

UNIVERSIDADE FEDERAL DE SANTA CATARINA

Ricardo Antonello

DESENVOLVIMENTO DE UM MODELO DE SISTEMA  
MULTIAGENTE PARA PREVISÃO DE RETORNO SOBRE  
INDICES DE AÇÕES

Florianópolis  
2010



RICARDO ANTONELLO

DESENVOLVIMENTO DE UM MODELO DE SISTEMA  
MULTIAGENTE PARA PREVISÃO DE RETORNO SOBRE  
ÍNDICES DE AÇÕES

Dissertação submetida à Universidade  
Federal de Santa Catarina como parte dos  
requisitos para a obtenção do grau de  
Mestre em Ciência da Computação.

Orientador: Dr. Ricardo Azambuja Silveira

Florianópolis  
2010



## RESUMO

ANTONELLO, Ricardo. **Desenvolvimento de um modelo de sistema multiagente para previsão de retorno sobre índice de ações.** Florianópolis, 2010. n. 30. Dissertação (Mestrado em Ciência da Computação)–Universidade Federal de Santa Catarina, Florianópolis, 2009.

No mundo das finanças, a Teoria dos Mercados Eficientes (TME) afirma que a flutuação do preço dos ativos financeiros é aleatória, sendo assim, não existem maneiras de proteger o investidor, prevendo os futuros movimentos do mercado. Contudo, várias iniciativas empíricas têm demonstrado que a afirmação da TME não é totalmente correta. Entre as frentes de pesquisa que buscam prever os movimentos de ativos financeiros, pode-se destacar a área com um ponto de vista econométrico, que tenta prever movimentos mediante métodos matemáticos e estatísticos, como regressão linear e regressão não linear, bem como as redes neurais. Além disso, em outra área de pesquisa, há a Teoria Multiagente de Modelagem de Mercado (*Theory of Multi-Agent Market Modeling*) que foca sua atenção na microestrutura do mercado, partindo do princípio de que os movimentos de preços emergem da interação de muitos agentes individuais do mercado. Contudo, esses modelos financeiros baseados em agentes têm algumas limitações. Não é possível adequar os agentes a dados reais do mercado para gerar previsões futuras, pois na maioria dos modelos a tomada de decisão é feita por meio de funções *ad-hoc* ou mecanismos que não podem ser ajustados a dados externos. Para obter uma previsão real do modelo, é preciso adaptar o mecanismo de decisão dos agentes com modelos econométricos, como as redes neurais, que podem ser ajustadas a séries de dados reais. Dessa forma, por intermédio da interação dos agentes, o modelo de mercado resultante pode capturar a dinâmica oculta do mercado e prever os movimentos futuros com uma eficácia maior do que faria um sistema de regressão não linear isoladamente. Este trabalho propõe um modelo computacional baseado na utilização do comportamento emergente de uma comunidade de agentes de *software* com mecanismos de decisão cognitiva, baseados em redes neurais, com o objetivo de realizar previsões do comportamento do Índice da Bolsa de Valores de São Paulo – Índice Bovespa. Os agentes da comunidade

interagem com um mecanismo de coleta dos valores das 65 ações mais negociadas da Bovespa que compõem o Índice Bovespa, utilizados para computar as previsões de evolução do índice. A fim de validar a hipótese da pesquisa, é feita uma comparação entre os resultados obtidos pelo modelo implementado, com uma abordagem tradicional de previsão baseada exclusivamente em redes neurais. Os resultados obtidos demonstram que as previsões do modelo proposto são mais performáticas do que a previsão isolada do índice baseada exclusivamente em redes neurais, já que o modelo proposto captura melhor a microestrutura do mercado, prevendo um passo a frente de maneira mais eficaz.

Palavras-chave: Sistemas multiagentes. Redes neurais. Previsão de série temporal.

## ABSTRACT

In finance world , the efficient-market hypothesis (EMH) states that the financial assets have random price fluctuation, so, there are not ways to protect the investor forecasting the future market movements. However, several initiatives have shown that empirical assertion of EMH is not entirely correct. Among the research fronts that seek to predict the movements of financial assets, we can highlight the area with an econometric point of view, which attempts to predict movements through mathematical and statistical methods such as linear regression and nonlinear regression, as well as neural networks. Moreover, in another area of research, we have the Theory of Multi-Agent Market Modeling that focuses attention on the micro-structure of the market, assuming that the price movements emerge from the interaction of many actors in the market. However, these financial models based on agents have some limitations. It is not possible to match agents to actual market data to forecast a step ahead, as in most models of decision making is done through ad-hoc functions or mechanisms that can not be adjusted to external data. For a preview of the real model, you need to adapt the decision-making mechanism of the agents with econometric models such as neural networks, which can be adjusted to actual data sets. Thus, through the interaction of the agents, the market model results can capture the hidden dynamics of the market and predict future movements with greater effectiveness than would a system of non-linear regression alone. This paper proposes a computational model based on the use of emergent behavior of a community of software agents with cognitive decision-making mechanisms base on neural networks in order to make predictions of the behavior of the index of He Stock Exchange of São Paulo – Bovespa Index. The agents of the community interact with one engine collects the values of the 65 most actively traded stocks that comprise the Bovespa Bovespa Index, used to compute the projected trend of the index. In order to validate the hypothesis of the study, a comparison is made between the results obtained by the model implemented with a traditional approach to forecasting based solely on neural networks. The results show that by the proposed model are more performing than the forecast index alone based solely on neural networks, since the proposed model better captures the microstructure of the market, and one step ahead more effectively.

## LISTA DE ILUSTRAÇÕES

Desenho 1:	Neurônio biológico .....	21
Esquema 1:	Neurônio artificial.....	22
Esquema 2:	Funções de ativação mais utilizadas: (a) função linear; (b) função degrau; (c) função sigmoide (ou logística); (d) tangente hiperbólica .....	24
Esquema 3:	Exemplos de redes <i>feedforward</i> : (a) rede de camada única; (b) rede multicamadas .....	25
Esquema 4:	Exemplos de rede recorrente.....	26
Esquema 5:	Exemplos de rede recorrente.....	28
Esquema 6:	Esquema geral de uma Rede de Elman.....	32
Esquema 7:	Esquema geral de uma Rede de Jordan.....	33
Esquema 8:	Janela de tempo para previsão de séries temporais em redes não recorrentes .....	35
Esquema 9:	Conceito de agente.....	36
Imagem 1:	Livro de ofertas da Perdigão (PRGA3).....	45
Imagem 2:	Códigos das ações mais negociadas na BMF&Bovespa .....	46
Imagem 3:	Livro de ofertas de uma ação sem liquidez.....	47
Gráfico 1:	Ações que fazem parte do Índice Bovespa com os respectivos pesos de ponderação .....	50
Quadro 1:	Ações que fazem parte do Índice Bovespa com os respectivos pesos.....	51
Organograma 1:	Aspectos do projeto de agentes no nível microeconômico.....	59
Organograma 2:	Classificação de técnicas de aprendizado frequentemente usadas na modelagem multiagente.....	63
Organograma 3:	Classificação de características macroeconômicas dos mercados usadas na modelagem multiagente.....	64
Organograma 4:	Diagrama de hierarquia de objetivos .....	65
Esquema 10:	Diagrama de sequência do caso de uso: Otimização do agente de decisão.....	67
Esquema 11:	Diagrama de sequência do caso de uso: ponderação das decisões .....	68
Esquema 12:	Diagrama de sequência do caso de uso: escolha do Agente Neural baseado somente nas cotações do Índice Bovespa.....	69
Fluxograma 1:	Diagrama de papéis.....	70

Fluxograma 2:	População de agentes do sistema .....	72
Esquema 13:	Configuração da rede neural utilizada pelos agentes de decisão .....	75
Gráfico 2:	Supertreinamento identificado após a época 1600 quando o acerto do conjunto de treinamentos começa a cair.....	78
Código 1:	Exemplo de criação de uma rede neural simples por meio do <i>framework</i> Encog .....	81
Código 2:	Exemplo de código para a criação de redes recorrentes.....	82
Arquivo 1:	Cotações diárias da ação preferencial PETR4 da Petrobras.....	83
Fluxograma 4:	Diagrama de classe de implementação.....	85

## LISTA DE ABREVIATURAS E SIGLAS

AMS	<i>Agent Manager System</i>
API	<i>Application Programming Interface</i>
JOONE	Java Object Oriented Neural Engine
RMA	<i>Remote Management Agent</i>
RMI	<i>Remote Method Invocation</i>
SM	Sistema Multiagente

## SUMÁRIO

1	<b>INTRODUÇÃO</b> .....	13
1.1	PROBLEMATIZAÇÃO .....	14
1.2	OBJETIVOS .....	15
1.2.1	<b>Objetivo Geral</b> .....	15
1.2.2	<b>Objetivos Específicos</b> .....	15
1.3	METODOLOGIA .....	16
1.4	ESTRUTURA DO TRABALHO .....	17
2	<b>REDES NEURAIS</b> .....	19
2.1	NEURÔNIOS ARTIFICIAIS .....	19
2.2	FUNÇÃO DE ATIVAÇÃO .....	22
2.2.1	<b>Função linear</b> .....	23
2.2.2	<b>Função degrau</b> .....	23
2.2.3	<b>Função sigmoide</b> .....	23
2.2.4	<b>Função tangente hiperbólica</b> .....	24
2.3	TOPOLOGIA DA REDE.....	25
2.4	TIPOS DE APRENDIZADO.....	26
2.4.1	<b>Aprendizado Supervisionado</b> .....	27
2.4.2	<b>Aprendizado não supervisionado</b> .....	27
2.5	REDES <i>MULTILAYER PERCEPTRON</i> (MLP) .....	27
2.6	ALGORITMO <i>BACKPROPAGATION</i> .....	29
2.6.1	<b>Algoritmo Resilient backpropagation</b> .....	29
2.7	PROCESSAMENTO TEMPORAL .....	30
2.7.1	<i>Time Delay Neural Network</i> (TDNN).....	31
2.7.2	<b>Redes de Elman</b> .....	31
2.7.3	<b>Redes de Jordan</b> .....	32
2.8	REDES NEURAIS EM PREVISÃO DE SÉRIES TEMPORAIS .....	34
3	<b>AGENTES</b> .....	36
3.1	RACIONALIDADE, APRENDIZADO E AUTONOMIA .....	37
3.2	SISTEMAS MULTIAGENTES (SMA).....	38
3.2.1	<b>Características dos ambientes</b> .....	39
3.2.2	<b>Comunicação entre Agentes</b> .....	39
4	<b>MODELAGEM MULTIAGENTE DE MERCADOS FINANCEIROS</b> .....	42
4.1	MERCADO FINANCEIRO NO BRASIL.....	42
4.1.1	<b>Sistema eletrônico de negociação de ações</b> .....	44

4.1.2	<b>Índice Bovespa</b> .....	48
4.2	TEORIA DOS MERCADOS EFICIENTES.....	51
4.3	PREVISÃO DO MERCADO DE AÇÕES.....	53
4.4	MODELAGEM MULTIAGENTE DE MERCADOS FINANCEIROS.....	54
4.4.1	<b>Simulação de crises e bolhas de preços por meio de sistemas multiagentes</b> .....	57
4.4.2	<b>Características dos agentes para modelagem de mercados financeiros</b> .....	59
4.4.2.1	Processo decisório.....	59
4.4.2.1.1	<i>Agentes baseados em regras</i> .....	60
4.4.2.1.2	<i>Agentes baseados em modelos de previsão</i> .....	60
4.4.2.2	Função Objetivo.....	61
4.4.2.3	Heterogeneidade.....	61
4.4.2.4	Aprendizado.....	62
4.4.3	<b>Características macroeconômicas dos modelos de mercados financeiros multiagentes</b> .....	64
5	<b>DESENVOLVIMENTO DO MODELO</b> .....	65
5.1	OBJETIVOS.....	65
5.2	CASOS DE USO E DIAGRAMAS DE SEQUÊNCIA...66	66
5.2.1	<b>Otimização do agente investidor</b> .....	66
5.2.2	<b>Ponderação das decisões individuais</b> .....	67
5.2.3	<b>Decisão sobre o Índice</b> .....	68
5.3	PAPÉIS.....	69
5.4	ESTRUTURA BÁSICA DO MODELO.....	71
5.5	MODELO DE DECISÃO.....	73
5.5.1	<b>Modelo de decisão dos agentes consultores</b> .....	73
5.5.1.1	Estruturas de RN utilizadas.....	74
5.5.1.2	Configurações de treinamento.....	76
5.5.2	<b>Modelo de decisão do agente agrupador</b> .....	78
6	<b>IMPLEMENTAÇÃO DO MODELO</b> .....	80
6.1	TECNOLOGIAS RELACIONADAS.....	80
6.1.1	<b>Detalhes de implementação por meio do <i>framework</i> Encog</b> .....	80
6.2	IMPORTAÇÃO DE COTAÇÕES.....	82
6.3	NORMALIZAÇÃO DOS DADOS.....	83
6.4	DIAGRAMA DE CLASSE DE IMPLEMENTAÇÃO ...84	84
7	<b>VALIDAÇÃO DO MODELO</b> .....	87
7.1	RESULTADOS OBTIDOS.....	87
8	<b>CONCLUSÃO</b> .....	91

<b>REFERÊNCIAS</b> .....	93
<b>ANEXO A – METODOLOGIA DO ÍNDICE BOVESPA (BOVESPA, 2009)</b> .....	101



# 1 INTRODUÇÃO

Todos os agentes financeiros são racionais e recebem, ao mesmo tempo, todas as informações disponíveis no mercado. Essa é uma afirmação da Teoria dos Mercados Eficientes (TME), que afirma ainda que todos os compradores e vendedores de ativos financeiros tomam as melhores decisões baseadas nas informações disponíveis. Quando não existem informações novas no mercado, os preços variam aleatoriamente e quando uma nova informação aparece, automaticamente os preços se movem para um novo patamar. Portanto, não é possível fazer uma previsão da tendência futura dos preços.

Contudo, não existe consenso a respeito da TME e várias iniciativas empíricas têm demonstrado que a afirmação da TME não é totalmente correta (MALKEI, 1999; FARMER; LO, 1996).

No caso do mercado de ações, mesmo com a velocidade atual dos meios de comunicação seria improvável que, ao mesmo tempo, todos os investidores recebessem todas as informações a respeito de uma determinada empresa que possui suas ações negociadas na bolsa de valores. Além disso, mesmo que as informações estivessem amplamente difundidas, é pouco provável que todos os investidores tomem a mesma decisão baseada nas informações do mercado, já que a complexidade e a quantidade das informações disponíveis tornam o processo decisório bastante complexo.

Sendo assim, partindo do princípio de que os agentes não são totalmente racionais e de que as informações não são igualmente distribuídas no mercado, há a possibilidade de tentar prever o comportamento futuro dos preços, baseados na premissa de que podem existir distorções temporárias que podem ser identificadas.

Dois grandes áreas de pesquisa buscam prever a futura direção dos movimentos de ativos financeiros. A primeira tem um ponto de vista econométrico, e utiliza métodos matemáticos e estatísticos – regressão linear e não linear –, bem como as redes neurais (PODDIG, 2000).

O outro campo de pesquisa que busca explicar os movimentos e as anomalias presentes nos mercados de uma maneira mais realista baseia-se na Teoria Multiagente de Modelagem de Mercado (*Theory of Multi-Agent Market Modeling*) é uma das mais importantes tendências nessa área (FARMER, 1998 apud GROTHMANN, 2002).

## 1.1 PROBLEMATIZAÇÃO

Os esforços na tentativa de utilizar sistemas multiagentes para capturar a microestrutura dos mercados esbarram em um problema básico: a falta de informação disponível. A grande maioria dos trabalhos propõe sistemas que possuem, como fonte de dados, apenas amostras da série temporal a ser explorada, ignorando os componentes que lhe dão origem, ignorando os eventos que formaram tal série. Um exemplo bastante encontrado na bibliografia é a tentativa de prever movimentos em série de índices das bolsas de valores, como o Índice Bovespa (FARIA, 2008; VIEIRA; THOMÉ, 1999) e o Índice da Bolsa de Nova York S&P500 (KALYVAS, 2001; KUTSURELIS, 1998), utilizando apenas séries com amostras do próprio valor do índice.

Contudo, índices de bolsas de valores não podem ser negociados (comprados ou vendidos) diretamente, pois são compostos por médias aritméticas ponderadas das ações que os compõem. Por exemplo, o índice S&P500 é composto pelas 500 maiores ações da bolsa de Nova York. Tentar buscar padrões na dinâmica dos preços dos índices ignorando a dinâmica individual de cada ação que compõe o índice é uma forma de simplificar o escopo da pesquisa, como também de ignorar importantes aspectos relacionados à real estrutura da série a ser explorada. Uma explicação para tais iniciativas serem tão numerosas é a dificuldade de se obter a grande massa de dados de cada ação, isoladamente, que compõe o índice, como também a dificuldade de se tratar cada série isoladamente, buscando avaliar o comportamento de todas as séries agrupadas no índice.

Outro problema encontrado é que grande parte dos trabalhos considera dados com séries históricas de longo prazo e frequência de leitura dos dados diária. Contudo, podem existir padrões nas séries que começam e terminam em poucos dias. A frequência diária na leitura dos dados não é suficiente para permitir correta identificação desses padrões. Neste trabalho serão utilizadas além da frequência de leitura diária, leituras de 60 em 60 minutos e de 15 em 15 minutos.

Além disso, nos últimos anos surgiram evidências de que existem janelas de tempo onde o sucesso da previsibilidade é maior (JOHNSON; GUPTA; HAUSER, 2005). Identificar esses espaços de tempo é fundamental para aumentar a segurança das previsões e evitar operações com prejuízos que, além de afetar o resultado final da lucratividade,

podem pôr em xeque a confiabilidade do sistema em aplicações reais (BOSAIPO, 2001). Para finalizar, outro ponto importante é que algumas métricas comumente utilizadas em séries temporais gerais, não se aplicam a séries financeiras, já que tais métricas não guardam relação direta com o lucro auferido pelo sistema (VIEIRA; THOMÉ, 1999). Dadas duas previsões realizadas por redes neurais distintas, não é certo que a previsão com o erro quadrático menor da saída é a previsão que auferiu o maior lucro, uma vez que as tendências captadas pelas redes neurais podem possuir diferentes magnitudes, conforme mostram Vieira e Thomé (1999):

[...] a quantidade de vezes em que uma tendência de alta ou baixa é prevista corretamente, guarda em si uma tênue relação com a lucratividade, já que a obtenção de lucro sofre influência direta da magnitude da variação de alta ou baixa do mercado, alterando de forma significativa o lucro final auferido.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo Geral

Desenvolver um modelo de comportamento emergente de uma comunidade de agentes inteligentes de *software*, com mecanismos de decisão cognitiva baseados em redes neurais, para a previsão de séries temporais de índices de ações.

### 1.2.2 Objetivos Específicos

- a) Estabelecer um modelo cognitivo de decisão para agentes de *software* que seja capaz de ser treinado com dados reais do mercado;

- b) estabelecer um modelo de comunicação entre agentes de uma comunidade de agentes inteligentes que permita a verificação de uma condição emergente no comportamento da comunidade;
- c) estabelecer um modelo de utilização do comportamento emergente de agentes inteligentes na indicação da dinâmica do preço de um índice de ações;
- d) revisar a plataforma tecnológica para a implementação do sistema, incluindo a revisão de *frameworks* para implementação de agentes e redes neurais;
- e) implementar o modelo proposto para realizar a previsão do Índice da Bolsa de Valores de São Paulo – Índice Bovespa.
- f) validar a hipótese da pesquisa, comparando o resultado obtido com estratégias de negociação de ações.

