um “mercado de risco”.

Nesse mercado, os principais títulos negociados são as ações, os representativos do capital das empresas e os representativos de empréstimos tomados por elas, via mercado, permitindo circulação de capital para custear desenvolvimento econômico (BOVESPA, 2008).

O crescimento econômico é muito ligado ao Mercado de Capitais devido ao fato deste aumentar as alternativas de financiamento para as empresas, reduzir o custo de financiamentos, diversificar e distribuir o risco e democratizar o acesso ao capital (PINHEIRO, 2008).

O Mercado de Capitais pode ser subdividido em mercado primário e secundário.

No mercado primário é onde ocorre a venda de novos títulos por parte do emissor, gerando uma entrada de recursos no seu caixa, atendendo a finalidade principal do mercado de capitais, que é permitir captação de recursos do público (GALVÃO, 2006).

No mercado secundário é onde os títulos são revendidos, porém não há ingresso de novos recursos no caixa do emissor. Todavia, esse mercado é de grande importância para governos ou empresas, pois quanto melhor for o mercado secundário para o emissor, maiores serão as chances de investidores adquirirem papéis no mercado primário (GALVÃO, 2006). Nesse mercado, as operações podem ocorrer em Bolsa de Valores, Futuros e Mercadorias, ou no “mercado de balcão” (EIZIRIK, 2008).

### **2.3 Mercado de Ações**

Ações são títulos que representam, cada uma, a menor parcela do capital social de uma empresa. Esse tipo de empresa é denominada “Sociedade Anônima”, podendo ser de capital fechado ou aberto. No caso de possuir capital aberto, a empresa deve ser registrada como tal na Comissão de Valores Mobiliários, tendo a obrigação de prestar informações sobre seu comportamento social, econômico e financeiro (MELLAGI FILHO, 2003).

Existem dois tipos de ação: ordinárias e preferenciais. Nas ordinárias, a característica principal é o direito a voto, conferindo ao titular o direito de participar em assembleias gerais e de acionistas. Nas preferenciais não há direito a voto, porém o titular tem preferência sobre lucros a serem distribuídos, na forma de juros sobre capital próprio ou dividendos (FORTUNA, 2005).

O mercado de ações pode ser dividido em primário e secundário, como já explicado anteriormente. No mercado secundário são comercializadas as ações já emitidas através das bolsas de valores (FORTUNA, 2005).

As bolsas de valores não são instituições financeiras, mas associações civis sem fins lucrativos, constituídas pelas corretoras de valores, fornecendo a infra-estrutura do mercado de ações. Pode-se dizer que a sua função não é de gerar riqueza, mas de transferir os recursos da economia (PINHEIRO, 2008).

### 2.3.1 Mercado à vista

Neste mercado é onde são realizadas as operações de compra e venda de ações para liquidação imediata (FORTUNA, 2005).

A principal característica do mercado à vista é a cotação atual dos preços das ações com liquidação em três dias úteis, sendo que a liquidação física (entrega dos títulos ao comprador) é realizada em dois dias úteis após a operação, e a liquidação financeira (pagamento e recebimento do valor da operação) ocorre no terceiro dia útil (PINHEIRO, 2008).

No mercado à vista também é permitida a realização de compra e venda de ações em um mesmo pregão, pela mesma corretora e mesmo investidor. Esta operação é chamada de *day-trade* e a liquidação financeira ocorre por compensação, também no terceiro dia útil (FORTUNA, 2005).

### 2.3.2 Mercado a termo

Este mercado é caracterizado pela compra ou venda de ações para liquidação futura, por um prazo predeterminado e preço fixado. Os prazos permitidos variam, normalmente, de 30 a 180 dias (MELLAGI FILHO, 2003).

O preço é determinado pelo preço da ação acrescido de uma taxa de juros, sendo também necessário, para operar nesse mercado, o depósito de uma margem de garantia, determinada pela Bovespa (MELLAGI FILHO, 2003).

O mercado a termo é utilizado, principalmente, nos casos onde há uma expectativa de alta ou baixa de uma ação, em operação de financiamento, caixa ou arbitragem entre investimentos (FORTUNA, 2005).

### 2.3.3 Mercado de Opções

O mercado de opções é uma modalidade operacional, onde não há a negociação da ação, mas direitos sobre ela. Assim, opções são direitos de uma parte comprar ou vender a outra certa quantidade de ações-objeto por um preço e durante um tempo preestabelecidos (PINHEIRO, 2008). Os direitos sobre as ações são negociados por um preço chamado de prêmio (FORTUNA, 2005).

Neste mercado, existem duas modalidades: opção de compra e opção de venda. Na primeira, o titular tem o direito de comprar certo lote de ações por um preço determinado, até certa data. Na segunda, o titular adquire o direito de vender o lote de ações, também por preço e data preestabelecidos. (MELLAGI FILHO, 2003).

### 2.3.4 Mercado Futuro

Neste mercado, as ações são negociadas com datas de liquidação futura, a um preço acordado entre as partes, com vencimento em data específica. O mercado futuro representa um aperfeiçoamento do mercado a termo, sendo possível que os envolvidos na transação revertam sua posição antes da data de vencimento (FORTUNA, 2005).

No mercado futuro, ao contrário do mercado a termo, o preço não é fixo até o dia da liquidação, ele vai sendo alterado diariamente, em função das negociações ocorridas no mercado (PINHEIRO, 2008).

### 2.3.5 Bovespa e Ibovespa

Segundo Pinheiro, 2008, fundada em 23 de agosto de 1890, como entidade oficial corporativa, a Bolsa de Valores de São Paulo só se tornou uma associação civil, sem fins lucrativos, com autonomia administrativa, financeira e patrimonial, como se mantém até hoje, em 1967.

A Bovespa é o maior centro de negociação de ações de América Latina, chegando a isso através da integração de todas as bolsas brasileiras em torno de um único mercado de valores, passando a concentrar toda a negociação com ações (PINHEIRO, 2008).

A Bovespa coleta, organiza e divulga várias informações sobre os negócios realizados em cada pregão. Entre essas informações está o Índice Bovespa, que é o mais importante e representativo indicador de desempenho médio das cotações do mercado de ações brasileiro.

O Ibovespa retrata o comportamento dos principais papéis negociados na Bovespa. Ele é o valor atual, em moeda corrente, de uma carteira teórica de ações, a partir de uma aplicação hipotética. Desde sua implantação, em 02 de janeiro de 1968, não sofreu modificações, sendo extremamente confiável e possuindo uma metodologia de fácil acompanhamento. Essa carteira teórica é formada pelas ações que, em conjunto, representam 80% do volume transacionado nos últimos 12 meses e a cada 4 meses é feita uma reavaliação do mercado, com o objetivo de identificar alterações e manter a representatividade do índice.

A Bovespa calcula seu índice em tempo real, considerando os preços de todos os negócios efetuados no mercado à vista com ações integrantes de sua carteira. O cálculo do Ibovespa é feito através do somatório dos pesos das ações (quantidade teórica da ação multiplicada pelo último preço da mesma) que compõem a carteira teórica (FORTUNA, 2005).

### 2.3.6 Bolsa de Mercadorias e Futuros – BM&F

A BM&F é uma associação sem fins lucrativos, representando a maior bolsa de commodities da América Latina e, ao longo de sua existência, incorporou outras instituições que atuavam na mesma área, tais como a BMSP (Bolsa de Mercadorias de São Paulo), em 1917 e a BBF (Bolsa Brasileira de Futuros), do Rio de Janeiro (BESSADA, 2003).

O maior objetivo da BM&F é organizar, operacionalizar e desenvolver um mercado de derivativos livre e transparente, que proporcione, aos agentes econômicos, oportunidades para a realização de operações de *hedge* contra as flutuações de preço das mais variadas *commodities* – produtos agropecuários, taxas de juro e câmbio, metais, índices de ações e todo e qualquer produto cuja a incerteza quanto à variação de seu preço no futuro possa influenciar negativamente a atividade econômica (FORTUNA, 2005).

Em 2008, a BM&F integrou-se com a Bovespa, criando a BM&FBOVESPA S.A., dando origem a uma das maiores bolsas do mundo em valor de mercado (BM&FBOVESPA, 2009).

### 2.3.7 Dow Jones

Desenvolvido pela Dow Jones & Co., foi o primeiro índice de preços de ações que surgiu nos Estados Unidos, em 1884, baseado na simples média aritmética, em que divide-se a soma dos preços das ações pelo número de empresas emitentes destas.

Todavia, esse método tornou-se um pouco ineficaz devido aos *splits*, quando da valorização das ações, e *inplits*, no caso de desvalorização. Assim, em 1928, foi apresentado um novo método, utilizando um número divisor para ajuste do índice, que, a partir desta data, ficou conhecido como Dow Jones *Industrial Average* (MELLAGI FILHO, 2003). Atualmente, esse índice é baseado nas trinta empresas mais negociadas na NYSE (New York Stock Exchange), a Bolsa de Nova Iorque (PINHEIRO, 2008).

## 2.4 Análise Fundamentalista

Segundo Pinheiro (2008), a análise fundamentalista utiliza fundamentos econômico-financeiros para determinação do valor da empresa, baseando-se em um estudo de toda a informação disponível sobre ela no mercado, com o objetivo de obter seu “valor real”.

Para esse tipo de análise é adotada a hipótese de que o mercado é eficiente em longo prazo, apesar de ocorrerem ineficiências em curto prazo. Assim, a justificativa para uso da análise fundamentalista é a de antecipar o comportamento futuro de uma determinada empresa. Para isso, é feito um cálculo do que seria um “valor justo” para ela, baseando-se em pontos, como: demonstrações financeiras passadas, situação atual da economia, estimativas futuras, lucro esperado, investimentos realizados e a realizar, entre outros.