### 1.3 METODOLOGIA

A metodologia utilizada para o desenvolvimento deste trabalho inicia-se pela revisão dos principais conceitos teóricos necessários para a compreensão do modelo cognitivo baseado em redes neurais proposto. Essa revisão concentra os principais conceitos relativos às redes neurais artificiais e à capacidade deste método de regressão não linear de prever a dinâmica de séries temporais. Sobre a tecnologia de agentes, apresentam-se os conceitos relacionados à sua estrutura individual e seu comportamento na comunicação dentro da comunidade de agentes, incluindo modelos de comunicação, que são formalismos necessários para que os agentes se compreendam, mediante um mecanismo comum de comunicação.

Ainda na revisão dos conceitos teóricos, aborda-se a importância do conceito do cálculo de um Índice de Ações por intermédio das ações que o compõe. É estabelecido, como exemplo, o cálculo formal do Índice Bovespa – Ibovespa, objeto de estudo deste trabalho. Conforme será mostrado, a utilização de agentes representando a microestrutura de cada ação que compõe o índice pode representar uma vantagem considerável em relação à utilização direta do próprio índice.

Além do estudo dos conceitos, houve a necessidade de um estudo a respeito dos modelos econométricos de decisão baseados em médias móveis, incluindo a conceituação desse indicador estatístico em suas

várias formas. Além da descrição formal da estratégia *buy and hold* baseada na Teoria dos Mercados Eficientes (TME).

A partir da compreensão desses conceitos, é selecionado um modelo cognitivo que é capaz de ser treinado com dados reais do mercado para a aplicação no processo decisório do agente. Além disso, é estabelecido um modelo de comunicação entre os agentes a fim de permitir a verificação de uma condição emergente no comportamento da comunidade. E, por fim, é estabelecido um modelo de utilização do comportamento emergente da comunidade de agentes inteligentes para indicar a dinâmica do preço de um índice de ações. Para possibilitar a implantação do modelo, foi revisada a plataforma tecnológica disponível para a implementação de sistemas multiagentes com capacidades cognitivas que atendessem às necessidades de comunicação entre os agentes do modelo proposto, incluindo a análise de *frameworks* específicos para atender às necessidades de criação do sistema multiagente e dos modelos de redes neurais necessários.

A fim de validar o modelo proposto, este foi implementado de modo a realizar a previsão do Índice da Bolsa de Valores de São Paulo – Índice Bovespa por meio da utilização do comportamento emergente da comunidade de agentes alimentada com os dados das mais de 60 ações mais negociadas da Bovespa que compõem o Índice Bovespa. Além disso, utilizando exatamente a mesma série de dados, foram realizadas previsões no mesmo período de tempo utilizando a abordagem tradicional de redes neurais, na qual apenas a série histórica do próprio índice é utilizada para realizar a previsão um passo a frente. Visando validar a hipótese da pesquisa, foi comparado o resultado obtido do modelo de sistema multiagente proposto com o resultado de um modelo tradicional de redes neurais. O modelo proposto foi implementado utilizando as séries históricas das mais de 60 ações do Índice Bovespa. Já o modelo tradicional de previsão de séries temporais foi implementado utilizando-se redes neurais onde apenas a série histórica do próprio índice é utilizada como entrada de dados para realizar a previsão um passo a frente.

#### 1.4 ESTRUTURA DO TRABALHO

O trabalho é organizado em oito seções: Introdução; Redes Neurais; Agentes; Modelagem Multiagente de Mercados Financeiros;

Desenvolvimento do Modelo; Implementação do Modelo; Validação do Modelo; Conclusão. Na Introdução são apresentadas as motivações e justificativas para a realização desta dissertação, bem como os objetivos a serem contemplados com a pesquisa.

As seções 2, 3 e 4 abordam os conceitos necessários à compreensão e desenvolvimento desta pesquisa. Na seção 2 ocorre a conceitualização de redes neurais incluindo as redes neurais *perceptron* de uma ou mais camadas, redes neurais recorrentes e com atraso de tempo (*time delay*) e as pesquisas recentes na área de redes neurais em previsão de séries temporais, além das aplicações de redes neurais em economia e finanças.

A seção 3 introduz o conceito de agentes e sistemas multiagentes. Na seção 4 apresentam-se a Teoria dos Mercados Eficientes e a abordagem dos sistemas multiagentes na modelagem de mercados financeiros. Também, faz-se, nessa seção, uma contextualização sobre o mercado financeiro no Brasil, incluindo o sistema eletrônico de negociação de ações da BMF&Bovespa e a forma de cálculo do Índice Bovespa, o principal índice de ações do Brasil.

O desenvolvimento do *modelo* proposto é descrito na seção 5, que apresenta a arquitetura tecnológica desenvolvida. Na seção 6 há uma aplicação para avaliação da potencialidade do uso do modelo para previsão de séries financeiras e na seção 7 declaram-se os resultados obtidos. Por fim, na seção 8 são expostas as considerações (percepções, dificuldades e sucessos) a respeito de cada uma das etapas da pesquisa realizada.

## 2 REDES NEURAIS

As Redes Neurais, também chamadas de Redes Neurais Artificiais, são sistemas conexionistas que fornecem um método com inspiração biológica para aprendizado de diversos tipos de funções. Uma rede neural pode ser vista como um processador paralelo e distribuído, constituído de unidades de processamento simples, que têm propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2001).

As Redes Neurais destacam-se entre os métodos utilizados para aproximação de funções, pois apresentam capacidade de aprendizado e generalização. Assim, podem ser empregadas no reconhecimento de padrões, no processamento de sinais digitais e imagens, em otimização numérica, em visão computacional, robótica e, também, para previsão de séries temporais (BRAGA; CARVALHO; LUDERMIR, 1998).

Conforme citam Braga, Carvalho e Ludermir (2000), o primeiro modelo de neurônio artificial foi criado em 1943, por Warren McCulloch e Walter Pitts. Mas foi Dobald Hebb, em 1949, que demonstrou a capacidade de aprendizado por intermédio da variação dos pesos sinápticos. Em 1958, Frank Rosenblatt demonstrou o *perceptron*, com sinapses ajustáveis. As redes com *perceptrons* tinham o objetivo de serem treinadas para reconhecer padrões e, até hoje, o *perceptron* é a base para muitas redes neurais. Contudo, em 1969, Minsky e Papert provaram que o *perceptron* não poderia resolver problemas que não fossem linearmente separáveis; essa prova deixou as Redes Neurais afastadas das pesquisas de muitos cientistas durante muitos anos. Somente após a publicação dos trabalhos de John Hopfield em 1982 e, principalmente, depois do algoritmo *back propagation* ter demonstrado por que Minsky e Papert estavam errados é que as Redes Neurais voltaram a ser bastante pesquisadas.

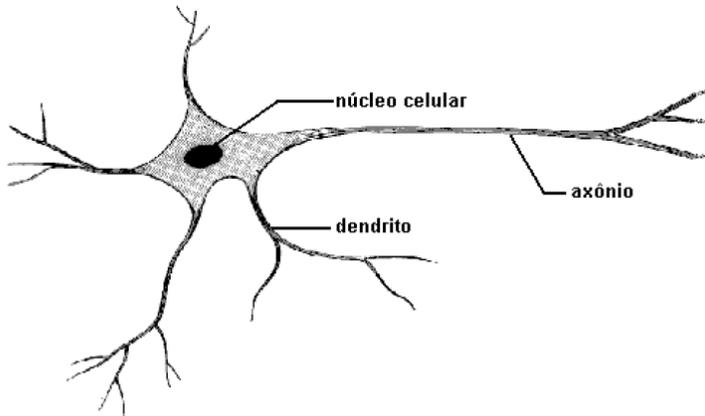
### 2.1 NEURÔNIOS ARTIFICIAIS

A inspiração biológica contida em uma Rede Neural Artificial vem do funcionamento do cérebro humano, no qual muitas unidades simples, os neurônios, trabalham em paralelo sem um controle central.

Assim como o cérebro humano, uma Rede Neural Artificial é composta de muitas unidades simples que trabalham em paralelo. As conexões entre essas unidades possuem pesos numéricos que podem ser modificados pelo elemento de aprendizado (RUSSEL; NORVIG, 2004). A essas unidades dá-se o nome de neurônio artificial e suas conexões são as sinapses. Contudo, as Redes Neurais Artificiais da forma como são implementadas computacionalmente hoje são semelhantes ao cérebro humano basicamente em dois aspectos (HAYKIN, 2001): a experiência é a fonte do conhecimento adquirido, e o conhecimento adquirido é armazenado nas sinapses.

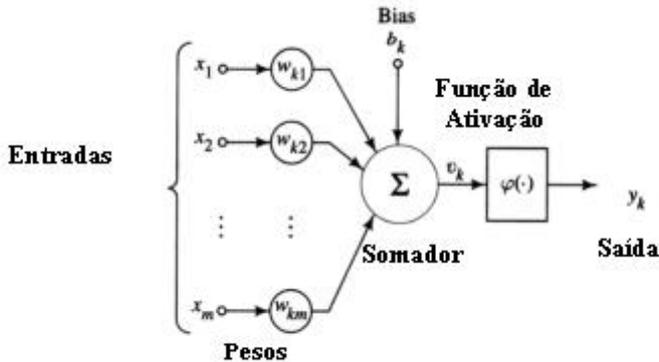
O cérebro humano é composto de uma rede interconectada de neurônios. O neurônio por sua vez, ilustrado no Desenho 1, é composto por um corpo celular onde se encontra seu núcleo e por axônios e dendritos. O axônio é uma fibra nervosa comprida, de superfície lisa, com poucas ramificações, que é responsável pela transmissão dos sinais elétricos para outros neurônios. Já os dendritos atuam como receptores na comunicação, eles têm aparência de árvores e possuem superfície irregular com muitas ramificações.

A comunicação entre o axônio (saída) de um neurônio e o dendrito (entrada) de outro neurônio é chamada de sinapse e é caracterizada por um processo químico no qual são liberadas substâncias transmissoras que se difundem pela junção sináptica entre neurônios, o que causa aumento ou queda no potencial elétrico do neurônio receptor. Resumindo, conforme cita Haykin (2001), uma sinapse é a conexão entre neurônios, o que implica excitação ou inibição do neurônio receptor.



Desenho 1: Neurônio biológico  
Fonte: Haykin (2001).

Um neurônio artificial apresenta as mesmas características, conforme se pode visualizar no Esquema 1, no qual as sinapses são representadas pelas entradas incluindo pesos sinápticos com seu somatório e a função de ativação. Cada sinapse é, portanto, caracterizada por um estímulo de entrada multiplicado pelo seu peso sináptico correspondente. Depois dessa multiplicação, cada sinal de entrada é somado e o resultado é então aplicado a uma função de ativação que restringe a saída do neurônio a um intervalo de 0 a 1 ou de  $-1$  a  $+1$ .



Esquema 1: Neurônio artificial  
 Fonte: Haykin (2001).

Conforme Haykin (2001), o neurônio artificial pode ser descrito pela equação:

$$y_k = \varphi \left( \sum_{i=1}^n x_i w_{ki} \right) \quad (1)$$

Onde,  $y_k$  é a saída do neurônio;  $\varphi$  é a função de ativação,  $x_i$  corresponde aos sinais de entrada do neurônio; e  $w_{ki}$  corresponde aos pesos sinápticos do neurônio k. Assim, o neurônio artificial tem um funcionamento similar ao do neurônio biológico que por meio das entradas representadas pelas sinapses e pela função de ativação que simula o processo químico de excitação ou inibição da saída para os dos próximos neurônios.

## 2.2 FUNÇÃO DE ATIVAÇÃO

Cada neurônio realiza um processamento simples: recebe uma entrada e computa um novo nível de ativação (RUSSEL; NORVIG, 2004). Esse processamento é composto por duas etapas: na primeira,

cada entrada  $x_i$  do neurônio é multiplicada pelo peso sináptico correspondente  $w_{ki}$  (peso da entrada  $k$  do neurônio  $i$ ). O resultado de cada multiplicação é então somado. Na segunda etapa a soma é aplicada a uma função de ativação  $f$ , obtendo-se a saída do neurônio  $y$ :

$$y = f\left(\sum x_i w_{ki}\right) \quad (2)$$

A função de ativação deve simular as características não lineares do neurônio biológico (RUSSEL; NORVIG, 2004). As funções mais utilizadas são: função linear, função degrau, função sigmoide e função tangente hiperbólica, as quais serão vistas a seguir.

### 2.2.1 Função linear

É uma equação linear da forma:

$$f(x) = ax \quad (3)$$

### 2.2.2 Função degrau

É uma equação utilizada para valores binários e é da forma:

$$f(x) = \begin{cases} 1 & \text{se } x > 0 \\ 0 & \text{se } x \leq 0 \end{cases} \quad (4)$$

### 2.2.3 Função sigmoide

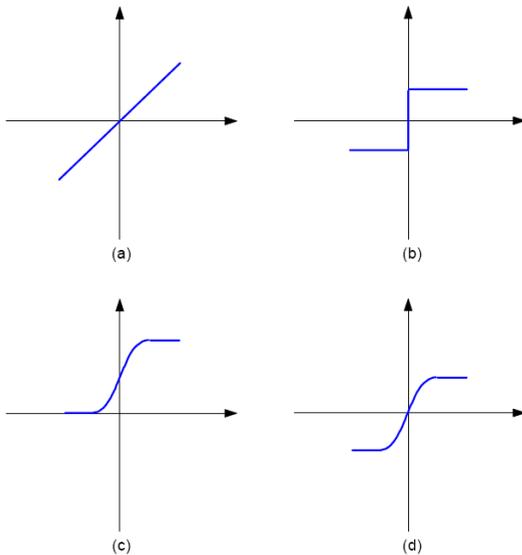
Também chamada de função logística, é uma função contínua que permite a transição gradual entre os dois estados. É dada por:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

### 2.2.4 Função tangente hiperbólica

É uma função sigmoide que varia entre  $-1$  e  $+1$ . É dada por:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (6)$$

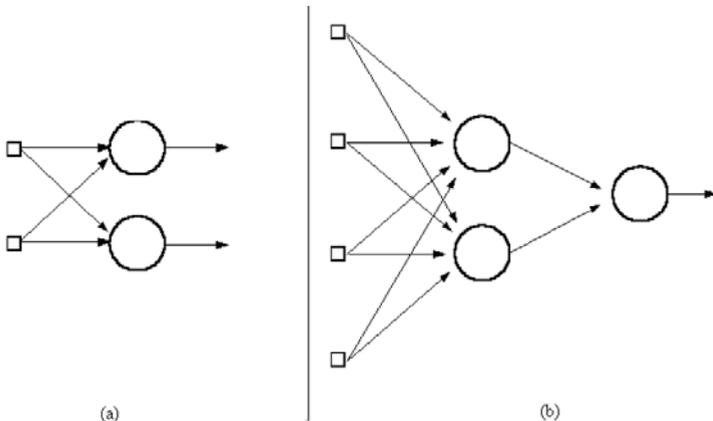


Esquema 2: Funções de ativação mais utilizadas: (a) função linear; (b) função degrau; (c) função sigmóide (ou logística); (d) tangente hiperbólica

Fonte: Braga, Carvalho e Ludermir (2000).

## 2.3 TOPOLOGIA DA REDE

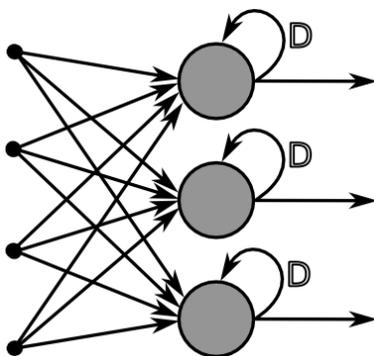
Existe uma grande variedade de redes, cada uma produz diferentes resultados. Elas podem ser classificadas basicamente em alimentadas a frente (*feedforward*) e recorrentes (RUSSEL; NORVIG, 2004). Nas redes *feedforward* os neurônios estão dispostos em camadas, podendo haver redes com uma única camada e redes com múltiplas camadas. As redes *feedforward* são inerentemente acíclicas, ou seja, o sinal é propagado somente da entrada para a saída da rede. Também são chamadas redes sem memória. As redes multicamadas se distinguem das redes de camada única pela presença de uma ou mais camadas ocultas. As entradas de um neurônio da camada oculta são as saídas dos neurônios da camada anterior, e, portanto, não há ligação entre neurônios de uma mesma camada. Uma rede *feedforward* é representada pela notação '*e-o1-o2-...-on-s*', onde '*e*' representa o número de neurônios nas camadas de entrada, '*o1*', '*o2*', ..., '*on*' representam o número de neurônios nas camadas ocultas e '*s*' o número de neurônios na camada de saída. O Esquema 3 ilustra uma rede *feedforward* de camada única (a) e uma rede multicamada 4-2-1 (b) (HAYKIN, 2001; RUSSEL; NORVIG, 2004).



Esquema 3: Exemplos de redes *feedforward*: (a) rede de camada única; (b) rede multicamadas

Fonte: Haykin (2001).

As redes *Perceptron* e o *Multi-Layer Perceptron (MLP)* são, respectivamente, exemplos de modelos de rede de camada única e rede de múltiplas camadas. Ao contrário das redes *feedforward* as redes recorrentes possuem laços de realimentação, ou seja, a saída de um neurônio pode ser entrada para outro de uma camada precedente ou, no caso de autorrealimentação, para o próprio neurônio. As redes recorrentes, chamadas de redes com memória, não possuem organização rígida e seus neurônios têm liberdade para se ligar a qualquer outro neurônio (HAYKIN, 2001; RUSSEL; NORVIG, 2004). O Esquema 4 ilustra uma rede recorrente.



Esquema 4: Exemplos de rede recorrente  
Fonte: Haykin (2001).

Como exemplos de modelos de redes recorrentes há a rede de Elman, rede de Hopfield, rede de Jordan e NARX.

## 2.4 TIPOS DE APRENDIZADO

O processo de aprendizagem ocorre mediante um processo interativo de ajuste dos parâmetros livres, pesos sinápticos, por estimulação do ambiente (HAYKIN, 2001). Os paradigmas de aprendizado são: aprendizado supervisionado e aprendizado não supervisionado, descritos a seguir.

### 2.4.1 Aprendizado Supervisionado

É também chamado de aprendizado com “professor”. Essa forma de aprendizado baseia-se em um conjunto de exemplos de entrada-saída que é apresentado à rede. A partir da entrada, a rede realiza seu processamento e a saída obtida é comparada com a saída esperada. Caso não sejam iguais, um processo de ajuste de pesos é aplicado, buscando-se um erro mínimo ou aceitável. O algoritmo de aprendizado supervisionado mais comum é o *backpropagation* (HAYKIN, 2001).

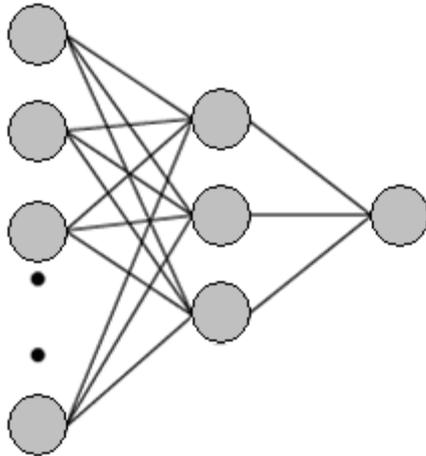
### 2.4.2 Aprendizado não supervisionado

Esse tipo de aprendizado é caracterizado pela ausência de um elemento externo supervisor, ou seja, um padrão de entrada fornecido permite que a rede livremente escolha o padrão de saída a partir das regras de aprendizado adotadas. Possui duas divisões: aprendizado por reforço que consiste no mapeamento entrada-saída por meio da interação com o ambiente, e aprendizagem não supervisionada ou auto-organizada onde, a partir de métricas de qualidade do aprendizado ocorre a otimização dos parâmetros livres da rede. Nesse caso, por exemplo, pode ser utilizada a regra de aprendizagem competitiva. Segundo Haykin (2001), os algoritmos de aprendizado não supervisionado mais importantes são: o Algoritmo de Hopfield e os Mapas de Kohonen.

## 2.5 REDES MULTILAYER PERCEPTRON (MLP)

Conforme citam Braga, Carvalho e Ludermir (2000), as redes de uma só camada com unidades *perceptron* não têm capacidade de resolver problemas linearmente separáveis. Por exemplo, uma rede de uma camada não consegue aprender a função XOR (ou exclusivo) já que não é um problema linearmente separável. Assim, a solução para problemas que não são linearmente separáveis é utilizar mais de uma

camada na topologia da rede. Segundo Cybenko (1989 apud BRAGA; CARVALHO; LUDERMIR, 2000), uma rede com uma camada intermediária, conforme Esquema 5, pode implementar qualquer função contínua. Contudo Braga, Carvalho e Ludermir (2000) alertam que o fato de permitir a implementação da função não garante que a rede consiga aprender essa função, já que dependendo da distribuição dos dados a rede pode, por exemplo, convergir para um mínimo local.



Esquema 5: Exemplos de rede multilayer  
Fonte: Haykin (2001).

Para treinar uma rede multicamadas o método mais comum baseia-se no gradiente descendente, que precisa de uma função de ativação contínua. Sendo assim, das várias funções de ativação vistas apenas as funções do tipo sigmoidal podem ser usadas.

As redes MLP são as redes mais utilizadas em aplicações de Redes Neurais Artificiais em razão de sua simplicidade e facilidade de implementação (BRAGA; CARVALHO; LUDERMIR, 2000).

Essas redes são utilizadas para várias aplicações, como reconhecimento de escrita, verificação de assinaturas, segurança em cartões de crédito, diagnóstico médico e previsão do comportamento de ações na bolsa.

## 2.6 ALGORITMO *BACKPROPAGATION*

O algoritmo *Backpropagation* é um algoritmo de aprendizado supervisionado baseado na correção de erros. Foi publicado por Rumelhart, em 1986, no livro *Parallel Distributed Processing*, embora tenha sido proposto por pesquisadores como Bryson e Ho em 1969, Werbos em 1974, Parker em 1985 e Minsky e Papert em 1988 para diversos propósitos (RUSSEL; NORVIG, 2004).

O objetivo do algoritmo *Backpropagation* é encontrar, na superfície de erro, um mínimo local, ou seja, valores para os pesos sinápticos que minimizam o erro da rede. Como um algoritmo de aprendizado supervisionado, o *Backpropagation* utiliza pares entrada-saída para ajustar os pesos da rede. A frequência com que esses ajustes são feitos depende do tipo de treinamento, que pode ser: por padrão (*on-line*), onde a atualização é realizada após cada exemplo apresentado; por ciclo (*batch* ou lote), onde a atualização é realizada após todos os exemplos do conjunto de treinamento serem apresentados à rede (HAYKIN, 2001). Os critérios de parada, embora ainda não existam critérios bem-sucedidos para terminar o processo de aprendizado, podem ser: quando, percorrendo-se a superfície de erro, for encontrado um mínimo; a variação do erro for infinitamente pequena sendo insuficiente para melhorar a *performance* da rede; e ao aplicar o conjunto de treinamento um número determinado de vezes, ou seja, baseado no número de épocas. É comum se observar, na prática, a combinação dos critérios supracitados conforme Haykin (2001).

### 2.6.1 Algoritmo *Resilient backpropagation*

O algoritmo *Resilient backpropagation* é um algoritmo de adaptação global que realiza treinamento supervisionado *batch* em redes do tipo MLP (BRAGA; CARVALHO; LUDERMIR, 2000). O algoritmo *Resilient backpropagation* tenta minimizar o problema do algoritmo *backpropagation* normal, quando a derivada parcial usada no ajuste dos pesos fica quase igual a zero, praticamente eliminando o ajuste dos pesos. Isso ocorre quando a saída do nodo for próxima de 0 e

a saída desejada for 1 ou quando a entrada do nodo for 1 e a saída desejada for 0.

Para resolver o problema, o algoritmo *Resilient backpropagation* usa somente o sinal da derivada para ajustar o peso sem considerar seu valor absoluto e o tamanho do ajuste é dado por um valor de atualização  $\Delta_{ji}^t$  baseado no sinal da derivada, o mais interessante é que se o sinal da derivada atual foi o mesmo sinal do ultimo ajuste que reduziu o erro geral da rede, então o valor de ajuste é aumentado por um fator  $\eta^+$  o que aumenta a velocidade de convergência da rede. Contudo, quando a derivada parcial muda de sinal, o que indica que o ajuste anterior foi grande demais, o valor de atualização  $\Delta_{ji}^t$  é reduzido pelo fator  $\eta^-$ , mudando a direção do ajuste.

## 2.7 PROCESSAMENTO TEMPORAL

Conforme citam Braga, Carvalho e Ludermir (2000), o tempo é um parâmetro importante para vários tipos de reconhecimento de padrões, incluindo detecção de movimentos, reconhecimento de voz, visão e processamento de sinais. Contudo, o algoritmo *backpropagation* não trata esses mapeamentos dinâmicos já que sua estrutura foi criada para tratar mapeamentos estáticos.

Alguns pesquisadores utilizam o artifício de janelas de tempo para ensinar mapeamentos dinâmicos com *backpropagation*. As janelas de tempo utilizam sequências de dados temporais como se fosse um padrão estático, essa solução, no entanto, não é a mais indicada para o processamento temporal.

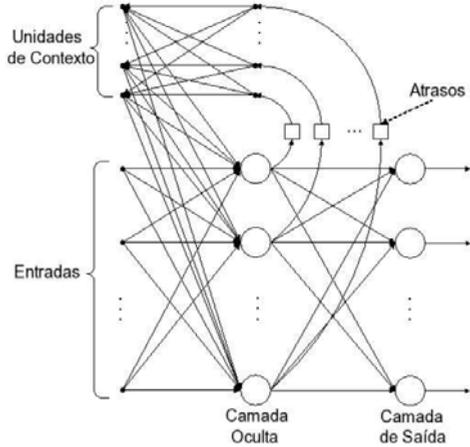
Conforme cita Elman (1990 apud BRAGA; CARVALHO; LUDERMIR, 2000), para uma rede neural artificial ser considerada dinâmica ela precisa ter memória. Existem duas formas de prover memória para as Redes Neurais, por meio de atrasos no tempo, como as técnicas *Time Delay Neural Network* (TDNN) ou utilizar redes recorrentes, como as redes de Elman e as redes de Jordan.

### 2.7.1 *Time Delay Neural Network* (TDNN)

Uma TDNN é uma rede neural *feedforward* com as unidades intermediárias e de entrada duplicadas. Essas unidades possuem valores com atraso, fornecendo entradas de iterações passadas à Rede Neural em questão. O atraso no fornecimento de entradas à rede introduz memória, proporcionando aos neurônios valores de entrada atuais e valores temporalmente anteriores a eles.

### 2.7.2 **Redes de Elman**

A Rede de Elman, ou rede recorrente simples, foi descrita por Elman (1990) e é uma rede na qual a realimentação das camadas ocultas permite a realização de tarefas que se estendem no tempo (HAYKIN, 2001). A Rede de Elman é uma rede recorrente; a realimentação ocorre da saída de cada neurônio da camada oculta para todos os neurônios da mesma camada. Uma camada, chamada Camada de Contexto, também oculta, composta de Unidades de Contexto simula a memória da rede. O processamento da rede ocorre da seguinte forma: no instante  $t$  (inicial) o sinal é propagado pela rede e as unidades de contexto, inicializadas com a saída da camada oculta com o valor 0, não influenciarão na saída da rede, ou seja, na primeira iteração a rede se comportará como uma rede *feedforward* comum. Ainda na primeira iteração, os neurônios ocultos ativarão os neurônios da camada de contexto e esses armazenarão a saída dessa iteração que será utilizada no próximo ciclo. O algoritmo *backpropagation* é então aplicado para a correção dos pesos sinápticos, com exceção das sinapses recorrentes, que são fixas em 1. No instante  $t+1$  o processo é repetido. A diferença é que a partir de agora os neurônios ocultos serão ativados pelas unidades de entrada e pelas unidades de contexto que possuem o valor de saída dos neurônios ocultos no instante  $t$  (ELMAN, 1990).



Esquema 6: Esquema geral de uma Rede de Elman  
 Fonte: Braga, Carvalho e Ludermir (2000).

A equação a seguir define a saída de um neurônio da camada oculta da rede de Elman, veja:

$$a_i(t) = f\left(\sum w_{ei}x_i(k) + \sum a_i(k-1) + w_{bi}\right) \quad (7)$$

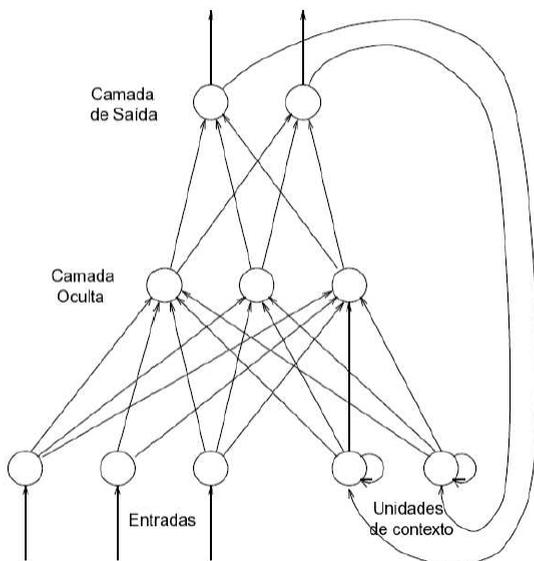
Onde  $a_i(t)$  é a saída do neurônio  $i$ , no instante  $t$ , dada pela função de ativação  $f$  que recebe a soma do produto  $w_{ei}$  que é o peso sináptico associado do neurônio e com o neurônio  $i$  multiplicado pela entrada  $x_i(t)$ , ou a saída do neurônio  $e$ ,  $a_e$ , somado ao somatório das saídas dos neurônios ocultos no instante  $t-1$ , somado ainda, a bias.

### 2.7.3 Redes de Jordan

As redes de Jordan também são redes recorrentes, ou seja, possuem ciclos nas ligações entre neurônios. Os ciclos, no caso das redes de Jordan, resumem-se à saída da última camada que retornam

para a camada intermediária, ou seja, a saída de um neurônio da camada de saída é usada como entrada adicional em todos os neurônios da camada intermediária. Outra camada chamada camada de contexto é usada para memorizar os valores de saída no instante anterior.

O processo ocorre da seguinte maneira: no instante  $t$  (inicial) o sinal é propagado pela rede e as unidades de contexto (iniciadas com zero) não vão interferir no processo. Contudo, a partir do instante  $t+1$ , as unidades de contexto estarão carregadas com os dados do instante  $t$  para realimentar a camada intermediária. Vale lembrar que as sinapses recorrentes possuem o valor fixado em 1, não sendo alteradas pelo *backpropagation*.



Esquema 7: Esquema geral de uma Rede de Jordan  
 Fonte: Braga, Carvalho e Ludermir (2000).

Ou seja, a rede de Jordan é muito similar à rede de Elman, com a única diferença de que as unidades de contexto são alimentadas com a saída da rede, e não com a saída da camada intermediária, como ocorre nas redes de Elman.

## 2.8 REDES NEURAIIS EM PREVISÃO DE SÉRIES TEMPORAIS

As Redes Neurais ganharam especial atenção na área de pesquisa sobre previsão de séries temporais, pela sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela. Essas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, como sazonalidade, periodicidade, tendências, entre outras, na maioria das vezes camufladas por ruídos.

Porém, as Redes Neurais também possuem limitações. O maior problema enfrentado pelos projetistas de redes neurais é a falta de procedimentos para definir com precisão o número de camadas escondidas ou o número de neurônios em cada uma dessas camadas. Em outras palavras, a topologia mais apropriada para a aplicação. Outro problema é a incapacidade de explicação dos resultados obtidos, já que o conhecimento fica internalizado nas sinapses criadas entre os neurônios.

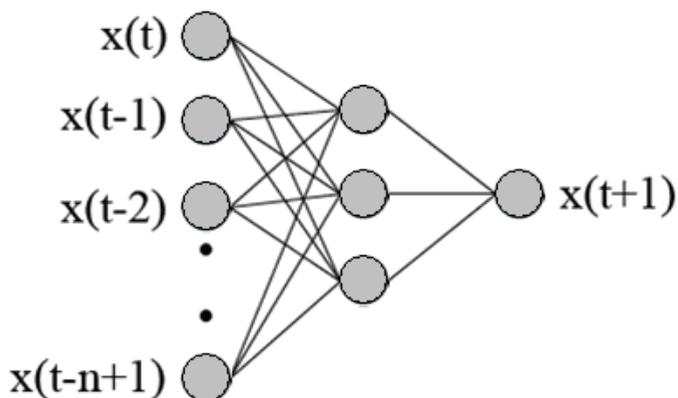
Um terceiro problema é a possibilidade de não convergência das redes neurais em virtude de mínimos locais ou, ainda, o problema de supertreinamento ou *overfitting*. O *overfitting* faz a rede neural perder o poder de generalização, isso acontece quando a rede é treinada excessivamente a ponto de modelar o ruído presente no conjunto de treinamento. Vários fatores podem levar ao *overfitting*, entre eles está o número excessivo de ciclos no treinamento ou o número excessivo de neurônios nas camadas ocultas, que deteriora a capacidade de generalização da rede.

Apesar das limitações, as redes neurais despertam muito interesse na utilização para previsão de séries temporais, principalmente no segmento financeiro. A prova disso é que 60% dos *e-mails* recebidos pelos mantenedores do *framework* Joone (JOONE, 2007) dizem respeito a usuários que estão utilizando o *framework* para fazer previsões sobre séries financeiras. Infelizmente, é difícil obter bons resultados na previsão de séries financeiras, principalmente devido ao ruído embutido em séries desse tipo (JOONE, 2007).

A técnica mais usada para trabalhar com séries temporais é capturar os valores da série em períodos discretos, como por exemplo, por intermédio de uma periodicidade semanal, diária, a cada 60 minutos ou a cada 30 minutos e então usar esses valores como entradas da rede neural.

De posse dos dados é possível trabalhar com redes de processamento temporal, como as redes de Elman ou Jordan, que são redes recorrentes, ou com redes *feedforward* simples, utilizando janelas de tempo.

No caso das janelas de tempo, o que se faz é selecionar um tamanho para a janela, ou seja, uma quantidade de observações-padrão. Para um tamanho  $n$  da janela, é necessário ter pelo menos  $n$  neurônios de entrada na rede neural, cada um representando uma observação da janela, conforme Esquema 8.



Esquema 8: Janela de tempo para previsão de séries temporais em redes não recorrentes

Fonte: Joone (2007).

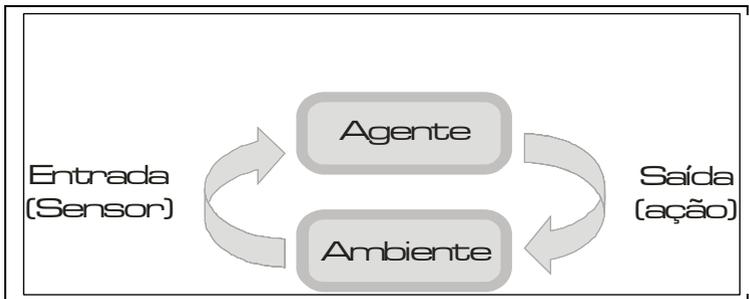
E novos exemplos poderão ser enviados à rede movendo um passo para frente a janela, portanto, a janela vai se movendo entre  $x(t)$  e  $x(t-n)$  tendo a saída da rede na fase de treinamento como sendo  $x(t+1)$ .

### 3 AGENTES

Nesta seção é descrita a tecnologia de agentes, necessária à compreensão do restante deste trabalho.

A Inteligência Artificial moderna utiliza fortemente o conceito de agente. Um agente é algo que pode perceber o ambiente no qual está inserido mediante sensores (entradas de dados) e, de posse dessas percepções, atua no ambiente por intermédio de atuadores (saída de dados) (RUSSEL; NORVIG, 2004). Em outras palavras, um agente é uma peça de *software* que trabalha de forma contínua e autônoma, dentro de um ambiente definido. O agente pode atuar em um ambiente de forma flexível e inteligente, necessitando do mínimo de intervenção humana.

Seguindo esse conceito, um agente que tenta melhorar a *performance* de suas atuações sobre o ambiente é considerado um agente racional. O Esquema 9 ilustra o conceito de agente.



Esquema 9: Conceito de agente  
Fonte: adaptado de Wooldridge (2002).

Segundo Wooldridge (2002), um agente é um sistema computacional que está situado em alguns ambientes, e que é capaz de realizar ações autônomas nesse ambiente de forma a atingir seus objetivos projetados (WOOLDRIDGE, 2002). No Esquema 9, o agente é ilustrado em seu ambiente capturando informações por meio de sensores e atuando mediante as ações produzidas. Russel e Norvig (2004) também destacam que um agente é tudo que pode ser

considerado capaz de perceber seu ambiente por meio de sensores e de agir sobre esse ambiente por intermédio de atuadores.

### 3.1 RACIONALIDADE, APRENDIZADO E AUTONOMIA

A racionalidade de um agente depende de quatro fatores, conforme Russel e Norvig (2004):

- a) a medida de desempenho para definir o critério de sucesso;
- b) o conhecimento anterior que o agente tem do ambiente;
- c) as ações que o agente pode executar;
- d) a sequência de percepções do agente até o momento.

Russel e Norvig (2004) complementam ainda que:

[...] para cada sequência de percepções possível, um agente racional deve selecionar uma ação que se espera venha a maximizar sua medida de desempenho, dada a evidencia fornecida pela sequência de percepções e por qualquer conhecimento interno do agente.

Definido o conceito de racionalidade, é importante ressaltar que os agentes podem ainda ser autônomos e, mais importante do que isso, podem aprender.

A racionalidade define que a escolha racional depende da sequência de percepções do agente até o momento. O agente pode e deve realizar ações para modificar suas percepções futuras, esse processo se chama coleta de informações e é uma parte importante da racionalidade.