## 2.5 Análise Técnica

Segundo Pinheiro (2008), a escola de análise técnica de ações é muito mais antiga que a escola fundamentalista. Seus primórdios são em 1700, quando algumas famílias japonesas já começaram a formular preço para um mercado futuro de arroz, a partir do acompanhamento do passado e formulação de tendência, criando um método muito conhecido como *Candlesticks*.

A análise técnica tem como conceito justamente o acima citado, tendo o objetivo de prever o comportamento dos preços das ações com base em estudos de movimentos passados e volume de ativos negociados.

Nesta análise é estudado como os preços movimentam-se e não o porquê disso. Ela toma como premissa o fato dos preços de negociações futuras estarem ligados aos preços de negociações anteriores (CAVALCANTE, 2002).

A escola técnica parte de três princípios: a ação do mercado já reflete todos os fatores envolvidos nele, ou seja, qualquer valor que possa influenciar o preço da ação já se encontra refletido em seu valor; os preços movem-se em tendências, apresentando padrões identificáveis; o futuro reflete o passado, baseando-se no conceito de que o investidor tende a reagir de forma similar a situações anteriores (PINHEIRO, 2008).

Dentro desta forma de análise, existem diversos métodos de avaliação do mercado, como teorias para análise de tendência, análise a partir de diversos tipos de gráficos e indicadores técnicos. Esses métodos serão apresentados nas próximas seções.

### 2.5.1 Teoria Dow

A teoria Dow é um conjunto de artigos publicados por Charles H. Dow, co-fundador da *Dow Jones & Co.*, entre 1900 e 1902. Ele dizia que o que aconteceu hoje pode determinar o que acontecerá amanhã, sendo o primeiro a enunciar que as ações do mercado se movem juntamente, seguindo a trajetória das mais representativas, tornando possível medir a intensidade das oscilações através de uma média (CAVALCANTE, 2002).

A partir dessa teoria surgiu o conhecido índice Dow Jones, sendo Charles Dow o primeiro a utilizar um índice médio de cotação como instrumento de avaliação da NYSE por

volta de 1884. Ele criou três índices, utilizados até hoje, apesar de terem sofrido alterações. São eles: Dow Jones Industrial (composto por 30 ações), Dow Jones Transportes (composto por 20 ações) e Dow Jones Serviços (composto por 15 ações).

A Teoria Dow foi baseada nos pressupostos de que as alterações diárias dos índices consideram o julgamento de todos os investidores e de que o mercado apresenta movimentos oscilatórios em amplitudes de longo prazo (um ano ou mais), médio prazo (três semanas a alguns meses) e curto prazo (seis dias e três semanas) (PINHEIRO, 2008).

### 2.5.2 Teoria de Ondas de Elliot

Criada por Ralph Nelson Elliot, em 1939, através de suas observações durante vários anos, essa teoria é considerada uma das principais ferramentas para localizar e antecipar determinados ciclos da bolsa (PINHEIRO, 2008).

A partir do estudo do DJIA (*Dow Jones Industrial Average*), Elliot descobriu que os preços das ações seguem um determinado comportamento identificável sob a forma de padrões geométricos ou figuras. Baseado nisso, ele identificou as formações de figuras no mercado, geradas pelo comportamento e oscilações do humor coletivo. Notou que são ondas que se repetem ao longo do tempo e podem ser reconhecidas, possibilitando assim uma previsão (MENDONÇA, 2009).

Elliot aprofundou-se nos estudos do matemático italiano Leonardo Fibonacci, que se destacou no século XIII, e criou, a partir do estudo do crescimento da população de coelhos, a série Fibonacci, na qual o número seguinte é obtido pela soma dos dois anteriores, contribuindo também para o chamado “número de ouro” ou 1,618, que, segundo o matemático, seria uma constante universal de crescimento e evolução da natureza (MENDONÇA, 2009).

Aplicando a série de Fibonacci aos seus estudos, Elliot concluiu diversas relações entre as ondas do mercado, como a de que a medida da primeira onda de uma sequência serve para estimar o comprimento das outras ondas que compõem essa sequência (PINHEIRO, 2008).

### 2.5.3 Gráfico de linha

Este tipo de gráfico, também chamado de gráfico simples, consiste na representação das cotações em intervalos de tempos regulares unidas por linhas retas. Para cada período marca-se um ponto para cada preço, e após uni-los, obtém-se uma linha representando a evolução das cotações. Para o gráfico de linha podem ser utilizadas diversas formas de cotação, como: abertura, fechamento, máxima, mínima e média (PINHEIRO, 2008).

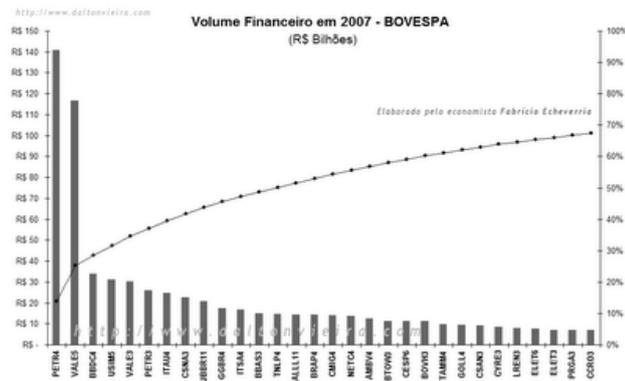


**Figura 1 – Gráfico de linhas**

Fonte: Weiland (2009, p.1)

### 2.5.4 Gráfico de volume

Segundo Pinheiro (2008), o gráfico de volume faz uma relação entre o valor monetário das transações realizadas ou o número de ações negociadas e um determinado período de tempo. Este gráfico é representado por meio de colunas verticais com o tamanho respectivo ao seu volume. Por meio do gráfico de volume é possível valorizar a força com que as cotações se movimentam, como, por exemplo, o fato de que uma forte alta só deve ser considerada significativa se for acompanhada por um alto volume. Devido a este fato, este tipo de gráfico costuma ser utilizado em conjunto com gráfico de linhas ou barras.

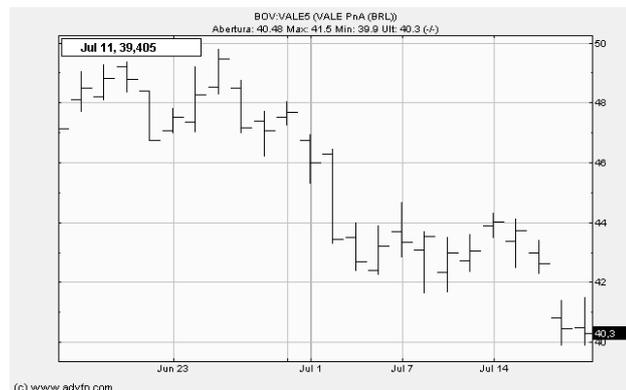


**Figura 2 – Gráfico de volume**

Fonte: Weiland (2009, p.1)

### 2.5.5 Gráfico de barras

Segundo Cavalcante (2002), o gráfico de barras é o instrumento mais utilizado pelos analistas, pois através dele é possível visualizar os preços máximo, mínimo, de fechamento, de abertura e o volume negociado em um determinado tempo. Cada período é representado por uma barra vertical, que liga os pontos de cotação máxima e mínima. Os valores de abertura e fechamento são representados por um traço horizontal, respectivamente à esquerda e à direita da barra vertical.



**Figura 3 – Gráfico de barras**

Fonte: Weiland (2009, p.1)

### 2.5.6 Gráfico ponto-figura

Este tipo de gráfico é mais preciso, trabalha com alterações em função do preço e não do tempo, retratando todos os preços pelos quais a ação foi negociada, não levando em conta o dia, mas representando com precisão a reversão da tendência. É um gráfico construído por meio de colunas X e O, onde este reflete uma baixa e, aquele, uma alta de preços (CAVALCANTE, 2002).



**Figura 4 – Gráfico de ponto-figura**

Fonte: Weiland (2009, p.1)

### 2.5.7 Gráfico *Candlesticks*

Segundo Pinheiro (2008), este tipo de gráfico é utilizado principalmente para análises de curto prazo. Mostra a interação entre compradores e vendedores. O *candlestick* é representado por uma “vela” formada pelos preços de abertura e fechamento, sendo que, ao final do pregão, se o preço de abertura for menor que o de fechamento, a vela será transparente e, em caso contrário, será escura.

As linhas (pavio) que saem abaixo e acima da vela representam, respectivamente, o preço mínimo e máximo que a ação alcançou durante o pregão. Para o reconhecimento de padrões é necessário uma média exponencial avaliando de três a cinco dias, determinando uma tendência de curto prazo.



**Figura 5 – Gráfico de *candlesticks***

Fonte: Weiland (2009, p.1)

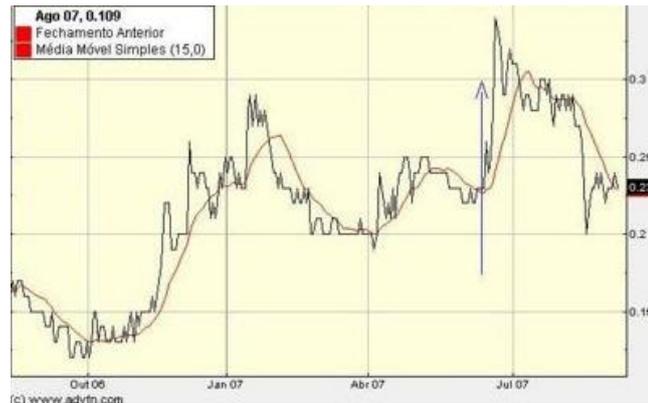
### 2.5.8 Médias Móveis

As médias móveis são um dos indicadores técnicos mais utilizados e versáteis devido a sua simplicidade de construção e objetividade de resultados, possibilitando a análise dos movimentos dos preços de uma ação (BORGES, 2009).