O aprendizado é outra característica importante de um agente racional, pois dada uma modificação no ambiente, percebida pelo agente, este deve mudar suas ações, ou seja, aprender com o ambiente em evolução visando maximizar seu desempenho.

Outro fator de grande importância é a autonomia de um agente. Conforme Russel e Norvig (2004) quando um agente se baseia no conhecimento anterior de seu projetista e não em suas próprias percepções afirma-se que o agente não tem autonomia. Um agente

racional deve ser autônomo e deve aprender o que puder para compensar um conhecimento prévio parcial ou incorreto. Vale lembrar que a grande maioria das aplicações reais considera ambientes parcialmente observáveis, onde o agente deve maximizar sua utilidade baseado nas informações existentes que correspondem possivelmente a apenas uma visão parcial de todo o ambiente.

### 3.2 SISTEMAS MULTIAGENTES (SMA)

Apesar de um agente poder atuar isoladamente, na maioria dos casos interage com outros agentes que estão presentes no ambiente. Quando isso ocorre, tem-se um sistema multiagente (SMA). Por meio das habilidades de cooperação e coordenação, aliadas ao poder de comunicação bem definidos, o objetivo principal do sistema poderá ser atingido (JENNINGS, 1996).

Em um SMA os agentes são capazes de interagir e trocar conhecimento, além de reconhecer as modificações do ambiente onde estão inseridos. Wooldridge (2002) define que para um agente ser considerado inteligente, ele deve conter as seguintes habilidades de forma a satisfazer os objetivos projetados:

- a) reatividade – os agentes devem perceber seu ambiente e responder, em tempo, as mudanças que ocorrerem;
- b) pró-atividade – os agentes devem demonstrar comportamentos objetivos por iniciativa própria;
- c) habilidade social – os agentes devem ser capazes de interagir com outros agentes (incluindo humanos).

Quanto à sua arquitetura interna, os agentes podem ser classificados de acordo com a forma de resolução de seus problemas da seguinte maneira:

- a) Agentes reativos – suas ações são provocadas pelo resultado de outra ação já realizada. Seu comportamento baseia-se no modo estímulo-resposta, que não considera a recordação de atividades realizadas anteriormente e as que serão efetuadas no futuro;

- b) Agentes cognitivos – a estes agentes estão envolvidas características, como crenças, conhecimento, desejos, intenções e obrigações. Logo, diferenciam-se por possuir atitudes e estados mentais, tendo a capacidade de compreender o funcionamento do ambiente que o cerca, vivendo em sociedade com organização, cooperação e comunicação;
- c) Agentes híbridos – mesclam características dos agentes reativos e dos agentes cognitivos.

As sociedades de agentes ainda podem ser classificadas quanto ao tipo de agentes que as compõem (homogêneos ou heterogêneos), quanto à migração de agentes (abertas ou fechadas) e quanto à presença de regras de comportamento (baseadas em leis ou não) (OLIVEIRA, 1996).

### 3.2.1 Características dos ambientes

Quando o SMA possui apenas um estado possível para uma determinada ação de um agente se diz que o ambiente é determinístico, contudo, existem ambientes onde após a ação de um agente, existe apenas uma probabilidade sobre os estados possíveis. Nesse caso, mapeia-se um par de estado e ação ( $st$ ,  $at$ ) para uma distribuição de probabilidade conforme segue  $P(st+1 | st, at)$ , e assim ocorre um ambiente estocástico. Além disso, quando o estado atual do ambiente descreve por completo o que ocorreu até aquele momento no ambiente, existe a propriedade de Markov. Nesse tipo de ambiente, um agente frequentemente não precisa possuir uma memória para tomar suas decisões.

### 3.2.2 Comunicação entre Agentes

Para um funcionamento cooperativo em uma sociedade, são necessários meios de comunicação. Estes podem ser diretos ou indiretos, e se diferem pelo fato de os agentes responsáveis pela troca de informações se conhecerem ou não.

Alem disso, é importante verificar as condições do ambiente, pois dependendo da natureza de um problema, o ambiente pode ser discreto ou contínuo. Um ambiente discreto é caracterizado por um finito numero de estados, um exemplo é o jogo de xadrez, onde o tabuleiro possui  $n$  configurações possíveis. Já um ambiente contínuo pode ter um infinito número de estados, como um robô andando por um ambiente com obstáculos.

Outra questão importante é a quantidade de informação que está disponível ao agente. O ambiente pode ser totalmente observável ou apenas parcialmente observável, que é o caso da maioria das aplicações reais.

Dentro de um ambiente, os agentes podem se comunicar de maneira direta ou utilizar uma estrutura compartilhada para esse fim. Em uma sociedade na qual a comunicação é direta, os agentes devem conhecer as identificações dos outros agentes e enviar mensagens explícitas. Esse procedimento requer a definição de um protocolo de comunicação, além de tornar a formulação do agente bem mais complexa. A comunicação indireta, normalmente, é realizada mediante uma estrutura denominada *blackboard* (CARVER; LESSER, 1994). A comunicação é mais simples porque é implícita, por intermédio de leituras e escritas a uma estrutura que toda a sociedade tem acesso.

Um exemplo típico de sistema multiagente com comunicação via *blackboard* é a aplicação de *Marketplace*, onde compradores e vendedores negociam produtos e serviços. Vendedores anunciam seu desejo de vender produtos ou serviços, submetendo ofertas para o *Marketplace*. Por outro lado, os compradores acessam esse mercado para submeter lances de compra para produtos ou serviços desejados e, simultaneamente, encontrar os vendedores que atendam às suas demandas. Uma vez que um comprador encontra um vendedor apropriado eles comunicam-se indiretamente por meio do próprio *Marketplace*, realizando propostas e contrapropostas. O *Marketplace* é aberto, isto é, agentes podem se juntar a ele ou deixá-lo quando quiserem, e inicialmente não conhecem seus parceiros de negócio.

Da mesma forma, agentes compradores e vendedores podem visitar *Marketplaces* diferentes, localizados na rede, a fim de atingir seus objetivos individuais. O padrão arquitetural *Blackboard* é uma solução natural para o problema de *Marketplaces*. *Blackboards* são os lugares comuns onde transações comerciais são conduzidas e onde produtos e serviços são negociados. *Blackboards* distintos representam

diferentes *Marketplaces* e funcionam como uma interface para troca de mensagens, utilizada na comunicação e coordenação das atividades realizadas pelos agentes. Agentes compradores e vendedores são as fontes de conhecimento que cooperam e competem no intuito de processar transações comerciais para seus donos. Os agentes leem e escrevem nos *blackboards* mensagens que encapsulam lances, ofertas, propostas ou contrapropostas. Cada servidor pode hospedar um ou mais *Marketplaces* distintos tendo, cada um deles, um componente de gerência responsável pelo fechamento e controle das transações.

## 4 MODELAGEM MULTIAGENTE DE MERCADOS FINANCEIROS

### 4.1 MERCADO FINANCEIRO NO BRASIL

Conforme citam Russel e Norvig (2004), a ciência da Economia teve início em 1776, quando o filósofo escocês Adam Smith (1723-1790) publicou *An Inquiry into the Nature and Causes of the Wealth of Nations*. Smith foi o primeiro a tratar a economia como ciência usando a ideia de que se pode considerar que as economias consistem em agentes individuais que maximizam seu próprio bem-estar econômico. A maior parte das pessoas pensa que economia trata de dinheiro, mas isso não é verdade. Na verdade, a economia estuda como as pessoas fazem escolhas que levam a resultados preferenciais. O tratamento matemático de “resultados preferenciais” ou utilidade foi normalizado primeiro por Leon Walras (1834-1910) e aperfeiçoado por Frank Ransey (1931) e, mais tarde, em 1944, por John von Neumann e Oskar Morgenstern no livro *The Theory of games and Economic Behavior* (RUSSEL; NORVIG, 2004).

No Brasil, o Sistema Financeiro Nacional (SFN) é composto por instituições responsáveis pela captação de recursos financeiros, pela distribuição e circulação de valores e pela regulação desse processo. Faz parte do subsistema normativo do SFN o Conselho Monetário Nacional (CMN), seu organismo maior, é quem define as diretrizes de atuação do sistema. Diretamente ligados a ele estão o Banco Central do Brasil, que atua como seu órgão executivo, e a Comissão de Valores Mobiliários (CVM), a qual responde pela regulamentação e fomento do mercado de valores mobiliários (de bolsa e de balcão). O Mercado de Capitais, portanto, é o segmento do mercado financeiro que realiza a distribuição de valores mobiliários, ou seja, tem o propósito de proporcionar liquidez aos títulos de emissão de empresas e viabilizar seu processo de capitalização. É constituído pelas bolsas de valores, sociedades corretoras e outras instituições financeiras autorizadas. No mercado de capitais, os principais títulos negociados são os representativos do capital de empresas, ou seja, as ações.

Uma ação é um título de renda variável, emitido por uma sociedade anônima, que representa a menor fração do capital da empresa

emite. O investidor em ações é um coproprietário da sociedade anônima da qual é acionista, participando dos seus resultados. As ações são conversíveis em dinheiro, a qualquer tempo, pela negociação em bolsas de valores. Além das ações, existem outros títulos que podem ser negociados no mercado de capitais, como o bônus de subscrição, debêntures e notas promissórias.

Para a economia do Brasil, a importância do mercado acionário é vital, já que é uma maneira bastante comum para as empresas levantarem recursos para investimento, além dos empréstimos bancários. A preferência pelo mercado de capitais é evidenciada em razão de que a captação de recursos mediante empréstimos bancários possui o ônus das altas taxas de juros e das garantias exigidas pelos bancos. Sendo assim, a abertura de capital no mercado se transforma em uma alternativa atraente. Dessa forma, as empresas abrem o capital porque, com a venda de suas ações, conseguem adquirir recursos para investir no negócio da empresa. Dessa forma, as empresas têm condições de investir em novos equipamentos, no desenvolvimento de pesquisas e no processo produtivo. Com o crescimento da empresa, o efeito imediato é um aumento na geração de emprego e renda, além do aumento nos lucros da empresa e, conseqüentemente, nos dividendos distribuídos ao acionista.

Após a abertura de capital, que representa o chamado mercado primário no Brasil, as ações podem ser negociadas livremente no mercado secundário. O mercado primário representa a primeira negociação das ações lançadas, ou seja, o mercado primário é onde a empresa efetivamente capta recursos. O mercado secundário existe para dar liquidez aos títulos emitidos no mercado primário. Quem comprou as ações no mercado primário (oferta pública) pode querer vender suas ações; facilitar esse processo é a missão do mercado secundário. De maneira geral, o mercado secundário é representado pela bolsa de valores. As bolsas de valores são associações civis, sem fins lucrativos, com ampla autonomia em sua esfera de responsabilidade. As obrigações da bolsa são: oferecer um mercado para a cotação dos títulos nelas registrados, orientar e fiscalizar os serviços prestados por seus membros e facilitar a divulgação constante de informações a respeito das empresas nela listadas. As bolsas de valores proporcionam um mercado contínuo, por intermédio de seus pregões diários. No caso da Bovespa, a Bolsa de Valores de São Paulo, o pregão é totalmente eletrônico, gerenciado por um sistema denominado Megabolsa.

Essa última característica da bolsa brasileira BMF&Bovespa é fundamental para proporcionar um cenário atraente para o desenvolvimento de sistemas utilizando agentes inteligentes. Como as transações são totalmente eletrônicas, executadas pelo sistema Megabolsa, é possível utilizar sistemas inteligentes para se comunicar com o sistema da bolsa e proporcionar um nível de segurança maior para o investidor.

#### 4.1.1 Sistema eletrônico de negociação de ações

As negociações na BMF&Bovespa são feitas da seguinte forma: uma ordem é uma autorização emitida pelo cliente para que a corretora compre ou venda determinada quantidade de um determinado ativo a determinado preço. A ordem deve ser enviada pela corretora à bolsa de valores que incluirá a ordem no chamado livro de ofertas; após ser incluída no livro de ofertas a ordem pode ser negociada se as condições estabelecidas referentes ao preço e à quantidade forem atendidas por outra(s) ordem(s) com a natureza da operação inversa (compra e venda). As ordens podem ser enviadas pelo cliente para a corretora através do *homebroker*<sup>1</sup> ou telefone. Algumas corretoras também aceitam ordens via correio eletrônico (*e-mail*) e via *chat*, em programas como o *Microsoft Messenger* (MSN) ou *Skype*.

Como visto anteriormente, o pregão da Bolsa de Valores de São Paulo é totalmente eletrônico. As ordens são registradas em livros de ofertas e o sistema Megabolsa se encarrega de fechar os negócios e avisar os compradores e vendedores sobre cada negociação. Na Imagem 1 é mostrado um exemplo de um livro de ofertas, nele são listadas todas as ordens de compra (lado esquerdo) e todas as ordens de venda (lado direito). As informações listadas no livro de ofertas são o preço, a quantidade e a corretora responsável. O sistema sempre dá preferência às ordens de compra com maior valor (mais caras) e para as ordens de venda com menor valor (mais baratas). No caso de ordens de mesmo valor, a referência cronológica define quem terá preferência.

---

<sup>1</sup> O *Home Broker* é o instrumento que permite a negociação de ações via internet. Ele permite que sejam enviadas as ordens de compra e venda de ações através do *site* da corretora na internet.

Lista de Ofertas PRGA3					
Corretora	Compra		Venda		Corretora
	Quant.	Preço	Preço	Quant.	
SLW	800	35,66	35,79	2.20 K	CSFB
GRADUAL	900	35,66	35,80	1,50 K	ÁGORA-SENIOR
SPINELLI	1,80 K	35,65	35,80	500	SOCOPA
BRASCAN	5 K	35,65	35,80	100	ÁGORA-SENIOR
BRASCAN	5 K	35,62	35,99	600	SOLIDEZ
LINK	1,60 K	35,51	36,00	100	BANIF PRIMUS
LINK	1,60 K	35,50	36,00	1 K	MORGAN STANLEY
LINK	1,60 K	35,50	36,00	400	ÁGORA-SENIOR
ÁGORA-SENIOR	100	35,50	36,08	1,20 K	CSFB

Imagem 1: Livro de ofertas da Perdigão (PRGA3)

Fonte: Um Investimentos (2009).

Cada empresa pode ter uma ou mais ações sendo negociadas no sistema eletrônico Megabolsa da Bovespa. As empresas podem ter ações ordinárias e preferenciais. Ações ordinárias ou Ordinárias Nominativas (ON) permitem ao acionista a participação nos resultados da empresa e conferem ao acionista o direito de voto em assembleias gerais. Já as ações preferenciais ou Preferenciais Nominativas (PN), garantem ao acionista a prioridade no recebimento de dividendos, geralmente em percentual mais elevado do que o atribuído às ações ordinárias, além de dar prioridade no reembolso de capital, no caso de dissolução da sociedade.

Cada ação negociada no sistema megabolsa possui um código. O código possui dois componentes, o primeiro é o código da empresa composto por quatro letras. O segundo componente é um número que especifica o tipo da ação. Como exemplo, há a ação preferencial da Petrobras com o código PETR3, as quatro primeiras letras “PETR” são o código da empresa, a empresa deve escolher esse código quando lançar suas primeiras ações na bolsa (IPO), o número 3 corresponde ao tipo da ação, no caso, ação ordinária. Para PETR4, há a ação preferencial da Petrobrás, o número 4 identifica a ação preferencial. Ações preferenciais classe A são identificadas pelo código 5, as ações preferenciais classe B pelo código 6 e, assim, sucessivamente. Na Imagem 2 podem ser percebidos os códigos das ações mais negociadas da bolsa. Essas ações fazem parte do índice Bovespa. O código “ED” que aparece em algumas ações no campo “Tipo” significa que a ação já está “ex-dividendos”.

Algumas empresas possuem somente um tipo de ação sendo negociada na bolsa. Nesse caso, a ação é, obrigatoriamente, do tipo ON (Ordinária Nominativa) e dá direito a voto ao acionista que a detém. Contudo, existem empresas que possuem ações ON e também PN (Preferenciais Nominativas) sendo negociadas. Nesse caso, cada ação terá um código e um livro de negociação diferente.

A empresa Vale, por exemplo, possui ações ordinárias negociadas com o código de negociação VALE3 e ações preferenciais negociadas com o código VALE5. No sistema megabolsa existe um livro de ofertas para cada uma delas. O mesmo ocorre com as ações da Petrobrás, a maior empresa em valor de mercado dentro da bolsa brasileira. A Petrobrás possui ações ordinárias negociadas com o código de negociação PETR3 e ações preferenciais negociadas com o código PETR4, cada uma delas possui um livro de ofertas separado.

Código	Empresa	Código	Empresa	Código	Empresa
ACES4	ACESITA	CYRE3	CYRELA REALT	PRGA3	PERDIGAO S/A
ALLL11	ALL AMER LAT	DURA4	DURATEX	PETR3	PETROBRAS
AMBV4	AMBEV	ELET3	ELETROBRAS	PETR4	PETROBRAS
ARCZ6	ARACRUZ	ELET6	ELETROBRAS	SBSP3	SABESP
BTOW3	BZW VAREJO	ELPL6	ELETROPAULO	SDIA4	SADIA S/A
BBDC4	BRADESCO	EMBR3	EMBRAER	CSNA3	SID NACIONAL
BRAP4	BRADESPAR	GFA3	GAFISA	CRUZ3	SOUZA CRUZ
BBAS3	BRASIL	GGBR4	GERDAU	TAMM4	TAM S/A
BRTP3	BRASIL T PAR	GOAU4	GERDAU MET	TNLP3	TELEMAR
BRTP4	BRASIL T PAR	GOLL4	GOL	TNLP4	TELEMAR
BRTO4	BRASIL TELEC	PTIP4	IPIRANGA PET	TMAR5	TELEMAR N L
BRKM5	BRASKEM	ITAU4	ITAUBANCO	TMCP4	TELEMIG PART
CCRO3	CCR RODOVIAS	ITSA4	ITAUSA	TLPP4	TELESP
CLSC6	CELESC	KLBN4	KLABIN S/A	TCSL3	TIM PART S/A
CMIG4	CEMIG	LIGT3	LIGHT S/A	TCSL4	TIM PART S/A
CESP6	CESP	LAME4	LOJAS AMERIC	TRPL4	TRAN PAULIST
CGAS5	COMGAS	LREN3	LOJAS RENNER	UBBR11	UNIBANCO
CPL6	COPEL	NATU3	NATURA	USIM5	USIMINAS
CSAN3	COSAN	NETC4	NET	VCPA4	V C P
CPFE3	CPFL ENERGIA	BNCA3	NOSSA CAIXA	VALE3	VALE R DOCE
CCPR3	CYRE COM-CCP	PCAR4	P.ACUCAR-CBD	VALE5	VALE R DOCE
				VIVO4	VIVO

Imagem 2: Códigos das ações mais negociadas na BMF&Bovespa

Fonte: Bovespa (2009).

A partir das ordens de compra e venda, incluídas no livro de ofertas, os negócios são fechados. A cotação da ação corresponde ao preço do último negócio fechado. Assim, o preço se forma a partir da oferta e demanda da ação que é materializada nas ordens do livro de ofertas. No longo prazo, é fato que o preço da ação reflete os fundamentos da empresa, ou seja, a saúde financeira do negócio da

empresa que gera o lucro. Contudo, existem períodos em que mesmo sem mudanças nos fundamentos da empresa, o preço da ação sofre alta variação. Nesse caso, o preço está sendo influenciado pela oferta e demanda momentânea que fazem o preço se comportar de maneira não esperada pelos analistas.

Outro ponto importante a ser observado é a questão da liquidez de uma ação. Um dos grandes riscos envolvidos nas operações do mercado de capitais é o risco de liquidez, ou seja, o risco de não encontrar compradores na hora de vender uma ação. A configuração do livro de ofertas da Imagem 3 é característica de uma ação sem liquidez. Perceba a grande diferença entre a melhor oferta de compra (R\$ 50,00) e a melhor oferta de venda (R\$ 58,00). Nesse caso, para o investidor comprar um lote dessas ações, deverá desembolsar R\$ 58,00 por ação. Se for necessário vender essas ações logo em seguida encontrará compradores pagando apenas R\$ 50,00 por ação, uma diferença de 16%. Isso não ocorre com ações de alta liquidez, onde se encontram ofertas de compra e venda com preços muito próximos.

Lista de Ofertas PNVL3						
Corretora	Compra			Venda		Corretora
	Quant.	Preço	Preço	Quant.		
INTRA	100	50,00	58,00	100		INTRA
GRADUAL	100	48,00	50,00	600		ITAÚ
DIFERENCIAL	100	45,00	59,89	100		BRADESCO
				1 K		FATOR DÓRIA
			70,70	100		BRADESCO

Última atualização

Imagem 3: Livro de ofertas de uma ação sem liquidez

Fonte: Um Investimentos (2009).

Para efetivar as transações lançando ordens de compra e venda, a BMF&Bovespa disponibiliza sistemas clientes de acesso ao Megabolsa. Assim como os sistemas de *homebanking* permitem o gerenciamento da conta do cliente na instituição bancária, os sistemas de *homebroker* permitem o gerenciamento da conta do cliente dentro das corretoras de valores ligadas à BMF&Bovespa. As funções básicas desses sistemas são: o acompanhamento da carteira de ações, o acompanhamento do saldo das contas, o envio *on-line* de ordens de compra e venda e a confirmação *on-line* de ordens executadas. Contudo, os *homebrokers*

variam em forma e funcionalidade de corretora para corretora, e podem incluir acesso a cotações *on-line*, notícias, análises e gráficos. Vale lembrar que apenas corretoras autorizadas podem visualizar e operar no sistema Megabolsa da BMF&Bovespa.

Por fim, conforme supracitado, o sistema Megabolsa da BMF&Bovespa utiliza um livro de ofertas para negociação de cada tipo de ação, nesse sentido, o livro de ofertas é um sistema que se encaixa perfeitamente no modelo de sistema multiagente com comunicação via *blackboard*, descrito anteriormente. O livro de ofertas é o próprio *blackboard* e os agentes são os compradores e vendedores que inserem ordens de compra e venda dentro do livro.

#### 4.1.2 Índice Bovespa

Índices de ações são carteiras teóricas que geralmente englobam as ações mais negociadas do mercado que representam. Existem inúmeros índices que traduzem a evolução dos vários mercados internacionais, entre os quais se podem citar o Dow Jones, SP500 e Nasdaq dos EUA, o CAC da França, o FTSE do Reino Unido, o DAX da Alemanha, o Nikkei do Japão e o Hang Seng de Hong Kong.

O Índice Bovespa é o mais importante indicador do desempenho médio das cotações do mercado de ações brasileiro. O Ibovespa ou Ibov, como também é chamado, retrata o comportamento dos principais papéis negociados na Bovespa. O índice manteve a integridade de sua série histórica e não sofreu modificações metodológicas desde sua implementação em 1968.

O índice Bovespa é recalculado a cada 4 meses. Para o quadrimestre que vai de setembro a dezembro de 2009 existem 65 ações no índice (BOVESPA, 2009), que são selecionadas baseadas no critério da liquidez, ou seja, quanto mais negociada, maiores são as chances de a ação estar presente no índice. O Ibovespa é recalculado a cada quatro meses e considera as movimentações dos últimos doze meses. Além disso, cada papel precisa apresentar participação, em termos de volume, superior a 0,1% do total do período, e ter sido negociado em mais de 80% do total de pregões do período. A metodologia completa do cálculo do Índice Bovespa encontra-se anexa neste trabalho.

O principal objetivo do Índice Bovespa é servir como indicador médio do comportamento do mercado. Para tanto, sua composição procura aproximar-se o máximo possível da real configuração das negociações à vista (lote-padrão) na Bovespa. As ações da carteira teórica do Índice Bovespa respondem por mais de 80% do número de negócios e do volume financeiro verificados no mercado à vista.

Vale lembrar que este índice leva em conta somente a quantidade de negócios e o volume financeiro negociado das ações, não analisando a saúde financeira da empresa.

Outro ponto importante é que cada ação, que faz parte do indicador, tem calculado seu índice de negociabilidade, o IN, que é calculado por meio da seguinte fórmula:

$$in = \sqrt{\frac{ni}{N} * \frac{vi}{V}} \quad (8)$$

Onde  $ni$  é o número de negócios da ação nos últimos 12 meses,  $N$  é o número de negócios de toda a bolsa de valores nos últimos 12 meses,  $vi$  é o volume em moeda oficial gerado pelos negócios da ação nos últimos 12 meses e  $V$  é o volume em moeda oficial gerado pelos negócios de toda a bolsa de valores nos últimos 12 meses.

Por fim, o índice de negociabilidade ( $in$ ) é usado como peso na média ponderada que cria o índice Bovespa. Veja no Gráfico 1, e no Quadro 1, a seguir, quais são os pesos de ponderação dos principais ativos do Ibovespa.

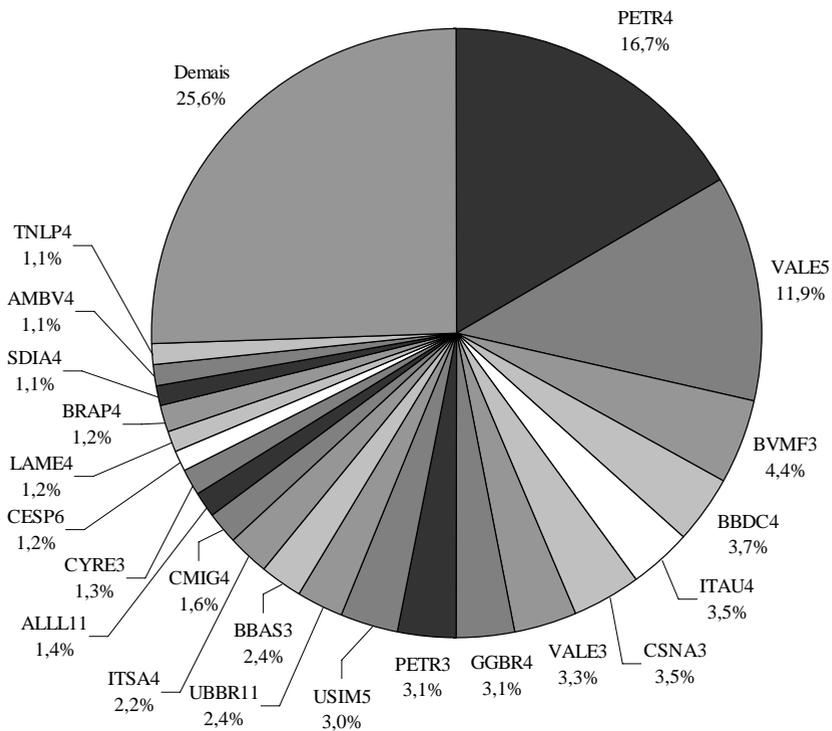


Gráfico 1: Ações que fazem parte do Índice Bovespa com os respectivos pesos de ponderação

Fonte: Bovespa 2009.

Código	Ação	Part.(%)			
ALLL11	ALL AMER LAT	1,42	KLBN4	KLABIN S/A	0,355
AMBV4	AMBEV	1,12	LIGT3	LIGHTS S/A	0,20
ARCZ6	ARACRUZ	0,78	LAME4	LOJAS AMERIC	1,20
BTOW3	BZW VAREJO	0,90	LRN3	LOJAS RENNER	0,86
BVMF3	BMF BOVESPA	4,36	NATU3	NATURA	0,64
BBDC4	BRADES CO	3,70	NETC4	NET	0,95
BRAP4	BRADES PAR	1,20	BNCA3	NOSSA CAIXA	0,40
BBAS3	BRASIL	2,40	PCAR4	P.ACUCAR-CBD	0,55
B RTP3	BRASIL TPAR	0,28	PRGA3	PERDIGAO S/A	0,89
B RTP4	BRASIL TPAR	0,44	PETR3	PETROBRAS	3,06
BRT04	BRASIL TELEC	0,42	PETR4	PETROBRAS	16,72
BRKM5	BRASKEM	0,55	RDCD3	REDECARD	0,93
CCRO3	CCR RODOVIAS	0,61	RSID3	ROSSI RESID	0,57
CLSC6	CELESC	0,12	SBSP3	SABESP	0,40
CMIG4	CEMIG	1,64	SDIA4	SADIA S/A	1,14
CESP6	CES P	1,22	CSNA3	SID NACIONAL	3,45
CGAS5	COMGAS	0,11	CRUZ3	SOUZA CRUZ	0,49
CPL6	COPEL	0,65	TAMM4	TAM S/A	0,71
CSAN3	COSAN	0,60	TNLP3	TELEMAR	0,42
CPFE3	CPFL ENERGIA	0,52	TNLP4	TELEMAR	1,09
CYRE3	CYRELA REALT	1,26	TMAR5	TELEMAR N L	0,30
DURA4	DURATEX	0,55	TLPP4	TELES P	0,19
ELET3	ELETROBRAS	0,95	TCSL3	TIM PARTS /A	0,20
ELET6	ELETROBRAS	0,95	TCSL4	TIM PARTS /A	0,76
ELPL6	ELETROPAULO	0,69	TRPL4	TRAN PAULIS T	0,37
EMBR3	EMBRAER	0,66	UGPA4	ULTRAPAR	0,44
GFA3	GAFISA	0,93	UBBR11	UNIBANCO	2,42
GGBR4	GERDAU	3,10	USIM3	USIMINAS	0,62
GOAU4	GERDAU MET	0,92	USIM5	USIMINAS	3,05
GOLL4	GOL	0,74	VCPA4	V C P	0,62
ITAU4	ITAUBANCO	3,47	VALE3	VALE R DOCE	3,27
ITSA4	ITAUSA	2,24	VALE5	VALE R DOCE	11,88
JBS3	JBS	0,66	VIVO4	VIVO	0,72
			Total		100,00

Quadro 1: Ações que fazem parte do Índice Bovespa com os respectivos pesos  
Fonte: Bovespa (2009).

## 4.2 TEORIA DOS MERCADOS EFICIENTES

No mundo das finanças, a Teoria dos Mercados Eficientes (TME) afirma que todos os agentes financeiros são racionais e têm, ao mesmo

tempo, o mesmo conjunto de informações disponível, ou seja, as informações e expectativas se refletem sempre corretamente e imediatamente nos preços dos ativos (FAMA, 1970, 1991).

De acordo com essa teoria, a flutuação do preço de ações e ativos financeiros é aleatória; a melhor previsão possível para o dia de amanhã é o preço de hoje, e não existiriam distorções nos preços de ativos, já que os preços refletem todas as variáveis disponíveis. Sendo assim, não existem maneiras de proteger o investidor prevendo os futuros movimentos do mercado e nenhum investidor seria capaz de obter rendimentos acima da média de mercado ou de proteger seu patrimônio aplicado de possíveis crises financeiras. No entanto, não existe consenso a respeito dessa teoria (MALKEI, 1999) e várias iniciativas empíricas têm demonstrado que a afirmação da TME não é totalmente correta (FARMER; LO, 1996; KALYVAS, 2001; KUTSURELIS, 1998; SANTOS, 2005).

Primeiramente, é difícil definir o conceito de racionalidade para os agentes financeiros do sistema, outro ponto é, apesar da velocidade com que a informação trafega em virtude da tecnologia atual, ainda assim é quase certo que alguns agentes conseguem obter com mais tempestividade do que outros certos tipos de informação.

Partindo do princípio de que os mercados não são eficientes, há a possibilidade de tentar prever os futuros comportamentos dos preços. O primeiro a citar a previsibilidade dos mercados financeiros foi Charles Henry Dow (1851-1902), jornalista americano que no início do século XX juntamente com Edward D. Jones fundou o *The Wall Street Journal* (MURPHY, 1999). Nos editoriais do jornal, Dow apresentava suas observações a respeito do comportamento dos preços do mercado. Uma delas afirma que os mercados se movem em tendências de alta ou de baixa, contrariando mais uma vez a Teoria dos Mercados Eficientes.

Existem basicamente duas grandes áreas de pesquisa que, contrariando a TME, buscam prever a futura direção dos movimentos. A primeira tem um ponto de vista econométrico, que tenta prever movimentos por meio de métodos matemáticos e estatísticos, como a regressão linear univariada, como os modelos Arima (*autoregressive integrated moving average*), além de métodos de regressão multivariada. Ainda, dentro da área econométrica, destacam-se os métodos de regressão não linear, como as redes neurais (PODDIG, 2000) e sistemas *fuzzy*.

A segunda grande área de pesquisa é mais recente. Trata-se da Teoria Multiagente de Modelagem de Mercado (*Theory of Multi-Agent Market Modeling*) que foca na microestrutura do mercado partindo do princípio de que os movimentos de preços emergem da interação de muitos agentes individuais do mercado (BAR-YAM, 1997 apud GROTHMANN, 2002). Esse modelo será abordado adiante com detalhes.

#### 4.3 PREVISÃO DO MERCADO DE AÇÕES

Prever o futuro caminho dos preços é uma tarefa que divide opiniões no mundo acadêmico. Existe um grupo que acredita que o mercado não pode ser previsto porque a cada nova informação que aparece imediatamente corrige os preços, não dando espaço para aproveitar o movimento. É a teoria dos mercados eficientes, contudo, existe um grupo que acredita na possibilidade de capturar informações no mercado que podem ajudar a prever o futuro direcionamento dos preços.

Do ponto de vista econométrico, muitos métodos estão presentes na literatura visando prever o futuro comportamento dos preços. Esses métodos podem ser divididos em quatro grandes categorias: análise fundamentalista, análise técnica, previsão de séries temporais tradicionais e métodos de aprendizagem de máquina.

A análise fundamentalista busca avaliar o preço justo de uma ação. O preço justo está relacionado com a capacidade da empresa de gerar lucros no futuro. Sendo assim, a análise fundamentalista busca avaliar conjunturas macro e microeconômicas, características setoriais da empresa, demonstrações financeiras e balanços da companhia para estabelecer o valor justo para uma ação. O valor justo é apurado, normalmente, mediante o cálculo em valor presente do fluxo de caixa futuro da empresa. Depois de estabelecido o valor justo de cada ação, é possível prever se o preço deve subir ou cair em relação ao preço atual.

A análise técnica é o estudo dos comportamentos dos preços do mercado. Como toda a oferta e demanda sobre os ativos é materializada nos preços dos gráficos, pode-se inferir que a análise técnica busca avaliar a oferta e demanda do mercado sobre determinado ativo. Segundo Murphy (1999), a análise técnica é o estudo dos preços e

volumes do mercado, principalmente através do uso de gráficos, visando prever as tendências futuras de preços. As origens da análise técnica moderna estão ligadas aos trabalhos de Charles Henry Dow (1851-1902). Além disso, é mérito de Charles Dow a criação dos índices de ações, incluindo o mais famoso do mundo, o Índice Dow Jones, da Bolsa de Valores de Nova York (NYSE).<sup>2</sup>

A previsão de séries temporais tradicional é baseada na regressão linear para reconhecer padrões no histórico de preços que antecipam movimentos, ou seja, prever futuros valores a partir de valores passados. Os modelos lineares são divididos em modelos de regressão univariada e modelos de regressão multivariada que usam uma ou mais variáveis para prever as séries de preços.

Por fim, há, também, a aprendizagem de máquina, que engloba vários métodos que usam um conjunto de exemplos de dados para traçar padrões de maneira linear ou não linear tentando aproximar a função que gerou os dados, entre eles as redes neurais e os sistemas nebulosos (*fuzzy systems*). Apesar de ser um dos modelos mais promissores e de vários trabalhos apontarem para a superioridade das redes neurais aplicadas a séries temporais financeiras, em relação a outras abordagens lineares (SANTOS, 2005), deve ser ressaltado que a qualidade da informação disponível para treinamento é crucial para o sucesso deste modelo, pois as séries financeiras são frequentemente influenciadas por ruídos e influências externas que mudam o movimento natural dos preços, como notícias e desastres naturais (NEUNEIER, 1998 apud GROTHMANN, 2002). Além disso, redes neurais possuem o problema de *overfitting* (HAYKIN, 2001), que ocasiona à rede neural a perda de suas habilidades de generalização, devido ao fato dela incorporar o ruído da série.

#### 4.4 MODELAGEM MULTIAGENTE DE MERCADOS FINANCEIROS

A modelagem de mercados financeiros e outros fenômenos sociais baseada em sistemas multiagentes têm atraído a atenção de muitos pesquisadores nos últimos anos (GALLA; MOSETTI, ZHANG,

---

<sup>2</sup> NYSE: *New York Stock Exchange*. Bolsa de Valores de Nova York.

2006; GUPTA; JOHNSON; HAUSER, 2001; GROTHMANN, 2002; ARAÚJO, 2004). A quantidade de fenômenos que podem ser estudados com esse tipo de modelagem é enorme, incluindo estudos sobre crescimento de epidemias, tráfego de veículos ou pedestres e investidores na bolsa de valores. A modelagem dos indivíduos que compõem os sistemas permite artificialmente representar um investidor no mercado de ações, uma empresa em negociações com fornecedores ou um veículo em uma rodovia. Depois de modelar os aspectos microeconômicos dos indivíduos, é possível determinar o aspecto macroeconômico de todo o sistema.

É interessante observar que os modelos multiagentes de mercados são uma alternativa à Teoria dos Mercados Eficientes (FAMA, 1970, 1991), e esta complementação dos sistemas multiagentes era necessária, já que nos mercados reais, empiricamente, é possível afirmar que a eficiência do mercado é frequentemente quebrada (FARMER; LO, 1996). Para entender essa afirmação, basta citar algumas premissas da teoria de mercados eficientes, uma delas é a de que os investidores são racionais, sempre dispostos a se esforçar ao máximo para aumentar os ganhos e diminuir as perdas. O primeiro problema, em relação a isso, é definir o que é racionalidade. Além do mais, a mídia demonstra, frequentemente, casos de empresas que assumem riscos maiores no mercado para alcançar mais lucros e, acabam tendo grande prejuízo. Recentemente houve, em 2008 os casos das empresas, como Sadia, Aracruz e Votorantim Celulose e Papel (VCP), com prejuízos bilionários referentes a perdas sobre apostas que não deveriam ter sido feitas no mercado financeiro. Outro ponto da Teoria dos Mercados Eficientes afirma que todos os agentes financeiros têm o mesmo conjunto de informações disponível ao mesmo tempo e que, assim, as informações e expectativas se refletem corretamente e imediatamente nos preços dos ativos. Desse modo, não existiriam distorções nos preços de ativos, já que os preços refletem todas as variáveis disponíveis, e nenhum investidor seria capaz de obter rendimentos acima da média de mercado (IGF, 2009).