Para a construção de uma média móvel é necessário escolher um determinado período de tempo e fazer uma média dos preços de fechamento nesse tempo. É chamada de móvel pelo fato do cálculo da média ser efetuado com base no último período acompanhado, subtraindo-se da média o primeiro dia e somando-se o atual (PINHEIRO, 2008).

A média móvel suaviza as flutuações dos preços. Um sinal de compra ocorre quando o preço de fechamento cruza a média móvel de baixo para cima e um sinal de venda é dado quando o movimento inverso acontece. A maior dificuldade para a construção das médias está em escolher o número de dias correto para o cálculo da média, de modo que ela seja sensível o suficiente para evitar defasagens, mas não tão sensível que crie excesso de cruzamentos e, conseqüentemente, um número maior de sinais falsos (BORGES, 2009).

De acordo com Pinheiro (2008), existem três tipos de médias: a simples, calculada através da soma das cotações de um período dividido pelo número de dias do mesmo; a ponderada, onde cada cotação usada na média é multiplicada pelo seu dia (primeiro dia por um, segundo por dois, etc.); a exponencial, que prioriza as cotações mais recentes.



**Figura 6 – Gráfico de médias móveis**

Fonte: Weiland (2009, p.1)

## 2.6 Inteligência Artificial

Segundo Dean (1995), Inteligência Artificial é o estudo de programas de computador capazes de comportar-se inteligentemente, baseando-se no que seria considerado como inteligente para um humano ou animal.

De acordo com Haykin (2001), a Inteligência Artificial é baseada no desenvolvimento de algoritmos ou paradigmas, buscando uma maneira de realizar tarefas cognitivas, em que os humanos atualmente são melhores.

Algumas tarefas que podem ser consideradas difíceis para programar, muitas vezes são mais simples do que algumas tarefas que as pessoas podem considerar mais fáceis. Pesquisadores de IA (Inteligência Artificial) têm escrito programas para controle de usinas nucleares e complicados dispositivos eletrônicos. Entretanto provou-se ser mais complicado desenvolver algoritmos para tarefas como reconhecimento de faces, que para nós seriam simples, ainda mais se considerarmos óculos, acessórios e cortes de cabelos diferentes (DEAN, 1995).

Um sistema de IA deve ser capaz de armazenar conhecimento, aplicar este conhecimento armazenado para resolver problemas e adquirir um novo conhecimento através da experiência. Este sistema deve apresentar três componentes fundamentais: representação, raciocínio e aprendizagem (HAYKIN, 2001).

A partir disso, segundo Barreto (2002), pode-se dizer que as redes neurais artificiais seriam uma abordagem para solução de problemas de inteligência artificial. Elas surgiram

motivadas pelo reconhecimento de que o cérebro humano processa informações de forma diferente dos computadores convencionais (HAYKIN, 2001). Por tudo isso, a seguir é feita uma breve fundamentação com relação ao funcionamento das redes neurais biológicas para após, serem descritas as redes neurais artificiais e alguns de seus principais conceitos.

## **2.7 Redes Neurais Biológicas**

Segundo Bear (2002), um dos maiores progressos da neurociência ocorreu quando da publicação do trabalho do histologista italiano Camillo Golgi que, em 1873, descobriu que submergindo uma amostra de tecido nervoso em uma solução de cromato de prata, os neurônios coram-se de preto em toda sua extensão, o que até então não era possível de ser visualizado. Esse método é até hoje chamado de procedimento de Golgi.

O método de Golgi mostra que os neurônios têm pelo menos duas partes distinguíveis: uma região central, onde está o núcleo, chamada de soma, corpo celular ou pericário; e numerosos tubos finos que irradiam dessa região, chamado de neuritos e divididos em dois tipos: axônio e dendritos (BEAR, 2002).

O corpo celular é o centro da célula, capaz de receber os estímulos. A partir dele é originado, normalmente, um único axônio, um prolongamento longo (que pode ter até um metro ou mais), que leva informações de um neurônio a outro. Os dendritos, muito menores (em torno de 2mm), são responsáveis por receber os estímulos de receptores e de outros neurônios (WANDERLEY, 2002).

A partir do procedimento de Golgi, surgiram os estudos de seu contemporâneo, o espanhol Santiago Ramón y Cajal, que aplicou o método de Golgi com mais eficiência, decifrando diversas regiões do encéfalo. Por meio dos estudos de Cajal é que foi estabelecido o conceito de que os neurônios não estão diretamente ligados de forma contínua, que eles se comunicam por algum contato descontínuo, atualmente conhecido como sinapse.

O sistema nervoso é composto de neurônios e células gliais. Os primeiros correspondem a um número ao redor de 100 bilhões, enquanto as outras correspondem a um número 10x maior. Entretanto os neurônios são as células mais importantes para as funções do cérebro (BEAR, 2002).

## 2.8 Redes Neurais Artificiais

Como já citado anteriormente, as redes neurais são uma maneira de construir um sistema que tenha a capacidade de apresentar um comportamento inteligente, aprendendo novas tarefas, fazendo descobertas e, frequentemente, ultrapassando seu professor, tendo a capacidade de se auto-organizar (BARRETO, 2002). São sistemas paralelos distribuídos, compostos por unidades de processamento simples (neurônios artificiais), que calculam funções matemáticas. Os neurônios podem ser dispostos em uma ou mais camadas, interligadas por conexões que possuem pesos e servem para ponderar a entrada recebida por cada neurônio (BRAGA, 2007).

A era atual de redes neurais que presenciamos começou com o trabalho pioneiro de McCulloch e Pitts, que, em 1943, juntaram-se para a realização de um trabalho no qual foi apresentada uma discussão sobre redes lógicas de neurônios artificiais, chamadas de MCP (McCulloch e Pitts), concentrando-se em descrever como seria o modelo do neurônio artificial, mas tratando pouco de apresentar métodos de aprendizado (HAYKIN, 2001).

A questão do aprendizado das RNAs (redes neurais artificiais) veio, anos depois, com os estudos de Donald Hebb, mostrando como a plasticidade da aprendizagem de redes neurais é conseguida através dos pesos de entrada dos neurônios, apresentando uma teoria para explicar o aprendizado em neurônios biológicos, através do reforço das ligações sinápticas entre os neurônios excitados (BRAGA, 2007).

Segundo Haykin (2001), as redes neurais extraem seu poder computacional através de sua estrutura paralelamente distribuída e sua habilidade de aprender e, portanto, de generalizar. A generalização vem do fato da RNA produzir saídas adequadas com base em entradas para as quais ela não foi diretamente treinada, fazendo com que ela possa resolver problemas complexos.

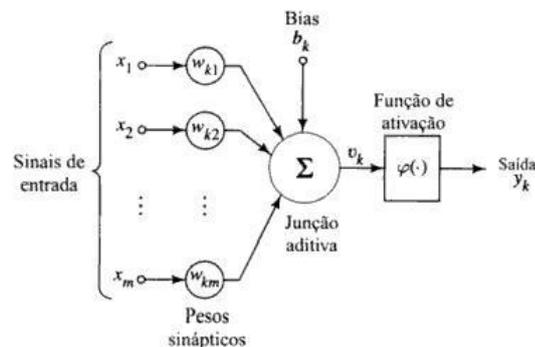
De acordo com Heaton (2009), é importante entender em quais tipos de problemas deve-se buscar uma abordagem baseada em redes neurais. Estas são normalmente úteis para problemas em que não é possível a descrição de uma série de passos para sua solução, como no caso de reconhecimento de padrões, classificação e mineração de dados.

Para Braga (2007), as principais tarefas onde as RNAs podem ser aplicadas são: classificação, atribuindo a um padrão desconhecido uma entre várias classes conhecidas (reconhecimento de caracteres e imagens, diagnóstico médico); categorização, através da descoberta de categorias ou classes nos dados apresentados (mineração de dados,

agrupamento de sequências de DNA); aproximação, pelo mapeamento das funções contínuas das variáveis de entrada; previsão, estimando situações futuras com base nos estados atuais e anteriores do sistema a ser modelado (previsão do tempo e financeira); otimização, buscando uma solução ótima ou mais aceitável (problema do caixeiro viajante).

### 2.8.1 Modelo geral de neurônio

O neurônio é o principal componente necessário para o funcionamento de uma rede neural. Como pode ser visto na Figura 7, o neurônio artificial, inicialmente estabelecido por McCulloch e Pitts, é uma simplificação do que se sabia a respeito do neurônio biológico (BRAGA, 2007).



**Figura 7 - Modelo de neurônio**

Fonte: Haykin (2001,p.36)

De acordo com Haykin (2001), podem ser identificados três elementos básicos que compõem um neurônio: as sinapses, o somador e a função de ativação.

O conjunto de sinapses ou conexões entre neurônios possuem, cada uma, um peso ou força. Como visto na figura acima, diversos sinais entram pelas conexões sinápticas do neurônio  $k$ , sendo multiplicados pelo peso de cada conexão em que entraram.

O somador tem a tarefa de calcular o somatório dos sinais de entrada multiplicados pelos pesos das conexões.

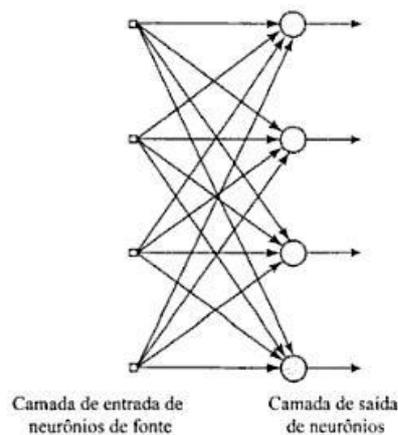
A função de ativação serve para restringir a saída do neurônio, ela limita o intervalo permitido de amplitude de sinal a um valor finito, que normalmente é entre 0 e 1 ou -1 e 1.

Na figura 7 está também incluído o bias, que tem como função aumentar a entrada líquida da função de ativação, se for positivo, ou de diminuir, se for negativo.

### 2.8.2 Redes diretas de camada única

Segundo Haykin (2001), em uma rede neural baseada em camadas os neurônios encontram-se divididos entre estas. A forma mais simples deste tipo de rede é caracterizada por uma camada de entrada que se projeta sobre uma camada de saída de neurônios, sendo, estas redes também conhecidas como alimentadas adiante ou de *feedforward*.

A figura a seguir mostra uma rede com quatro neurônios em cada camada. Apesar de aparecerem duas camadas visualmente, esta rede é chamada de “camada única” pelo fato de ser considerado somente o conjunto de nós computacionais de saída, pois na camada de entrada não é realizada qualquer computação.



**Figura 8 - Rede de camada única**

Fonte: Haykin (2001,p.47)

Dentro das redes de camada única pode ser colocado o *perceptron* de Rosenblatt, proposto em 1958, como primeiro modelo de aprendizagem com professor. Este *perceptron* é a forma mais simples de uma rede neural, consistindo em somente um neurônio com pesos ajustáveis e bias. É utilizado para classificação de padrões linearmente separáveis (HAYKIN, 2001).

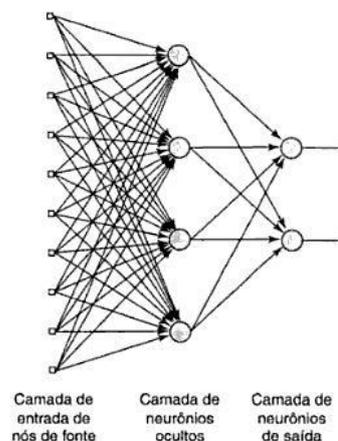
### 2.8.3 Redes diretas de múltiplas camadas

Este segundo modelo de redes neurais, também de *feedforward*, é principalmente caracterizado pela presença de uma ou mais camadas ocultas também chamadas de *hidden layers* (BARRETO, 2002). Essas camadas são formadas por nós computacionais chamados de neurônios ou unidades ocultas, que têm como função intervir de maneira útil entre a camada de entrada e saída, de modo a possibilitar a extração de estatísticas mais complexas, principalmente quando o tamanho dos dados de entrada é grande (HAYKIN, 2001).

Para Braga (2007), o papel das múltiplas camadas em uma rede *feedforward* é de transformar um problema descrito através de um conjunto de dados de entrada em uma representação tratável para a camada de saída.

Estas redes tornaram-se muito populares não só para a solução de diversos tipos de tarefas, como também por existirem métodos de aprendizagem bem difundidos e simples de aplicar. Um dos treinamentos mais conhecidos é o realizado através do algoritmo de retropropagação de erro, também chamado de *backpropagation* (BARRETO, 2002).

Na Figura 9 é possível ver um modelo de rede de múltiplas camadas, onde se tem uma camada de entrada, que fornece o vetor de entrada, que são passados como sinais para a camada oculta, para depois serem passados para a camada de saída.

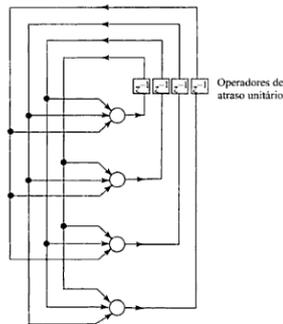


**Figura 9 - Rede de múltiplas camadas**

Fonte: Haykin (2001,p.48)

### 2.8.4 Redes recorrentes

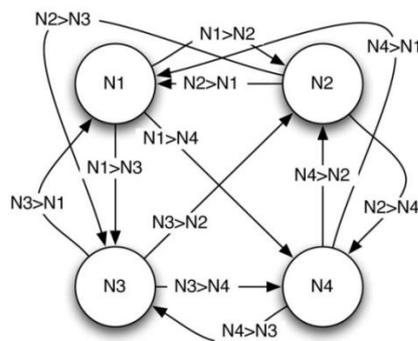
De acordo com Haykin (2001), as redes recorrentes diferenciam-se dos outros dois modelos acima citados (redes diretas) devido ao fato de apresentarem ao menos um laço de realimentação. Estas redes podem até ser constituídas por uma única camada de neurônios, como pode ser visto na Figura 10, em que o próprio sinal de saída é usado para realimentar a entrada dos neurônios. A presença desses laços de realimentação tem um impacto profundo na capacidade de aprendizado da rede e no seu desempenho.



**Figura 10 - Rede recorrente de camada única**

Fonte: Haykin (2001,p.48)

Um dos exemplos de redes recorrentes mais conhecidos é a de Hopfield. Para Heaton (2009), este é um dos tipos mais simples de redes neurais. É uma rede de camada única totalmente conectada (cada neurônio conectado a todos os outros) e auto-associativa, que significa que se a rede reconhece um padrão, ela irá retorná-lo.



**Figura 11 - Modelo de rede de Hopfield**

Fonte: Heaton (2009,p.84)

### 2.8.5 Aprendizagem supervisionada

O aprendizado supervisionado implica na existência de um supervisor, chamado também de professor, que indica o comportamento certo ou errado, sendo responsável por passar os padrões de entrada da rede e observar a saída, comparando a resultado obtido com o que seria o valor desejado para saída. A partir disso, os pesos entre neurônios devem ser ajustados de forma incremental, com pequenos ajustes, para que a saída da rede chegue o mais próximo possível do desejado (BARRETO, 2002).

Segundo Braga (2007), o aprendizado supervisionado pode ser aplicado, principalmente, em problemas em que se deseja obter um mapeamento entre padrões de entrada e saída. Os exemplos de algoritmos mais conhecidos para isso são a regra delta e sua generalização para redes de múltiplas camadas, o já citado, algoritmo de *backpropagation*.

Este tipo de aprendizado pode ser implementado de duas formas: *off-line* e *on-line*. O primeiro método usa um conjunto de dados para treinamento fixo. O segundo trabalha com dados que são atualizados constantemente, fazendo com que a rede fique em contínuo processo de adaptação.

### 2.8.6 Aprendizagem não supervisionada

Conforme Barreto (2002), neste tipo de aprendizagem não há a figura do professor para acompanhar o processo. Nesse tipo de treinamento somente os padrões de entrada estão disponíveis para a rede, ao contrário do método supervisionado onde tem-se a entrada e a saída esperada disponíveis.

Durante a aprendizagem, os padrões de entrada são apresentados continuamente à rede e a existência de regularidades nesses dados faz com que o aprendizado seja possível.

O aprendizado sem professor é aplicado para problemas que visam a descoberta de características estatisticamente relevantes em um conjunto de dados, sendo tipicamente utilizado para o treinamento de redes neurais para classificação. É usado também para mineração de dados, quando existe uma grande quantidade de dados para serem pesquisados mas não se sabe exatamente o que procurar. Esta técnica de treinamento também é muito utilizada para mapas auto-organizados (HEATON, 2009).

### 2.8.7 Algoritmo de retropropagação

Segundo Haykin (2001), este algoritmo é um dos mais utilizados e conhecidos. A aprendizagem por retropropagação de erro consiste de dois passos: um para frente, chamado de propagação, e outro para trás, chamado de retropropagação. No primeiro passo, o vetor de entrada é aplicado e seu efeito se propaga pelas camadas, gerando um conjunto de saídas. No segundo passo, é feito um cálculo de correção de erro, subtraindo-se a resposta real da rede pela resposta desejada e então os pesos sinápticos são ajustados de acordo com o resultado deste cálculo, com objetivo de diminuir erro, aproximando, cada vez mais, a resposta real da resposta desejada.

O algoritmo de retropropagação ficou popularizado em 1986. O seu desenvolvimento representa um marco nas redes neurais pelo fornecimento de um método eficiente para o treinamento das redes de múltiplas camadas (HAYKIN, 2001).

## 2.9 Tecnologias

Para o desenvolvimento do algoritmo foi utilizada a linguagem Java. Esta tecnologia começou a ser desenvolvida em 1991 com o nome de Green Project. Porém, é em 1995 que a linguagem Java é oficialmente lançada. É uma linguagem multiplataforma, sendo, atualmente, uma das mais utilizadas e servindo para qualquer tipo de aplicação, entre elas: web, desktop, servidores, mainframes, jogos, aplicações móveis, chips de identificação, etc (JAVAFREE.ORG, 2009).

## 2.10 Softwares e trabalhos similares

Com relação aos softwares similares, considerando os que trabalham somente com análise técnica/ gráfica, existem diversos, muitos deles disponíveis para uso diretamente via internet, como as aplicações fornecidas por muitos bancos aos seus clientes. Um exemplo de aplicação web grátis, que fornece análise de 500 diferentes ações, é a encontrada no site Sfera

Stock Analysis (SBRUZZI, 2009), no qual é gerada uma breve análise apresentando valores atuais e tendência para a ação selecionada.

Existem também diversos *softwares* em formato *desktop*, podendo-se citar o DesktopTrader, fornecido pela investBolsa (Figura 12) e também, o Trader Data (Figura 13).



Figura 12 - Desktop trader

Fonte: INVESTBOLSA (2009,p.1)



**Figura 13 - Trader data**

Fonte: TRADER DATA (2009,p.1)

Com relação a pesquisas similares, há diversos trabalhos que podem ser encontrados na área de redes neurais para previsão de mercado de ações. Alguns que trabalham para prever índices específicos com o Ibovespa e o Dow Jones. Outros que trabalham com a previsão dos preços das ações do mercado.