Contudo, mais uma vez, observações empíricas, tendem a confirmar que o mercado não age de forma eficiente, primeiro porque as informações não chegam ao mesmo tempo para todos, todavia, mesmo que chegassem, a interpretação que cada agente tem em relação ao conjunto de informações disponível pode ser completamente diferente. Podem-se citar inúmeros casos onde notícias que eram aparentemente

sinais de alta nos preços acabaram não se mostrando corretas no mercado. Por exemplo, as ações da Petrobrás, uma semana depois do anúncio da notícia da descoberta das reservas de petróleo pré-sal caíram bem abaixo do patamar de preços anterior à notícia. Outro exemplo foi o anúncio da fusão entre as empresas Sadia e Perdigão, que formou a maior empresa do setor de aves no mundo; a notícia aparentemente era ótima, mas as ações da Sadia caíram -5,05% e as da Perdigão -6,36% no dia do anúncio.

Nesse sentido, a abordagem de sistemas multiagentes aproxima-se muito mais da dinâmica dos mercados financeiros reais já que é capaz de “[...] capturar a complexidade e a dinâmica do comportamento e aprendizagem nos mercados financeiros usando modelos de mercados, estratégias e estruturas mais realistas.”<sup>3</sup> (FARMER; LO, 1996 apud GROTHMANN, 2002). Desse modo, a modelagem multiagente permite uma abordagem mais ampla do que a oferecida pela teoria dos mercados eficientes (FARMER; LO, 1996).

Contudo, esses modelos financeiros baseados em sistemas multiagentes têm algumas limitações. Não existe uma especificação semântica dos agentes (GROTHMANN, 2002) e, na maioria dos modelos, a tomada de decisão é feita por meio de funções *ad-hoc* (CHALLET; ZHANG, 1997), ou de mecanismos que não podem ser ajustados a dados externos. Como exemplo, podem-se citar os modelos baseados no Minority Game (MG) (CHALLET; ZHANG, 1997) que baseia as decisões de compra ou venda em uma tabela de valores binários que é sorteada de maneira aleatória inicialmente. A tabela possui um número fixo de estratégias, sendo que cada estratégia possui valores que representam as últimas N iterações do sistema, além da ação de compra ou venda a ser tomada. Dessa forma, os agentes escolhem uma estratégia baseada nesta tabela fixa e remuneram as estratégias com pontuação positiva ou negativa, dependendo do resultado da escolha, em um processo de aprendizado por reforço. Esse nível de racionalidade e tomada de decisão não condiz com a realidade de um mercado financeiro real, além de não ser possível treinar os agentes baseados em dados reais do mercado.

---

<sup>3</sup> “[...] to capture complex learning behavior and dynamics in financial markets using more realistic markets, strategies, and information structures” (FARMER, 1996 apud GROTHMANN, 2002, tradução nossa).

Assim, tais modelos geram apenas resultados qualitativos que são úteis na explicação do complexo fenômeno econômico dos mercados, mas não podem ser aplicados para previsões reais. Para obter uma previsão real do modelo, é preciso adaptar o mecanismo de decisão dos agentes com modelos econométricos, como regressão linear univariada ou multivariada, ou, ainda, com modelos de regressão não linear, como as redes neurais, que podem ser ajustados a séries de dados reais (GROTHMANN, 2002). Sendo assim, acredita-se que, por intermédio da interação dos agentes, o modelo de mercado resultante pode capturar a dinâmica oculta do mercado e prever os movimentos futuros com uma eficácia maior do que faria um sistema de regressão não linear isoladamente.

Em resumo, a grande vantagem da modelagem com sistemas multiagentes é conseguir obter a dinâmica do mercado financeiro real a partir da perspectiva dos indivíduos, ou seja, mediante a interação entre os indivíduos (agentes) (GROTHMANN, 2002). Na modelagem baseada em agentes, a estrutura do sistema é modelada de baixo para cima, ou seja, primeiro é definido o comportamento e o modelo de decisão de cada agente do sistema, após, as decisões tomadas pelos agentes, que são as ordens de compra e venda, conforme visto no início desta seção, são coletadas para gerar a dinâmica do mercado como um todo. Portanto, o nível microeconômico é definido antes dentro de cada agente para que depois as interações entre os agentes gerem os aspectos macroeconômicos do sistema.

Grothmann (2002) cita alguns exemplos de modelagem de mercados financeiros baseados em sistemas multiagentes que ajudam a explicar fenômenos complexos, como bolhas de preço e crises.

#### **4.4.1 Simulação de crises e bolhas de preços por meio de sistemas multiagentes**

Muitos autores já realizaram estudos sobre crises econômicas e bolhas de preço utilizando sistemas multiagentes como, por exemplo, Steiglitz e Callaghan (1997), Levy, Levy e Solomon (1994) e Kaizoji (2000).

O modelo de Steiglitz e Callaghan (1997) descreve uma economia artificial de duas *commodities*, ouro e comida. A comunidade

de agentes possui três tipos diferentes de indivíduos: agentes regulares, que não têm inteligência e só produzem e consomem; agentes fundamentalistas, que baseiam suas decisões em previsão de variáveis fundamentais e agentes técnicos, que acompanham a tendência do mercado. O autor mostra que utilizando variáveis fundamentalistas exógenas, a interação entre os agentes cria bolhas inflacionárias e o estouro da bolha causa crises deflacionárias.

O modelo de Levy, Levy e Solomon (1994) utiliza agentes heterogêneos que diferem entre si, devido a seus tamanhos de memória e, também, devido a um fator psicológico desconhecido, que é simulado por uma variável randômica  $\varepsilon$  com desvio padrão  $\sigma_\varepsilon$ . Esses agentes tentam maximizar sua função de utilidade por meio de duas opções de investimentos: um investimento em ações pagando dividendos  $D$  e outra opção com risco baixo pagando juros de renda fixa. O autor descobriu que se os agentes forem muito parecidos, ou seja, se a variável  $\varepsilon$  é pequena, as crises tendem a aparecer. Além disso, a taxa do dividendo (lucro da empresa distribuído para o acionista) sobre o preço da ação é um grande indicador do comportamento do mercado, por exemplo, quando o indicador *dividend yield*<sup>4</sup> é relativamente baixo há um sinal de que uma forte queda nos preços deve ocorrer.

O autor ainda descobriu que, se os agentes são mais heterogêneos na tomada de decisão, as bolhas e crises tendem a ser menores e a probabilidade de uma crise ocorrer é bem menor. Finalmente, o autor conclui que a interação entre os agentes artificiais é similar ao comportamento do mercado real e que o comportamento dos agentes é condizente com as opiniões dos economistas sobre o que ocorre com o mercado real.

Os modelos descritos servem para obter resultados qualitativos das propriedades dos mercados financeiros, dando uma explicação dos fenômenos que acontecem. Contudo, resultados quantitativos, como a previsão do valor futuro dos preços não é o objetivo desses modelos, que não permitem obter tais resultados.

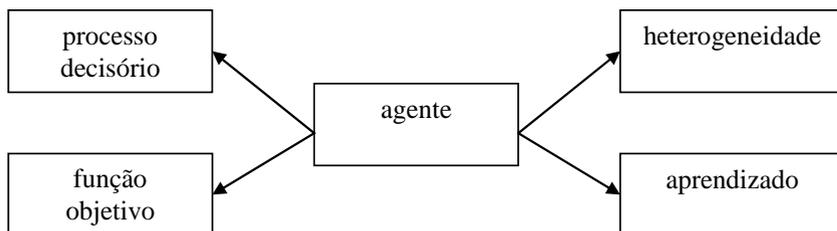
---

<sup>4</sup> *Dividend Yield*: Parte do preço da ação pago em forma de dividendo. Fórmula: Dividendo por Ação/Preço da Ação.

#### 4.4.2 Características dos agentes para modelagem de mercados financeiros

Segundo Grothmann (2002), o aspecto mais importante de um sistema multiagente que modela um mercado financeiro é o projeto dos próprios agentes. Grothmann (2002) também cita que os agentes podem variar entre um agente completamente sem inteligência, como no modelo de Gode and Sunder (GODE; SUNDER, 1993 apud GROTHMANN, 2002), que envia as ordens de compra e venda baseadas em uma decisão aleatória, até agentes bem sofisticados, como no modelo de mercado de ações artificial Santa Fé (LAP99 e LAHP97 apud GROTHMANN, 2002), que adapta suas próprias estratégias e as evolui mediante algoritmos genéticos.

Grothmann (2002) cita quatro aspectos importantes relacionados à modelagem de agentes para o mercado financeiro, conforme visto no Organograma 1.



Organograma 1: Aspectos do projeto de agentes no nível microeconômico  
Fonte: Grothmann (2002).

##### 4.4.2.1 Processo decisório

Na maioria dos modelos existentes, incluindo os trabalhos de Bak, Paczusi e Shubik (1996), Ciarella e He (2001), Steiglitz e Callaghan (1997), Farmer (1998), Youssefmir e Huberman (1995) e Lux (1998), os tipos de agentes introduzidos nos modelos são divididos em duas categorias: agentes técnicos e fundamentalistas. Os agentes

técnicos utilizam o histórico de preços e volumes de negociação dos ativos, incluindo cálculos de indicadores técnicos, para tomar as decisões. Já os fundamentalistas utilizam os valores atuais da ação, comparados com a expectativa do valor do fundamento econômico da empresa, como os lucros ou a expectativa de dividendos para tomar as decisões.

Mais especificamente, o processo decisório pode ser baseado em regras (*rule based*) ou, ainda, baseado em modelos de previsões (*forecast models*) (GROTHMANN, 2002).

### *Agentes baseados em regras*

Os agentes baseados em regras capturam os dados do mercado e, diretamente, por intermédio de uma fórmula matemática decidem se vão comprar ou vender no mercado. Um agente baseado em regras pode tomar as decisões baseado em dados de entrada fundamentalistas, assim, será um agente fundamentalista, pode tomar as decisões por meio do histórico de preços do mercado, utilizando, por exemplo, uma estratégia de seguir a tendência dos preços e, assim, será um agente técnico.

Nos dois casos, os agentes podem ter suas regras fixas ou, ainda, evoluir as regras no decorrer do tempo, sendo considerados agentes baseados em regras dinâmicas. No caso de regras dinâmicas, normalmente, para dar a característica de dinamismos, os projetistas utilizam técnicas de aprendizado evolutivo (LEBARON, 2001 apud GROTHMANN, 2002). Um exemplo desses agentes são os do modelo de mercado de ações artificial Santa Fé, onde as regras que são ativadas quando o mercado está em tendência são diferentes das regras ativadas quando o mercado está estável. Para saber o estado atual do mercado, os agentes utilizam variáveis fundamentalistas e indicadores técnicos.

### *Agentes baseados em modelos de previsão*

Outra maneira possível de incluir um esquema de decisão nos agentes é incluir no agente um modelo de previsão dos preços. Normalmente, o esquema possui dois passos: primeiro o modelo de

previsão define o valor futuro dos preços, depois, essa previsão é utilizada por uma função objetivo ou por uma regra adicional de decisão para compra ou venda.

Portanto, ao invés de deduzir a ação de compra ou venda diretamente da entrada de dados, como fazem os agentes baseados em regras, os agentes baseados em modelos de previsão utilizam a entrada de dados para criar um modelo de previsão dos preços.

Ainda dentro dos agentes baseados em modelos de previsão, podem-se dividir os agentes que utilizam modelos econométricos, como regressão linear univariada ou multivariada e os agentes que utilizam modelos de previsão baseados em sistemas cognitivos, como Beltratti, margarita e Terna (1996), que utilizaram antes, com modelos de redes neurais *feedforward* com três camadas, e Yang (1999), que utilizou redes recorrentes de Elman com três tipos de agentes diferentes: agentes fundamentalistas, agentes de momento e agentes de ruído (*noise traders*), sendo os dois últimos agentes que utilizam indicadores técnicos.

#### 4.4.2.2 Função Objetivo

É uma característica primordial do processo decisório do agente, já que o modelo de previsão do preço pode indicar a direção futura dos preços, mas não indica as ações concretas a serem tomadas como comprar, vender ou esperar mais algum tempo. As funções objetivo podem ser divididas em função de maximização de lucro, que visa apenas lucrar o máximo possível, ou, ainda, função de maximização de utilidade, que visa além do lucro, acompanhar outros aspectos, como o gerenciamento do risco das operações.

#### 4.4.2.3 Heterogeneidade

As diferenças entre os agentes são importantes, pois já foi confirmado que, em mercados onde os agentes são homogêneos, a volatilidade é muito grande e isso não condiz com o mercado real. Quando os preços estão subindo, alguns agentes podem comprar

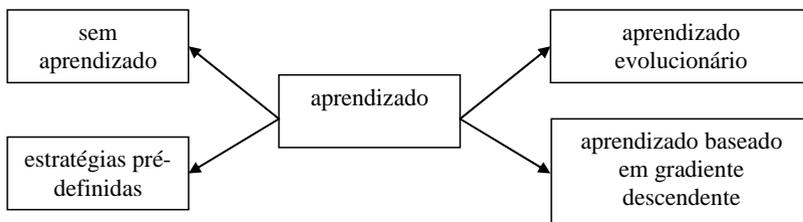
achando que é uma tendência de alta e alguns agentes podem vender, achando que os preços já subiram demais.

Segundo Grothmann (2002), o que torna os agentes heterogêneos, basicamente, pode ser dividido em quatro categorias:

- a) base de informações – alguns agentes podem utilizar informações fundamentalistas da empresa como lucros e dividendos, informações sobre análise de balanço ou demonstração de resultados da empresa, já outros podem utilizar o histórico de preços dos ativos negociados no mercado padrões de comportamento da série;
- b) configurações de parâmetros – nesse caso a função de utilidade pode incorporar parâmetros como aversão a risco ou, ainda, é possível encontrar modelos que consideram características psicológicas nos agentes por intermédio de uma variável randômica, como em Levy, Levy e Solomon (1994);
- c) tipos de agentes – podem existir agentes fundamentalistas e agentes técnicos, por exemplo, como já explicado anteriormente;
- d) algoritmos de aprendizado – outro fator que torna os agentes diferentes um do outro é sua capacidade de aprendizado, que pode incluir inclusive algoritmos genéticos como fonte de mudanças nas estratégias.

#### 4.4.2.4 Aprendizado

O aprendizado dos agentes pode ocorrer de diferentes maneiras, quando se tratam de agentes para representar indivíduos nos mercados financeiros. Grothmann (2002) classifica em quatro os tipos de técnicas frequentemente utilizadas na modelagem multiagente, conforme pode-se observar no Organograma 2.



Organograma 2: Classificação de técnicas de aprendizado frequentemente usadas na modelagem multiagente

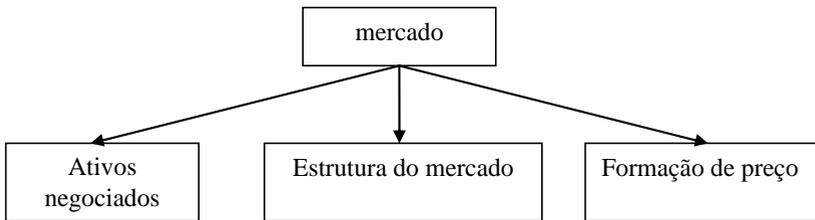
Fonte: Grothmann (2002).

- a) Sem aprendizado – nesse caso, os agentes não aprendem, pois possuem uma única estratégia predefinida que decide diretamente por meio da entrada de dados que atitude tomar;
- b) Estratégias predefinidas – nesse caso, os agentes possuem mais de uma estratégia predefinida, que decidem diretamente, por meio da entrada de dados, que atitude tomar. Contudo, dependendo das condições de mercado, uma das estratégias pode se sobrepôr às outras. Por exemplo, o agente pode tomar uma atitude, quando o mercado está em tendência, ou pode escolher outra estratégia, quando o mercado está estável;
- c) aprendizado evolucionário – nesse caso, agentes homogêneos iniciam o processo, mas, no decorrer das negociações, evoluem suas estratégias ou, podem ainda, criar estratégias totalmente novas. Na maioria dos casos, esse tipo de aprendizado utiliza inspiração biológica, como os algoritmos genéticos. Todavia, a desvantagem dessa técnica é que as estratégias formadas não vêm de deduções a partir dos dados do mercado ou de variáveis fundamentalistas sobre as empresas. As estratégias são formadas apenas das trocas feitas no conjunto genético do algoritmo;
- d) Aprendizado baseado em gradiente descendente – nesse caso, o aprendizado é derivado dos dados de entrada do mercado; o exemplo mais típico é o algoritmo de aprendizado *backpropagation* de propagação do erro padrão das redes neurais *feedforward* com mais de uma camada.

#### 4.4.3 Características macroeconômicas dos modelos de mercados financeiros multiagentes

Explicados os tipos de agentes que se podem utilizar para os modelos de mercado financeiros, podem-se analisar as características que emergem da interação dos agentes, ou seja, pode-se estudar a dinâmica do mercado.

Existem três grandes características dos mercados modelados via sistemas multiagentes que podem ser analisadas, segundo Grothmann (2002), conforme Organograma 3.



Organograma 3: Classificação de características macroeconômicas dos mercados usadas na modelagem multiagente

Fonte: Grothmann (2002).

Os ativos que podem ser negociados no mercado variam de ações, títulos e até moeda estrangeira (*foreign exchange market*) também chamados FX Markets ou simplesmente Forex.

Quanto à estrutura do mercado, podem-se ter mercados onde todos os agentes recebem informações externas igualmente ou pode-se definir que algumas informações sobre o mercado são distribuídas apenas localmente. Também, deve-se considerar a sincronização das negociações, pois se pode ter um mercado onde as negociações somente podem ser definidas em pontos específicos do tempo ou acontecer de os agentes definirem as negociações a qualquer momento.

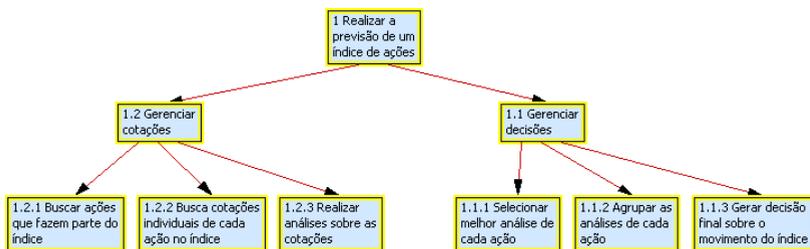
Por fim, deve-se considerar o mecanismo de formação de preços que pode ir desde um simples sistema com uma função previamente definida, até um mecanismo de formação de preços do mercado real.

## 5 DESENVOLVIMENTO DO MODELO

Para o desenvolvimento do modelo de mercado utilizado neste trabalho, foi necessária a escolha de uma técnica de modelagem de uma sociedade de agentes que contemplasse as características básicas de um mercado financeiro. A modelagem foi realizada utilizando, como base conceitual, a metodologia *Multiagent Systems Engineering* (MaSE) (DELOACH; WOOD, 2000). O MaSE indica ao projetista as fases do projeto que precisam ser desenvolvidas, de uma maneira lógica, permitindo identificar adequadamente o que deverá ser elaborado. Utilizando o MaSE, há claramente qualificados quais são os agentes e como estes se comportarão na sociedade. A metodologia propõe uma série de modelos que definem os objetivos gerais do SMA, a definição dos casos de usos, troca de mensagens, diálogos entre os agentes, e as classes de implementação.

### 5.1 OBJETIVOS

O objetivo principal do SMA deve ser dividido em subobjetivos. A realização dos subobjetivos permitirá a realização do objetivo principal. No caso do SMA proposto, o objetivo fundamental é realizar a previsão de um índice de ações, no caso, o Índice Bovespa. Para que isto seja possível, é necessário desenvolver uma série de subobjetivos, conforme apresentados no Organograma 4.



Organograma 4: Diagrama de hierarquia de objetivos

Para que o objetivo geral do SMA seja realizado, é necessário que ocorra o gerenciamento das cotações que são a fonte de informação para subsidiar as decisões. Além disso, é preciso gerenciar as decisões baseadas nas ações que compõem o índice para realizar a previsão final.

## 5.2 CASOS DE USO E DIAGRAMAS DE SEQUÊNCIA

Os casos de uso são utilizados para compreender as funcionalidades a serem contempladas pelo SMA, cada caso de uso pode reunir uma ou mais ações que são descritas pelos diagramas de sequência. Os casos de uso e diagramas de sequência para o modelo deste trabalho são: otimização do agente investidor, que tem como ator principal o agente investidor e que se comunica com os agentes consultores e, por fim, o caso de uso ponderação das decisões individuais, onde o ator principal é o agente mediador que se comunica com todos os agentes investidores.

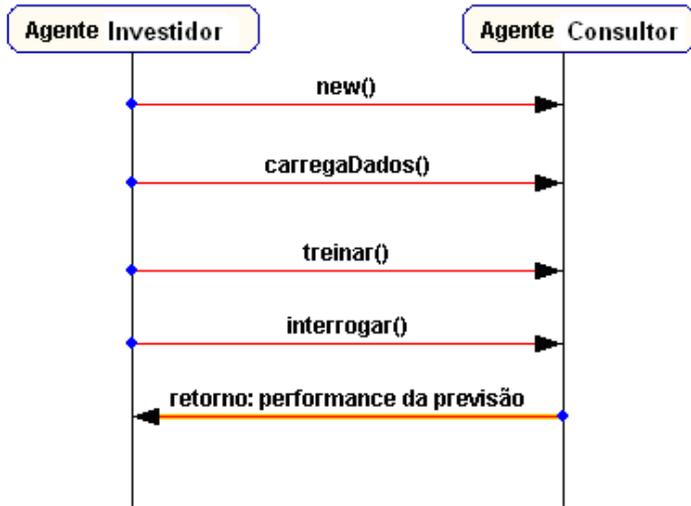
### 5.2.1 Otimização do agente investidor

Não houve, nesta etapa, a preocupação em definir os aspectos de implementação, como o modelo de criação e instanciação dos agentes, bem como da manutenção do repositório dos agentes investidor ou decisor. Sendo assim, o primeiro caso de uso descreve o processo de escolha do mais adequado motor de decisão para os agentes consultores. O Esquema 10 ilustra a interação entre os agentes.

O agente investidor realiza o treinamento e a interrogação de vários agentes consultores. Cada agente de investidor decide somente sobre um ativo, mas, para tomar essa decisão, o agente utiliza vários agentes consultores sobre o mesmo ativo, para tentar melhorar a *performance* da decisão. Apenas o agente consultor mais apto será considerado na hora da decisão.

Nessa etapa, o agente consultor fornece uma indicação de alta ou baixa, um passo a frente. Contudo, como os agentes consultores podem ter parâmetros diferentes de análise, é possível que alguns agentes

consultores sejam mais performáticos que outros. Sendo assim, é dever do agente de investidor escolher e utilizar apenas o consultor mais apto.

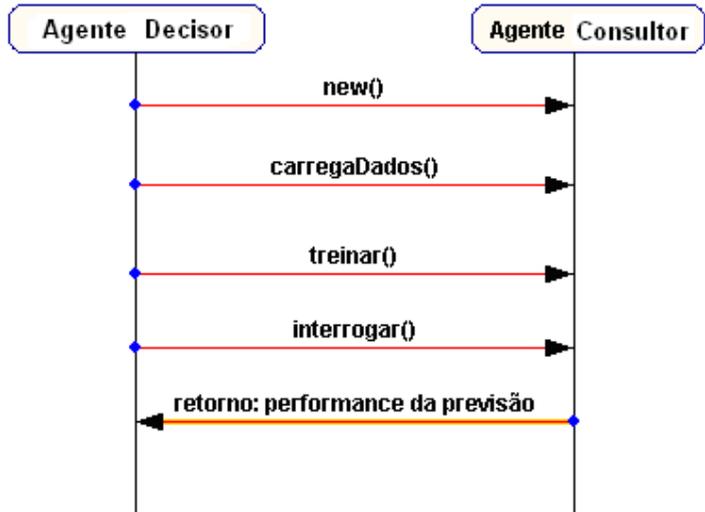


Esquema 10: Diagrama de sequência do caso de uso: Otimização do agente investidor

### 5.2.2 Ponderação das decisões individuais

Após cada agente investidor realizar sua própria decisão, um passo a frente, entra em cena o agente mediador. É dever do agente mediador coletar as posições de cada agente investidor para, posteriormente, comunicar cada uma dessas decisões para o agente agrupador, que irá criar sua própria previsão sobre a direção do índice. A comunicação desse processo segue conforme descrito no diagrama de sequência, expresso no Esquema 11.



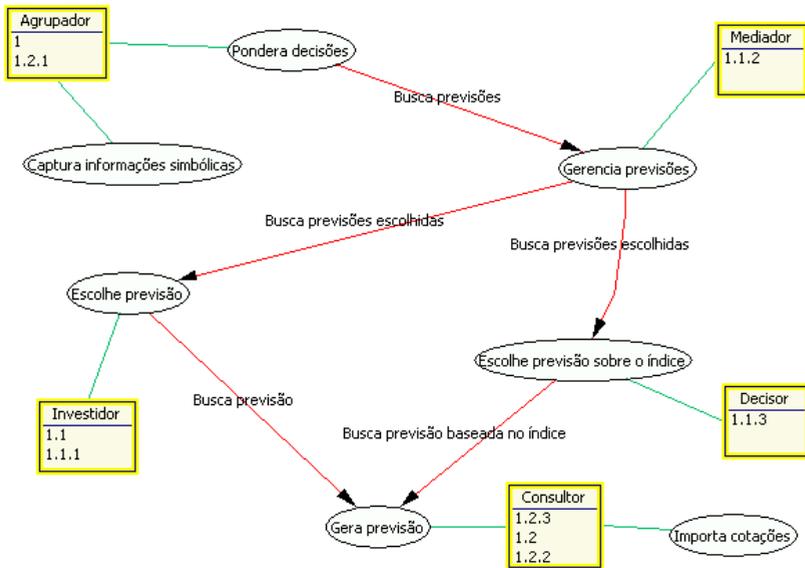


Esquema 12: Diagrama de sequência do caso de uso: escolha do Agente Consultor baseado somente nas cotações do Índice Bovespa

A responsabilidade do agente decisor é importante, pois, para validar a hipótese de pesquisa deste trabalho, precisa-se provar que a análise isolada do índice de ações é menos performática do que as análises ponderadas de cada agente de decisão sobre cada ativo do índice que é feita pelo SMA deste trabalho.

### 5.3 PAPÉIS

O diagrama de papéis ilustra como cada objetivo pode ser alcançado por intermédio dos papéis estabelecidos. No Fluxograma 1, os papéis são representados em retângulos, as tarefas são representadas pelas elipses e os protocolos de comunicação são representados pelas setas.



Fluxograma 1: Diagrama de papéis

São cinco os papéis dos agentes do modelo proposto que foram identificados durante o processo de modelagem do sistema, são eles: Investidor, Consultor, Mediador, Agrupador e Decisor, cada um deles com as seguintes características:

- a) Investidor – é uma abstração do papel do investidor, ou seja, do comprador ou vendedor que atua no mercado financeiro. Esse agente será criado e especializado para tomar as decisões de compra e venda com a ajuda do consultor;
- b) Consultor – especialista em analisar os dados reais do mercado para gerar a previsão um passo a frente, um investidor poderá consultar vários consultores para tomar uma decisão;
- c) Mediador – realiza a comunicação com todos os investidores do sistema, buscando as decisões de cada um para o próximo período;
- d) Agrupador – comunica-se com o mediador, pois é preciso ponderar cada decisão dos investidores recebidas pelo mediador

com o conhecimento simbólico do agrupador sobre o peso de ponderação de cada ativo no cálculo final do índice (ver o item Índice Bovespa 40 para mais detalhes sobre o peso de ponderação de cada ativo no Índice);

- e) Decisor – escolhe entre um grupo de consultores qual é a melhor atitude. É importante perceber que nesse papel é escolhido um dos consultores que usa apenas as cotações do Índice Bovespa, sem ter conhecimentos sobre as cotações das ações individuais.

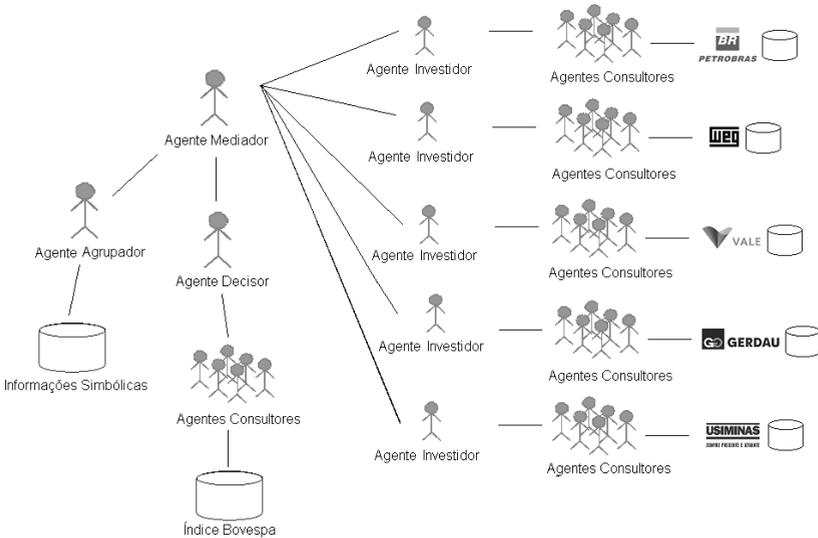
#### 5.4 ESTRUTURA BÁSICA DO MODELO

A população dos agentes das classes Investidor e Mediador é composta de 66 indivíduos correspondentes, cada um deles, a um dos títulos que constitui a carteira teórica do Ibovespa, válida para o quadrimestre setembro a dezembro de 2009, sendo 65 investidores e um único agente mediador. Para cada um dos 65 ativos do Índice Bovespa, um agente investidor será criado e especializado para tomar as decisões de compra e venda um passo a frente, relativo àquele título, sempre baseado no treinamento referente ao histórico real de cotações do ativo, tomados por meio dos Agentes Consultores que são os agentes com capacidade de estimar a evolução do título, para cada agente investidor são criados dez agentes consultores. O último agente do sistema será o Agente Mediador, que irá realizar a comunicação com todos os agentes de decisão do SMA, buscando as decisões de cada um para o próximo período, e ponderando essas decisões, para realizar a previsão final do índice, composto pelos 65 títulos.

A partir da definição da estrutura básica do modelo, os próximos passos são: selecionar um modelo cognitivo para os *agentes consultores* que permita o treinamento, com dados reais do mercado, para a aplicação no processo decisório do agente. Além disso, deve ser selecionado um modelo de comunicação entre os agentes que permita a verificação de uma condição emergente no comportamento da comunidade de *agentes consultores* para que os agentes investidores tomem a decisão mais correta sobre as compras e vendas. E, por fim, deve-se estabelecer um modelo de utilização do comportamento

emergente da comunidade de agentes inteligentes para indicar a dinâmica do preço de um índice de ações.

O Fluxograma 2 ilustra a arquitetura de agentes proposta:



Fluxograma 2: População de agentes do sistema

Os agentes consultores recebem as cotações de cada ativo (ação) e são consultados pelos agentes investidores. Os agentes investidores, por sua vez, são consultados pelo agente mediador que envia os resultados para o agente agrupador, este, por fim, realiza a previsão final do índice, baseado em seu conhecimento simbólico sobre os pesos de ponderação de cada ação dentro do índice. Outro papel do agente mediador é receber a previsão do agente decisor que utiliza um grupo de agentes consultores que se baseiam apenas nas cotações do próprio Índice Bovespa, sem considerar cada ação individualmente.

Nos SMA que trabalham em ciclos, em cada ciclo, é feita a previsão um passo a frente. Os ciclos são determinados pela fonte de dados reais do mercado. Tipicamente, os analistas humanos do mercado financeiro utilizam os gráficos e acompanham as cotações por meio de periodicidades definidas. Por exemplo, uma periodicidade diária significa que as observações dos dados são feitas uma vez ao dia. Já na

periodicidade de 60 minutos, a cada hora o analista tem acesso a uma cotação do ativo. E, por fim, na periodicidade de 15 minutos, a cada 15 minutos uma cotação é gerada baseada na negociação do ativo nos últimos 15 minutos.

Tipicamente, periodicidades diárias (período de um dia) são usadas para análises de longo prazo. Além disso, existem as periodicidades chamadas *intraday* (dentro do dia), onde, para análise de médio prazo é usada a periodicidade de 60 minutos e para curto prazo a periodicidade de 15 minutos. Neste trabalho, utiliza-se apenas a periodicidade diária para gerenciar os ciclos de treinamento e a previsão um passo a frente.

## 5.5 MODELO DE DECISÃO

### 5.5.1 Modelo de decisão dos agentes consultores

Conforme descrito anteriormente, no subitem 4.4.2.4, das técnicas de aprendizado frequentemente usadas na modelagem multiagente, apenas a técnica do aprendizado baseado em gradiente descendente permite a utilização de dados do mercado como entrada para gerar a tomada de decisão. O exemplo mais típico da técnica do gradiente descendente é o algoritmo de aprendizado *backpropagation* de propagação do erro padrão das redes neurais (RN) *feedforward* com mais de uma camada oculta.

A habilidade de uma RN em realizar previsões sobre uma determinada série temporal ou reconhecer padrões em um conjunto de dados provém de sua capacidade de aprendizado. O problema do aprendizado consiste em encontrar, por intermédio de um processo iterativo (onde cada entrada provoca uma resposta) e iterativo (reiterado), um conjunto de parâmetros livres que possibilite à rede o desempenho desejado. Em outras palavras, deve-se encontrar o ajuste dos pesos sinápticos  $W_i$  e do nível de bias que produzam o menor nível de erro entre a resposta desejada e a resposta estimada pela rede (no caso de uma série temporal) ou a melhor fronteira de separação (decisão) entre padrões presentes em um conjunto de dados.

Neste trabalho, foram utilizadas redes neurais (RN) como parte do motor de decisão dos agentes, que devem ser capazes de aprender com o histórico de preços reais do mercado para então tomar uma decisão quanto ao período seguinte. A principal fragilidade das RN para a previsão futura de preços é o ruído presente na série histórica de dados. Por isso, utiliza-se a periodicidade diária dos preços que possuem um ruído menor, pois é consenso entre os analistas que quanto menor a periodicidade da série histórica, maior é o componente do ruído embutido na série.

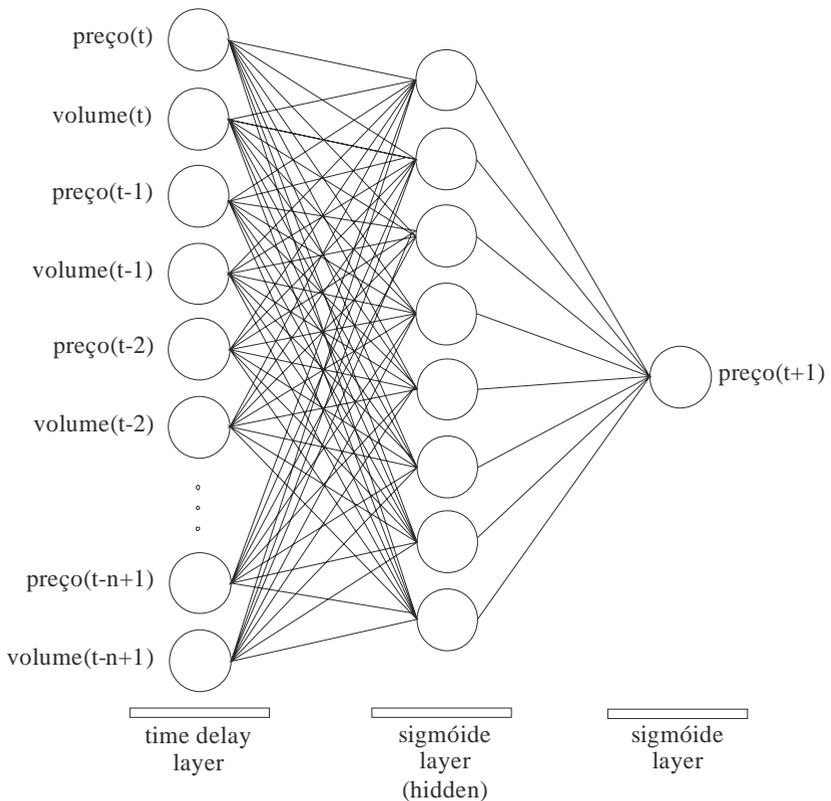
Cada agente investidor realiza a previsão de alta ou baixa, para o passo seguinte, por intermédio das opiniões dos agentes consultores que possuem um motor de decisão baseado em redes neurais, cada agente consultor possui uma e somente uma rede neural. Vale lembrar que ocorre uma competição entre vários agentes consultores sobre um mesmo ativo, e apenas a proposta do agente consultor mais performático é usada para a verificação um passo a frente pelo agente investidor.

#### 5.5.1.1 Estruturas de RN utilizadas

Para que os agentes investidores possam ser atendidos por consultores com diferentes habilidades, foi modelada uma população de agentes com diferentes configurações, fazendo com que cada agente investidor tenha à sua disposição um grupo de consultores com diferentes *performances* no grau de precisão de acerto na estimativa do índice de cada ação. As configurações de rede neural utilizadas na implementação dos agentes consultores foram:

- a) rede neural *perceptron* multicamadas (RN-MLP) acíclica (*feedforward*), com treinamento supervisionado por meio do algoritmo *backpropagation*;
- b) rede neural *perceptron* multicamadas (RN-MLP) acíclica (*feedforward*) com treinamento supervisionado por meio do algoritmo *Resilient backpropagation*;
- c) rede de Elman, onde a realimentação das camadas ocultas permite a realização de tarefas que se estendem no tempo (HAYKIN, 2001). A Rede de Elman é uma rede recorrente onde a realimentação ocorre da saída de cada neurônio da

- camada oculta para todos os neurônios da mesma camada. Uma camada, chamada Camada de Contexto, também oculta, composta de Unidades de Contexto, simula a memória da rede;
- d) redes de Jordan, também são redes recorrentes, ou seja, possuem ciclos nas ligações entre neurônios. Os ciclos no caso das redes de Jordan se resumem à conexão das saídas da camada de saída que retornam à camada intermediária, ou seja, a saída de um neurônio da camada de saída é usada como entrada adicional em todos os neurônios da camada intermediária.