Nesta área existem estudos fora do país há bastante tempo, como o de Kimoto; Asakawa (1990), que usa mais de uma rede neural para estabelecer relações com o objetivo de maximizar a escolha dos momentos de compra e venda dos papéis.

Atualmente, são encontrados diversos trabalhos no Brasil, para a previsão de índices ou preços de ações, todavia, trabalham com a previsão e não com o objetivo de melhorar a análise técnica.

### 3 SIMULAÇÕES COM JOONE

JOONE (*Java Object Oriented Neural Engine*) é um *framework* Java feito para construção e execução de aplicações de inteligência artificial baseadas em redes neurais. O JOONE consiste em uma arquitetura modular baseada em componentes que podem ser ligados entre si (referência).

Inicialmente, foi escolhida a simulação das redes neurais utilizando o JOONE ao invés de a programação direta da rede neural como uma forma de estudo inicial, o que contribuiu para entender melhor o funcionamento desta técnica de IA. Através do JOONE é possível analisar quais os tipos de funções de ativação e quais os parâmetros necessários para a execução, permitindo, em geral, uma visualização mais prática da teoria estudada.

Posteriormente, as simulações foram utilizadas para avaliar as opções de redes e seu desempenho, de acordo com as ideias criadas para a solução do problema. A partir disso foi desenvolvida a RNA, baseando-se na estrutura utilizada nas simulações, de modo a analisar o desempenho das simulações em comparação à rede programada.

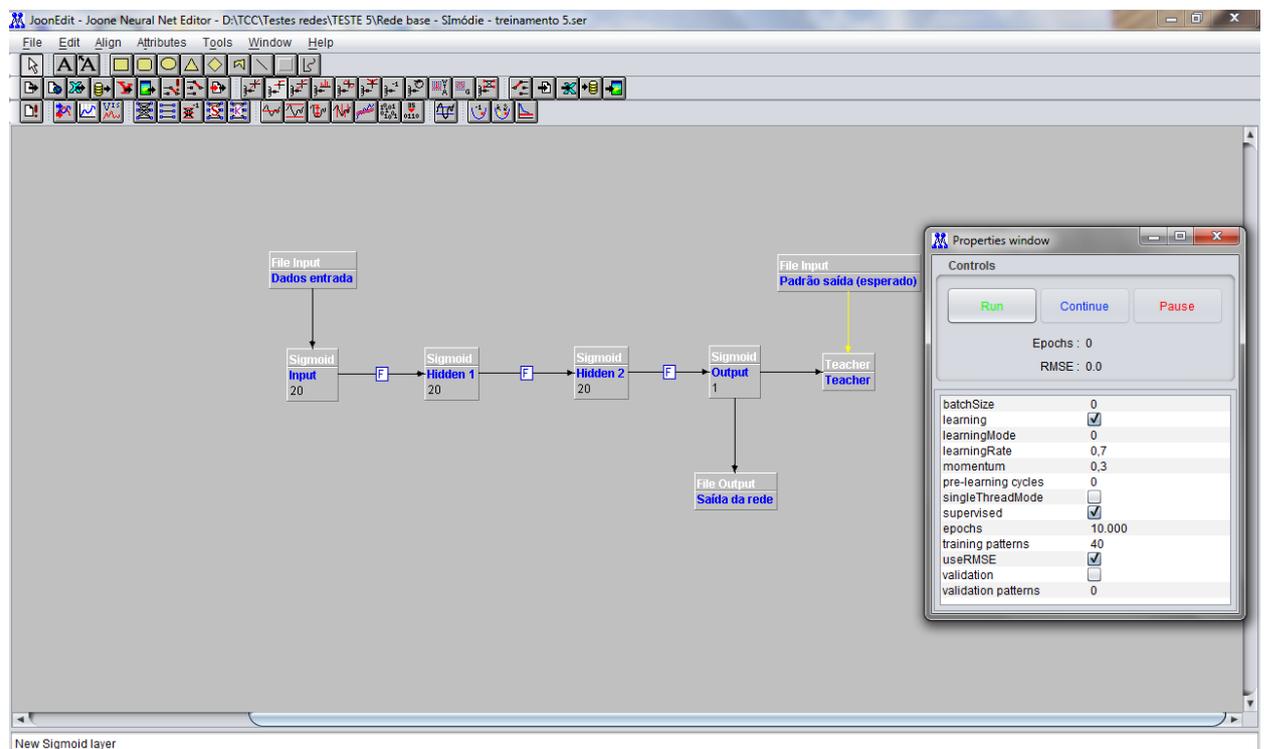


Figura 14 – Screenshot do programa JOONE mostrando uma rede com função sigmoide

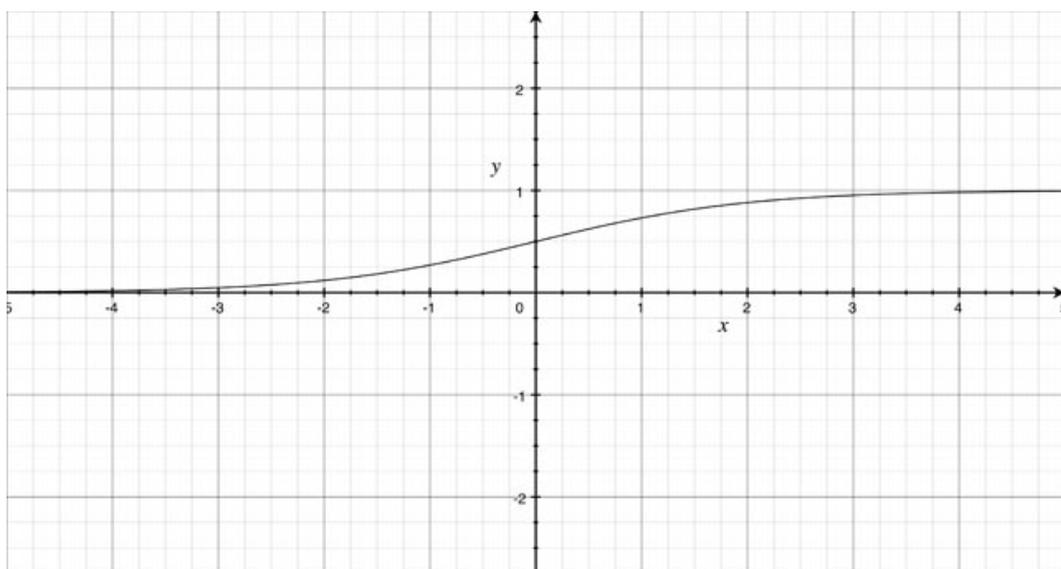
Na Figura 14 mostra-se uma imagem do ambiente de simulação oferecido pelo JOONE, em que se pode perceber as diversas opções de camadas/ funções de ativação possíveis de serem utilizadas (sigmoide, tangente hiperbólica, linear, seno).

Os dados utilizados foram obtidos a partir dos valores de fechamento das ações da USIMINAS. Para o treinamento inicial das redes foram utilizados dados de 4 meses, de janeiro a abril de 2009. Assim, foram gerados 77 padrões de treinamento e para cada padrão utilizou-se uma série de 30 valores, correspondendo ao que seria o dia atual, juntamente com os 29 dias anteriores (padrão de entrada = dia atual + 29 dias anteriores). Não foi utilizado um conjunto maior de dados devido ao excesso de trabalho gerado para adaptar o formato dos dados existentes ao formato utilizado pelo JOONE.

O objetivo inicial foi utilizar uma rede de *feedforward* com algoritmo de aprendizado por retropropagação ou *backpropagation*, utilizando também uma função de ativação sigmoide. Essa escolha foi baseada em testes iniciais utilizados como aprendizado para entender o funcionamento do JOONE e RNAs, nos quais este tipo de função de ativação apresentou boa aproximação ao resultado esperado.

Segundo Heaton (2008), a função sigmoide é uma das funções de ativação mais utilizadas para redes de *feedforward*, sendo representada pela equação 1:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (1)$$



**Figura 15 – Gráfico função sigmoide.**

Fonte: Heaton (2008, p.152).

É importante notar que essa função retorna somente valores positivos entre 0 e 1. O termo sigmoide se refere à curva em duas direções, como a letra “S”. Isso pode ser percebido na figura 15.

Como método de treinamento inicial foram pegos todos os dias, mesmo os que não representam pontos de compra ou venda. Como saídas esperadas da rede para treinamento supervisionado, foram estabelecidos os seguintes valores:

COMPRA	VENDA	SEM TRANSAÇÃO
1.0	0.0	0.5

**Tabela 2 – Padrão de saída - primeira simulação**

Para cada padrão de treinamento foi atribuído como resposta desejada um dos valores acima representados, seguindo a análise feita de quais seriam os melhores momentos de compra e venda para o melhor ganho possível.

Para o treinamento com *backpropagation* podem ser estabelecidos dois parâmetros: o *learning rate*, que especifica com qual velocidade a rede irá aprender e é estabelecido entre 0 e 1, sendo que este valor representa um percentual; e o *momentum* especifica o quanto a iteração de treinamento anterior afetará a iteração atual, também representado por um valor em 0 e 1.

No primeiro teste, utilizando um *learning rate* de 0,7 e um *momentum* de 0,5, obteve-se um erro médio de 0,2968. Para esse primeiro teste a rede funcionou tecnicamente, todavia os resultados não foram bons. Isso já era esperado devido à taxa de erro que, para este tipo de rede, é considerada alta. Testando a rede com os mesmo padrões de treinamento, obteve-se valores muito próximos, ou seja, não foi possível fazer com que a rede reconheça diferente padrões.

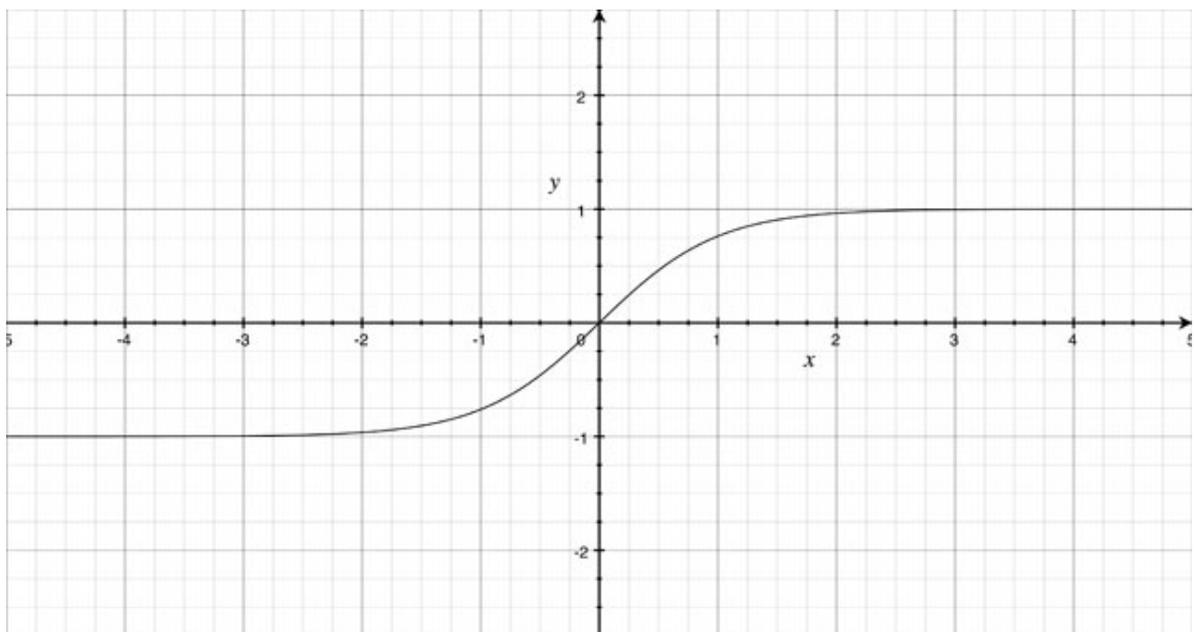
Após este teste inicial foram realizados diversos outros testes utilizando a função de ativação sigmoide. Foram testados vários tamanhos de dados de entrada e quantidade de padrões de treinamento, e conseqüentemente, quantidades de neurônios, tanto na camada de entrada como nas camadas ocultas. Outras tentativas de diminuir o erro apresentado e melhorar o desempenho da rede foram feitas alterando o *learning rate* e o *momentum* com diversos valores entre 0 e 1, como também treinamento até 100.000 épocas. No entanto, não foi possível diminuir o erro abaixo de 0,2858, e, ainda, continuou-se com a baixa variação do resultado obtido na saída da rede, independente do conjunto de dias apresentados para teste.

Um segundo conjunto de testes foi desenvolvido utilizando o mesmo modelo de rede, porém com uma função de ativação diferente, a tangente hiperbólica, e, conseqüentemente, um treinamento e uma interpretação dos dados de saída da rede diferentes.

De acordo com Heaton (2008), a função tangente hiperbólica funcionaria como se movêssemos a função sigmoide para uma região do gráfico de modo a permitir que ela retorne números negativos. Essa função é representada pela seguinte equação 2:

$$f(x) = \frac{e^{2x} - 1}{e^{2x} + 1} \quad (2)$$

Apesar de parecer mais complexa, basicamente, a tangente hiperbólica seria uma função sigmoide positiva e negativa, podendo, assim, retornar números entre -1 e 1, como pode ser visto na figura abaixo.



**Figura 16 – Gráfico função tangente hiperbólica**

Fonte: Heaton (2008, p.154)

Para o treinamento com a função de ativação tangente hiperbólica foram modificados os dados de saída esperados para o treinamento supervisionado de modo a trabalhar com valores entre -1 e 1, sendo possível, assim, tentar detectar padrões tanto para momentos de compra, como para momentos de venda de ações. Foram utilizados os seguintes valores:

COMPRA	VENDA	SEM TRANSAÇÃO
-1.0	1.0	0.0

**Tabela 2 – Padrão de saída - segunda simulação**

Utilizando este tipo de rede no JOONE, também não foi possível conseguir uma boa saída de dados que fosse passível de interpretação.

## 4 ALGORITMOS BASEADOS EM RNAs

Para a realização deste trabalho a rede neural foi trabalhada de três maneiras diferentes, uma para previsão e duas para detecção de momentos de compra e venda.

### 4.1 Rede baseada em previsão de crescimento

De acordo com os estudos realizados e simulações feitas, optou-se por continuar utilizando uma rede de *feedforward*, pois esta é citada pela literatura como uma boa forma de detectar padrões e é muito utilizada para o mercado financeiro. É usada principalmente para detectar padrões baseados em um histórico das ações, tentando aprender com o passado para que seja possível “prever” o futuro.

Apesar de não ser o objetivo direto do trabalho, inicialmente desenvolveu-se uma rede voltada para a previsão para futuras comparações. Trabalhou-se com os dados das ações da USIMINAS, mesma empresa utilizada nas simulações.

Abaixo, transcreve-se um trecho do arquivo em formato CSV, que foi utilizado como base para a criação dos padrões de entrada e saída da rede neural, de modo a facilitar o entendimento dos dados utilizados para trabalhar com a rede. Na coluna “Ação”, um momento de compra é representado por “C”, um momento de venda por “V” e quando não há transação atribuiu-se o valor 0.

Data	Volume	Fechamento	Ação
24/04/2009	1000	31.20	V
23/04/2009	1000	31.20	0
22/04/2009	1000	30.58	0
20/04/2009	1000	30.00	C
17/04/2009	1000	31.40	V
16/04/2009	1000	30.12	0
15/04/2009	1000	28.33	C
14/04/2009	1000	28.34	0
13/04/2009	1000	28.81	0
09/04/2009	1000	29.00	V
08/04/2009	1000	28.38	0

Tabela 3 – Valores de entrada

Para esta primeira rede foram utilizadas as colunas de data e fechamento. Os padrões de treinamento foram estabelecidos de acordo com uma data de início passada como parâmetro para a criação dos padrões, juntamente com o número de padrões de treinamento.

Como função de ativação para a rede, foi escolhida a tangente hiperbólica, pelo fato desta trabalhar com valores positivos e negativos. Para entrada e saída de dados, como a função necessita valores entre -1 e 1, trabalhou-se com a porcentagem de crescimento das ações. O cálculo foi feito utilizando a relação entre o valor atual da ação (fechamento do dia) e o valor do dia anterior.

Como exemplo, utilizando os primeiros 10 valores do arquivo acima, ter-se-iam os seguintes valores:

09/04/2009: Valor atual=29.00, % Mudança=2,18%  
 13/04/2009: Valor atual=28.81, % Mudança=-0,66%  
 14/04/2009: Valor atual=28.34, % Mudança=-1,63%,  
 15/04/2009: Valor atual=28.33, % Mudança=-0,04%,  
 16/04/2009: Valor atual=30.12, % Mudança=6,32%,  
 17/04/2009: Valor atual=31.40, % Mudança=4,25%,  
 20/04/2009: Valor atual=30.00, % Mudança=-4,46%,  
 22/04/2009: Valor atual=30.58, % Mudança=1,93%,  
 23/04/2009: Valor atual=31.20, % Mudança=2,03%,  
 24/04/2009: Valor atual=31.20, % Mudança=0,00%,

Cada padrão de entrada para treinamento ou teste da rede é constituído por um conjunto das porcentagens de crescimento, só que utilizando números entre -1 e 1 (6,32% = 0,0632). Para a saída da rede, foi colocado como valor esperado o dia posterior ao dia atual, tentando, dessa forma, prever o próximo crescimento, e conseqüentemente, o próximo valor da ação. No caso do dia 22/04/2009, por exemplo, o valor esperado para saída seria 2,03%.

Para o treinamento da rede, optou-se por utilizar um método híbrido aplicando, além do *backpropagation* tradicional para redes de *feedforward*, um método chamado de *simulated annealing*, citado por Heaton (2008), como uma boa forma de diminuição do erro das redes e que se mostrou eficiente em diversos casos.

O objetivo buscado ao usar o *simulated annealing* é evitar um problema de mínima local, que tende a ocorrer com o algoritmo de *backpropagation*. Deve-se treinar a rede até

chegar a um erro mínimo global, porém o algoritmo de retropropagação poder confundir o mínimo local com o global.

Dado um específico número de entradas para uma função, o algoritmo de *simulated annealing* trabalha para determinar quais delas produzirão o resultado mínimo. Com relação às redes neurais, os pesos entre neurônios servem como um ótimo padrão de dados, em que diferentes conjuntos de pesos são utilizados até que seja encontrado um retorno menor da função de cálculo de erro (HEATON, 2008).

Assim, foram utilizados para treinamento da rede os dois métodos alternados. O *simulated annealing* era utilizado em cinco iterações de treino a cada 100 execuções de *backpropagation*, e somente era executado quando este algoritmo apresentava baixa eficiência (diminuição de erro) a cada iteração.

Segundo o que pode ser visto no trecho de treinamento abaixo, em algumas das execuções, o *simulated annealing* apresentou uma diminuição considerável do erro ao ser utilizado. Uma melhor eficiência do algoritmo foi percebida quanto maior era o erro que a rede apresentava, pois com a diminuição deste, as iterações de *simulated annealing* passaram a surtir pouco efeito.

```

Iteração(Backprop) #717 Erro:0.13090671150445837
Iteração(Backprop) #718 Erro:0.1307940412557057
Iteração(Backprop) #719 Erro:0.13068338784748249
Iteração(Backprop) #720 Erro:0.1305747164505722
Iteração(Backprop) #721 Erro:0.13046799277570403
Iteração(Backprop) #722 Erro:0.1303631830673008
Iteração(Backprop) #723 Erro:0.13026025409722558
Iteração(Backprop) #724 Erro:0.13015917315852907
Iteração(Backprop) #725 Erro:0.13005990805920276
Treinando com simulated annealing por 5 iterações
Iteração(Anneal) #1 Erro:0.10851143899949
Iteração(Anneal) #2 Erro:0.10851143899949
Iteração(Anneal) #3 Erro:0.1006807445785134
Iteração(Anneal) #4 Erro:0.1006807445785134
Iteração(Anneal) #5 Erro:0.09447603566334596
Iteração(Backprop) #726 Erro:0.09446378114719774
Iteração(Backprop) #727 Erro:0.09445368518026186

```

Após diferentes testes variando o *learning rate*, *momentum*, o tamanho do treinamento entre 50 e 100 padrões, a camada de entrada e interna entre 10 e 30 neurônios e o número de camadas internas entre 1 e 2, obteve-se uma melhor relação de desempenho com um padrão de entrada de 10 valores, uma camada interna de 10 neurônios, um conjunto de treinamento de 50 dias, *learning rate* de 0,0001 e *momentum* de 0,1.

A rede foi treinada até obter um erro máximo abaixo de 0,04, o que representaria 4% de erro, em média, para a previsão. Como pode ser visto nas iterações abaixo, foram necessárias 108619 iterações de *backpropagation*, correspondendo a um tempo de treinamento de 53 minutos.

Iteração(Backprop) #108612 Erro:0.04000040126795013  
 Iteração(Backprop) #108613 Erro:0.04000033472499303  
 Iteração(Backprop) #108614 Erro:0.04000026818273487  
 Iteração(Backprop) #108615 Erro:0.040000201641175626  
 Iteração(Backprop) #108616 Erro:0.0400001351003153  
 Iteração(Backprop) #108617 Erro:0.04000006856015386  
 Iteração(Backprop) #108618 Erro:0.04000000202069127  
 Iteração(Backprop) #108619 Erro:0.03999993548192757

A rede foi treinada com base em dados de 2008 e testada com dados de 2009, apresentando uma diferença entre a saída esperada e a saída prevista em torno de 5%, como é possível perceber no conjunto de saídas abaixo, extraídas de parte do teste executado.

13/04/2009: Valor atual=28.81, Mudança esperada=-0,66%, Previsão de mudança= -2,47%:Diferença=1,81%

14/04/2009: Valor atual=28.34, Mudança esperada=-1,63%, Previsão de mudança= -7,06%:Diferença=5,43%

15/04/2009: Valor atual=28.33, Mudança esperada=-0,04%, Previsão de mudança= -5,03%:Diferença=5,00%

16/04/2009: Valor atual=30.12, Mudança esperada=6,32%, Previsão de mudança= -3,09%:Diferença=9,41%

17/04/2009: Valor atual=31.4, Mudança esperada=4,25%, Previsão de mudança= 0,55%:Diferença=3,70%

20/04/2009: Valor atual=30.0, Mudança esperada=-4,46%, Previsão de mudança= -3,41%:Diferença=1,05%

Com base nos dados acima é interessante notar que, em algumas saídas da rede, a diferença entre o crescimento esperado e o previsto é consideravelmente baixa, chegando a 1,05%.

## 4.2 Redes para compra e venda

Tomando como ponto de partida a rede programada para previsão, procurou-se desenvolver uma rede que, ao invés de prever o próximo valor, pudesse detectar padrões e classificá-los de um modo que fosse possível interpretar momentos de compra e venda de ações, baseando-se no dia atual juntamente com um conjunto de valores representando os dias anteriores.

Primeiramente, optou-se por trabalhar com o mesmo modelo de dados utilizado para a rede de previsão, ou seja, para a formação dos padrões de entrada, foram utilizadas as porcentagens de crescimento em relação ao dia anterior.

A estrutura da rede utilizada (função de ativação, algoritmos de treinamento) foi a mesma aplicada para previsão, todavia foi alterado o padrão de saída esperado, procurando treinar a rede para uma interpretação diferente dos dados. Baseando-se no resultado ótimo de ganho, utilizou-se o seguinte padrão de resposta da rede:

COMPRA	VENDA	SEM TRANSAÇÃO
-1.0	1.0	0.0

**Tabela 4 - Padrão de saída - RNA**

Utilizando a mesma estrutura e o mesmo padrão para resposta da rede, porém trabalhando de maneira um pouco mais simples, ainda foi desenvolvida uma terceira rede somente com o valor das ações dividido por 100, de modo a ficar entre 0 e 1.

Apesar de ter sido interessante como uma nova tentativa para comparação, este modelo não obteve resultados satisfatórios, quando comparados à primeira rede implementada para compra a venda. Por isso, a análise será feita nos dados obtidos através dos testes utilizando os padrões de crescimento como entrada, e não os valores “puros” das ações.

Para este modelo, no treinamento em que se obteve o melhor resultado foi utilizado 50 padrões com 20 números e, conseqüentemente, 20 neurônios de entrada. Foi utilizada, ainda, uma camada interna também com 20 neurônios.

O menor erro que se conseguiu obter dentro de um prazo de tempo aceitável foi de 0,4, o que representaria 40%. Este valor foi obtido após 61438 iterações durante um tempo de 51 minutos, como pode ser visto no trecho extraído abaixo.

```

Iteração(Backprop) #61428 Erro:0.40000896682790105
Iteração(Backprop) #61429 Erro:0.40000806455757304
Iteração(Backprop) #61430 Erro:0.4000071622905948
Iteração(Backprop) #61431 Erro:0.4000062600269662
Iteração(Backprop) #61432 Erro:0.4000053577666873
Iteração(Backprop) #61433 Erro:0.40000445550975877
Iteração(Backprop) #61434 Erro:0.4000035532561801
Iteração(Backprop) #61435 Erro:0.4000026510059517
Iteração(Backprop) #61436 Erro:0.40000174875907357
Iteração(Backprop) #61437 Erro:0.4000008465155458
Iteração(Backprop) #61438 Erro:0.39999994427536867

```

Comparando esse treinamento com a rede baseada em previsão, nota-se que praticamente no mesmo tempo, o número de iterações foi bem menor na primeira rede. Isso ocorre pois nesse caso utilizou-se um número maior de iterações com *simulated annealing* devido ao fato do *backpropagation* não conseguir grande eficiência em diminuir o erro.

A seguir mostra-se um exemplo da saída obtida ao executar a rede para compra e venda. Pode-se notar que, ao invés da saída esperada ser a próxima porcentagem de crescimento, o valor é 0, 1 ou -1.

07/05/2008: Valor ação=83.99, Resultado esperado=-1.0, Previsão= -0.7825183224034552: Diferença=21,75%

08/05/2008: Valor ação=86.8, Resultado esperado=0.0, Previsão= 0.2525283629919276: Diferença=25,25%

09/05/2008: Valor ação=88.0, Resultado esperado=0.0, Previsão= 0.08805085603737932: Diferença=8,81%

12/05/2008: Valor ação=88.79, Resultado esperado=0.0, Previsão= 0.09186445677388547: Diferença=9,19%

13/05/2008: Valor ação=89.6, Resultado esperado=1.0, Previsão= 0.2773925069634486: Diferença=72,26%

14/05/2008: Valor ação=89.05, Resultado esperado=-1.0, Previsão= -0.4510456486725125: Diferença=54,90%

15/05/2008: Valor ação=91.15, Resultado esperado=0.0, Previsão= -0.0380751582360218: Diferença=3,81%

16/05/2008: Valor ação=95.11, Resultado esperado=0.0, Previsão= 0.0871728952689561: Diferença=8,72%

19/05/2008: Valor ação=96.69, Resultado esperado=1.0, Previsão= 0.2473941038872171: Diferença=75,26%

20/05/2008: Valor ação=93.41, Resultado esperado=0.0, Previsão= -0.02117308886840828: Diferença=2,12%

21/05/2008: Valor ação=88.85, Resultado esperado=-1.0, Previsão= -0.4972201333751489: Diferença=50,28%

23/05/2008: Valor ação=89.2, Resultado esperado=0.0, Previsão= -0.025534740015797284: Diferença=2,55%

26/05/2008: Valor ação=89.5, Resultado esperado=1.0, Previsão= 0.6874610209664525: Diferença=31,25%

27/05/2008: Valor ação=87.05, Resultado esperado=-1.0, Previsão= -0.5419070562638443: Diferença=45,81%

28/05/2008: Valor ação=91.8, Resultado esperado=1.0, Previsão= 0.9912979739959837: Diferença=0,87%

29/05/2008: Valor ação=88.75, Resultado esperado=0.0, Previsão= 0.05802221555819012: Diferença=5,80%

Você ganhou: 19030.0 Compras:7 Vendas: 7

Para esta rede foi implementada uma função permitindo avaliar o ganho de acordo com os momentos de compra e venda de ações indicados nas saídas processadas e também o número de transações realizadas.

Foram realizados diversos testes variando a interpretação do que seria um bom momento de compra e venda. Baseando-se no fato de que a saída esperada para venda seria 1 e para compra -1, os testes foram feitos considerando momentos de compra com valores abaixo de -0,5 até -0,95 e momentos de venda acima de 0,5 até 0,95.

a) Primeira simulação: utilizando 50 padrões de entrada (50 dias ou 2,5 meses), sendo estes os mesmos usados para o treinamento - resultado ótimo = R\$ 26.490,00.

Parâmetro	Ganho Total	Número de transações
0,50	R\$ 2.860,00	14
0,55	R\$ 7.820,00	12
0,60	-R\$ 3.980,00	10
0,65	-R\$ 14.930,00	6
0,70	-R\$ 6.330,00	6
0,75	-R\$ 6.330,00	6
0,80	-R\$ 6.040,00	6
0,85	-R\$ 6.870,00	6
0,90	-R\$ 4.270,00	6
0,95	-R\$ 12.500,00	2

**Tabela 1 - Dados a partir de 11/06/08**

b) Segunda simulação: utilizando 50 padrões de entrada (50 dias ou 2,5 meses), utilizando dados a partir de 14/03/2008 - resultado ótimo = R\$ 53.870,00.

Parâmetro	Ganho Total	Número de transações
0,50	R\$ 19.030,00	14
0,55	R\$ 13.690,00	12
0,60	R\$ 14.530,00	12
0,65	R\$ 15.690,00	10
0,70	R\$ 17.490,00	10
0,75	R\$ 14.620,00	8
0,80	R\$ 7.210,00	4
0,85	R\$ 15.000,00	2
0,90	R\$ 0,00	0
0,95	R\$ 0,00	0

**Tabela 2 - Dados a partir de 14/03/2008**

c) Terceira simulação: utilizando 50 padrões de entrada (50 dias ou 2,5 meses), utilizando dados a partir de 10/02/2009 – resultado ótimo = R\$ 21.110,00.

Parâmetro	Ganho Total	Número de transações
0,50	-R\$ 5.510,00	18
0,55	-R\$ 5.510,00	18
0,60	-R\$ 5.740,00	16
0,65	-R\$ 840,00	12
0,70	R\$ 1.420,00	8
0,75	R\$ 800,00	8
0,80	R\$ 630,00	8
0,85	R\$ 3.680,00	6
0,90	-R\$ 1.450,00	4
0,95	-R\$ 790,00	2

**Tabela 3 - Dados a partir de 10/02/2009**

Com relação a essas simulações percebe-se que a rede consegue, em parte, reconhecer alguns padrões.

No primeiro conjunto de testes obteve-se um lucro total maior com o parâmetro 0,55, possivelmente pelo maior número de transações e pelo teste ser o mesmo do treinamento.

Apesar de o valor ficar longe do melhor resultado, conseguiu-se obter um valor considerável. É interessante notar que com o mesmo número de transações obteve-se um ganho total bem diferente, somente pela variação do parâmetro passado, principalmente com relação ao 0,65.

Com relação à segunda simulação, percebe-se que, em geral, quanto menor o número de transações, menor tende a ser o ganho total, principalmente neste caso em que o período teve uma leve tendência de alta.

Neste segundo caso, a rede seguiu uma tendência de aumentar o número de transações, percebendo-se aí um padrão correto, seguindo os dados analisados como ótimos, onde nesse período o número de transações total foi maior que no primeiro período testado.

Em relação ao último caso, não é muito perceptível um padrão específico, porém ainda assim conseguiu-se lucro em alguns dos casos, mesmo com as ações seguindo uma tendência de baixa.

## 5 CONCLUSÃO

Este trabalho foi iniciado com base na hipótese de que o mercado de ações segue determinados padrões ao longo do tempo e que estes são passíveis de detecção utilizando técnicas de Inteligência Artificial, mais especificamente, Redes Neurais Artificiais. Para o caso deste trabalho, os padrões a serem detectados seriam momentos de compra a venda de ações.

Para isso foi desenvolvida a rede neural, que tinha como objetivo detectar esses padrões com base em um histórico do valor das ações, funcionando de uma maneira como se, ao receber um padrão, a rede pudesse gerar como saída: “agora compra” ou “agora vende”.

Diversos testes foram realizados até chegar a uma boa relação entre número de padrões de treinamento e o coeficiente de erro mínimo obtido ao treinar a rede. Para comparação, foi implementada a rede neural para previsão, que é a maneira abordada na maioria dos estudos para mercado financeiro.

Comparando os resultados entre as duas redes, percebe-se que a de previsão obteve um resultado melhor ao compararmos a diferença entre a resposta correta e a resposta prevista. Todavia, deve-se levar em conta que para este tipo de rede ser usada para análise de compra e venda, seria necessário utilizar um método de realimentação e uma previsão de mais dias, o que geraria uma diferença maior entre correto e previsto, e, ainda, seriam necessários cálculos matemáticos para determinar qual transação realizar.

A rede para compra e venda tinha como objetivo trabalhar com uma abordagem diferente, no entanto notou-se, através dos resultados, uma maior dificuldade de adaptação, visto que, para a previsão, a variação da resposta da rede em relação aos valores de entrada apresentados é menor. Já para a rede de detecção de compra e venda, da maneira como foram colocadas as saídas esperadas, a mudança de apenas um valor em um padrão de 10 ou 20 números, muda totalmente a resposta esperada, transformando, por exemplo, uma compra (resposta -1) em uma venda (resposta 1), e, ainda, na maioria dos casos, este único número modificado não sofre uma grande variação em relação ao anterior.

Apesar desta maior dificuldade de adaptação, foi possível perceber que em alguns casos a rede conseguiu detectar determinados padrões e acompanhar algumas tendências. Isso fica melhor representado principalmente com o teste utilizando um período onde os valores das ações seguiam uma tendência de alta.

Sendo assim, conclui-se que o mercado de ações apresenta padrões detectáveis, mas é muito difícil chegar ao que seria o resultado ótimo devido à grande flutuação dos valores das ações, que sofrem influência de diversos fatores ao redor do mundo. Por tudo isso, o trabalho realizado foi interessante como estudo, ao buscar uma nova alternativa para a análise técnica de ações, ainda que não tenha conseguido gerar resultados suficientemente bons a ponto de serem usados para análise de investimento real.

Os estudos feitos do mercado de ações e, principalmente, das redes neurais para a realização deste trabalho, foram muito proveitosos em termos de conhecimento obtido, agregando valor para formação pessoal e acadêmica.

Para trabalhos futuros, poder-se-ia tentar utilizar alguma estrutura de rede diferente e trabalhar com outros métodos de aprendizagem, de modo a encontrar uma melhor adaptação ao mercado de ações e padrões de compra e venda.

## REFERÊNCIAS

BARRETO, Jorge M. **Introdução às Redes Neurais Artificiais**. Florianópolis: UFSC, 2002.

BESSASA, Octavio. **O mercado de derivativos financeiros**. 2. ed. Rio de Janeiro: Record, 2003.

BM&FBOVESPA. **História**. Disponível em:  
<http://www.bmfbovespa.com.br/portugues/historia.asp>. Acesso em: 3 de nov. 2009

BOVESPA. **Mercado de Capitais**: introdução. Junho de 2008. Disponível em:  
<http://www.bovespa.com.br/Pdf/merccap.pdf>. Acesso em 23: de out. 2009.

BRAGA, Antônio de P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais**: Teoria e Aplicações. 2. ed. Rio de Janeiro: LTC, 2007.

DEAN, Thomas; ALLEN, James; ALOIMONOS, Yiannis. **Artificial Inligence: theory and practice**. California: Addison-Wesley, 1995.

EIZIRIK, Nelson; GAAL, Ariana B.; PARENTE, Flávia; HENRIQUES, Marcus de Freitas. **Mercado de Capitais**: regime jurídico. Rio de Janeiro: Renovar, 2008.

FORTUNA, Eduardo. **Mercado financeiro**: produtos e serviços. 16. ed. Rio de Janeiro: Qualitymark, 2005.

GALVÃO, Alexandre et al. **Mercado Financeiro**: uma abordagem prática dos principais produtos e serviços. Rio de Janeiro: Elsevier, 2006.

HAYKIN, Simon. **Redes Neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001.

HEATON, Jeff. **Introduction for Neural Networks to JAVA**. 2. ed. St. Louis: Heaton Research, 2008.

INVESTBOLSA. **desktopTrader**. Disponível em:  
<https://www.investbolsa.com.br/Sistema/desktopTrader.aspx>. Acesso em: 3 de dez. 09.

KIMOTO, Takashi; ASAKAWA, Kazuo. **Stock Market Prediction System with Modular NeuralNetworks**. IJCNN International Joint Conference on Neural Networks. 1990

MELLAGI FILHO, Armando; ISHIKAWA, Sérgio. **Mercado Financeiro e de Capitais**. 2. ed. São Paulo: Atlas, 2003.

MENDONÇA, André. **O que é a Teoria das Ondas de Elliot**. Disponível em: <http://www.elliottbrasil.com/teoriadeelliott.php>. Acesso em: 7 de nov. 2009

PINHEIRO, Juliano Lima. **Mercado de Capitais: fundamentos e técnicas** 4. ed. São Paulo: Atlas, 2008.

SBRUZZI, Elton. **Ideia – Sfera Stock Analysis**. Disponível em: <http://www.sferastockanalysis.com/br/ideia.php#3>. Acesso em: 4 de dez. 09.

TRADER DATA. **Produtos**. Disponível em: <http://www.traderdata.com.br/TDLiteImgs.aspx>. Acesso em 4 de dez. 09

WANDERLEY, Swami S.; PEREIRA, Tereza C. A.; FERNANDES; Paulo R. B. **Princípios da Neuroanatomia**. Rio de Janeiro: MEDSI, 2002.

WEILAND, Carla. **Análise Técnica: tipos de gráficos**. Disponível: [http://www.monitorinvestimentos.com.br/ver\\_artigo.php?id\\_artigo=81](http://www.monitorinvestimentos.com.br/ver_artigo.php?id_artigo=81). Acesso em: 9 de nov. 2009.

JAVAFREE.ORG. **Tutorial Java**. Disponível em: <http://javafree.uol.com.br/artigo/871498/Tutorial-Java-O-que-e-Java.html>. Acesso em: 2 de dez. 09.