Esquema 13: Configuração da rede neural utilizada pelos agentes de decisão

Para todas as configurações de rede foram utilizadas 3 camadas, conforme mostra o Esquema 13. A primeira camada foi composta por 10 neurônios para abrigar 10 dias úteis de cotações. O valor de entrada para cada neurônio dessa primeira camada é o retorno percentual diário e não o preço da ação propriamente dito. O retorno  $r_t$ , para o dia  $t$  é definido por  $\frac{P_t - P_{t-1}}{P_{t-1}}$  onde  $p_t$  é o preço atual da ação no dia  $t$ , e  $p_{t-1}$  é

o preço da ação no dia anterior. Em outras palavras, o retorno é a variação do preço de fechamento do dia atual em relação ao preço de fechamento do dia anterior.

A camada intermediária (*hidden layer*) foi configurada com 5 neurônios, tendo como função de ativação a função sigmoide, que é definida como uma função estritamente crescente, que exibe um balanceamento adequado entre comportamento linear e não linear (HAYKIN, 2001). Já a última camada foi formada por apenas um neurônio, que emitirá a decisão final sobre a rede e, também, possui função de ativação sigmoide.

### 5.5.1.2 Configurações de treinamento

Durante a fase de treinamento, os agentes consultores que utilizaram o algoritmo de treinamento *backpropagation* tiveram as seguintes configurações de treinamento: taxa de aprendizagem (*learning rate*) configurada a 0,8 e momento (*momentum*) configurado a 0,3. Para os agentes consultores que utilizaram o algoritmo *resilient backpropagation* não foi fornecida configuração adicional, pois esse algoritmo não necessita definir taxas de aprendizagem nem momento. Contudo, nos dois casos, o treinamento foi realizado utilizando-se a técnica do *early stopping*, que interrompe o treinamento da rede assim que o parâmetro do *early stopping* tenha sido atingido, evitando assim o supertreinamento (*over fitting*) da rede, que deteriora o desempenho de previsão.

O seguinte procedimento é adotado como *early stopping*. Um parâmetro  $p_{es}$  é definido antes do treinamento, esse parâmetro indica qual o índice de acerto percentual mínimo sobre o conjunto de

treinamento é desejado, por exemplo 80%. Durante o treinamento, após cada época, o poder de previsão da rede é testado com base no conjunto de treinamento, e, caso o resultado percentual de acertos seja igual ou superior a  $p_{es}$ , então um contador é acionado. Nas épocas seguintes, caso a *performance* da rede melhore, o contador é zerado, mas caso a *performance* da rede caia ou fique estável, o contato é incrementado. O *early stopping* é acionado somente quando o contador atinge o valor 100, ou seja, 100 épocas de treinamento sem melhora da *performance*. E caso, após 50 mil épocas, a rede neural não tenha atingido o critério de parada, então ela é descartada automaticamente. Nesse caso, o respectivo agente consultor tem o seu ciclo de vida encerrado e não será consultado pelo agente investidor.

Outro ponto importante é que as redes neurais dos agentes consultores são treinadas para prever a direção do movimento do dia seguinte, para cima ou para baixo. Saídas com valores iguais ou superiores a 0,5 indicam alta enquanto saídas com valores inferiores a 0,5 indicam queda. Sendo assim, a saída do agente consultor é uma decisão binária.

Conforme descrição supracitada, este trabalho utiliza como métrica os acertos do movimento dos preços, para cima ou para baixo. Apesar de essa métrica ser comumente utilizada em séries temporais gerais, alguns autores têm a opinião de que essa métrica não é a mais adequada, pois não guarda relação direta com o lucro auferido (VIEIRA; THOMÉ, 1999). Segundo Vieira e Thomé (1999), as tendências captadas pelas redes neurais podem possuir diferentes magnitudes. A quantidade de vezes em que uma tendência de alta ou baixa é prevista corretamente, guarda em si, uma tênue relação com a lucratividade, pois o lucro sofre influência direta da magnitude da variação de alta ou baixa do mercado (VIEIRA; THOMÉ, 1999).

Contudo, é praticamente consenso entre os pesquisadores atuais que outras métricas, como o erro quadrático do resultado em relação ao preço real observado pode levar a interpretações equivocadas. Resultados gerados com um erro quadrático menor, em relação à série real observada, podem, na verdade, gerar um lucro menor do que resultados com um erro quadrático maior, mas que capturaram a dinâmica do movimento dos preços de maneira mais adequada acertando mais vezes a direção de alta ou baixa dos preços. Por esse motivo, não se utilizará o erro quadrático como métrica neste trabalho.

O Gráfico 2 mostra como, após a época 1600, apesar do erro quadrático continuar caindo, os acertos dos movimentos sobre o conjunto de treinamento começam a diminuir. Sendo assim, nesse caso, a partir da época 1600, a rede está sofrendo um supertreinamento.

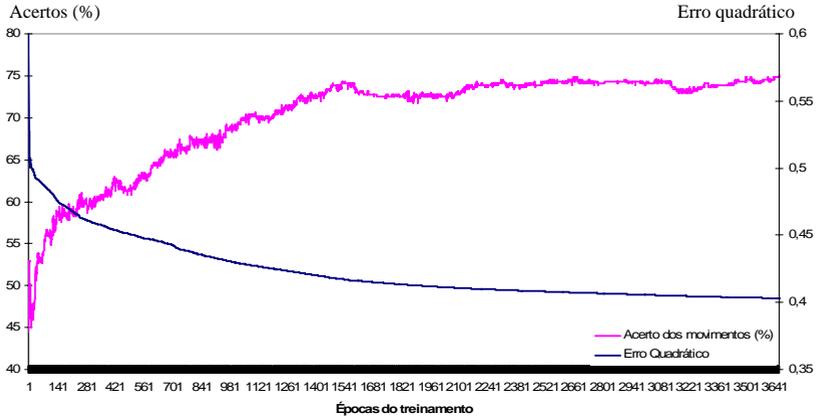


Gráfico 2: Supertreinamento identificado após a época 1600 quando o acerto do conjunto de treinamentos começa a cair

Nota: Após esse momento, a rede está sofrendo um supertreinamento com consequente perda da capacidade de generalização.

Como observado no Gráfico 2, apesar do erro quadrático menor, os acertos da rede sobre o próprio conjunto de treinamento deterioram com o supertreinamento. Os dados foram obtidos com uma Rede MLP com algoritmo de treinamento *Resilient BackPropagation* com 10 neurônios na camada oculta e 10 neurônios na camada de entrada. O Gráfico 2 mostra que o *Earlying Stopping* do treinamento deve acontecer logo que a quantidade de acertos do movimento para de subir. Depois disso, o erro quadrático até diminui, contudo, a rede começa a perder a capacidade de generalização.

### 5.5.2 Modelo de decisão do agente agrupador

O agente agrupador gera sua decisão baseado nas informações recebidas por intermédio do agente mediador que contém as indicações

de todos os 65 agentes investidores do SMA sobre o que ocorrerá em cada ativo um passo a frente. As indicações variam entre 0 a 1; valores iguais ou superiores a 0,5 indicam alta e valores inferiores a 0,5 indicam queda. De posse das decisões, o agente agrupador multiplica cada uma das indicações pelo respectivo peso<sup>5</sup> de ponderação do ativo no Índice Bovespa conforme a seguir:

$$p_{t+1} = \left( \sum_{i=1}^n d_i w_i \right) \quad (9)$$

Onde  $p_{t+1}$  é a previsão  $p$  no instante  $t+1$ , ou seja,  $p_{t+1}$  significa a previsão um passo a frente,  $d_i$  é a previsão da direção do movimento do investidor  $i$ , e  $w_i$  é o peso de ponderação dentro do Índice Bovespa do ativo  $i$ , e  $n$  é o número de agentes investidores no sistema, ou seja, 65.

Após receber as decisões dos investidores, o agente agrupador realiza o cálculo, multiplicando a indicação de cada agente investidor pelo respectivo peso de ponderação no índice. Depois disso, somando o resultado de cada agente investidor há, ao final, uma indicação de alta se o resultado for maior ou igual a 0,5 ou baixa, se o resultado for inferior a 0,5.

Neste ponto, é importante notar que o sistema esta utilizando as melhores previsões de cada ação do índice. Para cada ação, um grupo de agentes heterogêneos é treinado e testado, então um único agente deste grupo é escolhido para ser utilizado na previsão final. Dessa forma, a população de agentes heterogêneos garante que um espaço maior de possibilidades de previsão seja pesquisado, esta é uma das principais características do sistema proposto.

Além disso, como o índice é composto por ações que não são correlacionadas, unir as previsões individuais de cada ação do índice gera uma previsão diferente do que simplesmente prever a série histórica do índice, por isso o sistema é válido.

---

<sup>5</sup> Para mais informações sobre peso do índice veja o item 4.1.2 Índice Bovespa.

## 6 IMPLEMENTAÇÃO DO MODELO

Para a implementação de um sistema multiagente com capacidades cognitivas, que atendessem às necessidades de comunicação entre os agentes do modelo proposto, foi considerada a verificação das alternativas de plataformas tecnológicas disponíveis, e a análise de *frameworks* específicos para atender às necessidades de criação do sistema multiagente e dos modelos de redes neurais necessários.

### 6.1 TECNOLOGIAS RELACIONADAS

Apesar de existirem *frameworks* para a criação de SMA, a construção de sistemas multiagentes pode ser realizada em qualquer linguagem de programação e de forma livre por seus desenvolvedores. Assim, para este trabalho, foi utilizada uma implementação própria do SMA utilizando-se a linguagem Java com o JDK (Java Development Kit) versão 1.6.0 juntamente com a IDE (*Integrated Development Environment*) Netbeans 6.5 (NETBEANS, 2009).

Para implementar as redes neurais presentes nos agentes neurais, foi utilizado o *framework* Encog (*Artificial Intelligence Framework for Java and DotNet*) (ENCOG, 2009), foi avaliado, também, o *framework* Joone (*Java Object Oriented Neural Engine*) (JOONE, 2009), contudo, o Joone não apresenta atualizações desde 2007, enquanto o *framework* Encog teve sua última versão publicada em 10 de novembro de 2009.

#### 6.1.1 Detalhes de implementação por meio do *framework* Encog

O *framework* Encog (ENCOG, 2009), possui uma API Java com classes que possibilitam a montagem de uma rede neural completa. Para a criação de uma rede neural simples são utilizadas as seguintes classes:

- a) *BasicNetwork* – encapsula uma rede neural simples;

- b) *BasicLayer* – encapsula uma camada da rede neural. Normalmente uma rede neural é composta de pelo menos três camadas: amada de entrada, camada escondida ou intermediária e camada de saída;
- c) *ActivationSigmoid* – encapsula uma função de ativação do tipo *Sigmoid*;
- d) *ResilientPropagation* – encapsula um treinador do tipo *backpropagation* para a rede neural;
- e) *NeuralDataSet* – encapsula um conjunto de dados para treinamento ou validação da rede.

A seguir, apresenta-se um código de exemplo de criação de uma rede neural simples por meio do *framework* Encog:

```
//Criação da rede
BasicNetwork network = new BasicNetwork();
network.addLayer(new BasicLayer(new
ActivationSigmoid(), 10)); //10 neurônios
network.addLayer(new BasicLayer(new
ActivationSigmoid(), 5)); //5 neurônios
network.addLayer(new BasicLayer(new
ActivationSigmoid(), 1)); //1 neurônios
network.getStructure().finalizeStructure();
network.reset();

//treinamento da rede
NeuralDataSet trainingSet = new
BasicNeuralDataSet(inputTreinamento,
idealTreinamento);
Train train = new ResilientPropagation(network,
trainingSet);
train.iteration();//treina a rede durante uma época
```

Código 1: Exemplo de criação de uma rede neural simples por meio do *framework* Encog

Para a criação de redes recorrentes, como as Redes de Elman, a seguinte porção de código pode ser utilizada:

```

//Criação da rede de Elman
Layer hidden;
int nNeuronios_hidden = 5;
final Layer context =
    new ContextLayer(new ActivationSigmoid(),
false, nNeuronios_hidden);
final BasicNetwork network = new BasicNetwork();
network.addLayer(new BasicLayer(new
ActivationSigmoid(), false, 10));
network.addLayer(hidden = new BasicLayer(new
ActivationSigmoid(), false, nNeuronios_hidden));
hidden.addNext(context, SynapseType.OneToOne);
context.addNext(hidden);
network.addLayer(new BasicLayer(new
ActivationSigmoid(), false, 1));
network.getStructure().finalizeStructure();

```

Código 2: Exemplo de código para a criação de redes recorrentes

Repare que a linha de código

“hidden.addNext(context, SynapseType.OneToOne);” conecta a saída da camada oculta da rede com a camada de contexto, e a linha “context.addNext(hidden);” reconecta a camada de contexto com a camada oculta para realizar a realimentação. Essa realimentação é a característica fundamental das redes de Elman.

## 6.2 IMPORTAÇÃO DE COTAÇÕES

Outro ponto importante do sistema é a confiabilidade dos dados. Para os testes realizados, as cotações utilizadas foram importadas de arquivos texto, separados por ‘;’ no formato “csv”. A fonte de informação é o *software* ProfitChart da empresa Nelogica (NELOGICA, 2009). O *software* ProfitChart possui uma opção de exportação de arquivos em formato “csv”, onde é possível exportar a base completa de ativos disponível na bolsa de valores do Brasil. O *software* cria um arquivo “csv” para cada ativo exportado. Segue um trecho de um

arquivo referente às cotações diárias da ação preferencial PETR4 da Petrobrás.

```
PETR4;21/9/2009;34,38;34,78;34,11;34,60;656003296,00;19031000
PETR4;18/9/2009;34,24;34,65;34,24;34,65;389595362,00;11306700
PETR4;17/9/2009;34,18;34,78;34,15;34,30;713475358,00;20676300
PETR4;16/9/2009;33,53;34,38;33,46;34,35;957624737,00;28195100
PETR4;15/9/2009;33,39;33,58;33,25;33,40;453091316,00;13556800
PETR4;14/9/2009;32,90;33,33;32,66;33,24;441892486,00;13357400
PETR4;11/9/2009;33,40;33,50;33,07;33,14;371657886,00;11182600
```

Arquivo 1: Cotações diárias da ação preferencial PETR4 da Petrobras

O Arquivo 1 mostra uma sequência de dados contendo o código da ação, data, preço de abertura do dia, preço máximo do dia, preço mínimo do dia, preço de fechamento do dia, volume financeiro (em reais) negociado no dia e a quantidade de ações negociadas no dia.

Os dados disponíveis nos arquivos “csv” são importados pela classe *helper* *AtivoHelper*, disponível no diagrama de classes de implementação, ver 6.4 Diagrama de classe de implementação. A classe *AtivoHelper* utiliza acesso direto a disco para leitura dos arquivos texto.

### 6.3 NORMALIZAÇÃO DOS DADOS

Outro ponto importante a ser observado é que todos os dados fornecidos aos agentes neurais são normalizados no intervalo de 0 a 1. Sendo assim, as funções de ativação das redes neurais são sempre configuradas como sigmoide que também possui um *range* de 0 a 1. A função de normalização utilizada segue:

$$n = \frac{(origem - \min)}{(\max - \min)} * (novoMax - novoMin) + novoMin \quad (10)$$

Onde:

n = número normalizado

origem = número desnormalizado

min = valor mínimo do conjunto a ser normalizado

max = valor máximo do conjunto a ser normalizado

novoMax = valor máximo do range de destino da normalização

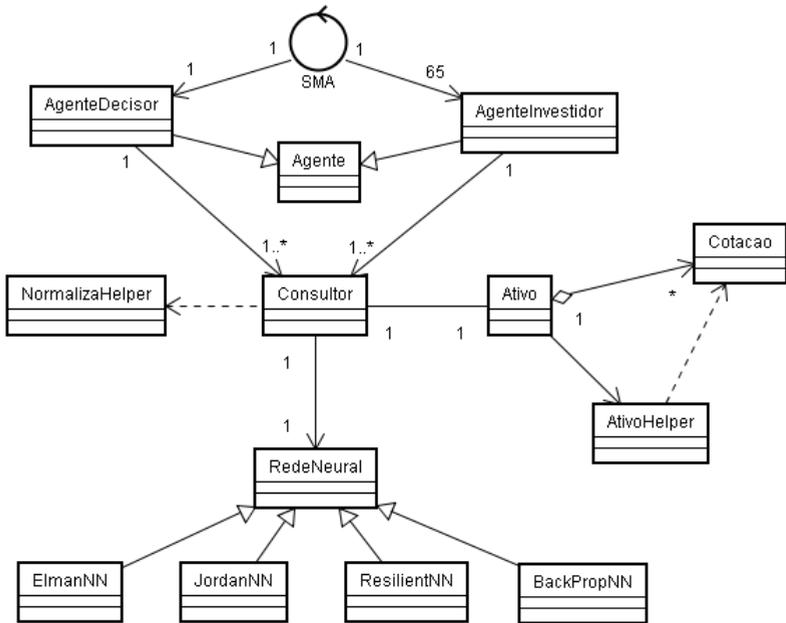
novoMin = valor mínimo do range de destino da normalização

A fórmula está implementada na classe de implementação NormalizaHelper, disponível no diagrama de classes de implementação, ver 6.4 Diagrama de classe de implementação. A classe NormalizaHelper é responsável por prestar serviços de normalização e desnormalização de dados que são utilizados pela classe de implementação Consultor para alimentar as redes neurais do sistema.

## 6.4 DIAGRAMA DE CLASSE DE IMPLEMENTAÇÃO

Baseado na descrição do modelo da seção 5 Desenvolvimento do modelo, a implementação foi feita conforme o diagrama de classes do Fluxograma 4. Algumas classes acessórias, como Ativo, Cotação, AtivoHelper e NormalizaHelper se fazem presentes apenas a partir de agora, pois são classes apenas de implementação. A classe Ativo encapsula os dados de um ativo (ação) específico contendo dados, como código da ação na bolsa, nome da empresa e uma coleção de objetos da classe Cotação. A classe Cotação encapsula dados, como preço de fechamento, data e hora do período em questão e volume de negócios do período. A classe AtivoHelper é utilizada para auxiliar na leitura dos arquivos “csv” que são a fonte de informação para a coleção de objetos da classe Cotação. E, por fim, a classe NormalizaHelper ajuda a classe Consultor a normalizar e desnormalizar os dados que são enviados e recebidos das classes do tipo RedeNeural.

No diagrama de classe de implementação do Fluxograma 4, fica em evidência a classe SMA que representa uma classe controladora do sistema, é nela que está implementado o método *main()* responsável pela partida do sistema.



Fluxograma 4: Diagrama de classe de implementação

Na implementação realizada, a análise de dados é diária e não existe a necessidade de alta *performance* ou processamento em tempo real, portanto, todas as classes do sistema foram instanciadas dentro do mesmo *container* Java e sobre a mesma máquina virtual. Dessa forma, não foi necessário implementar nenhum tipo de comunicação especial via *sockets* ou *Remote Method Invocation (RMI)*.

Apesar disso, no caso de uma implementação para análise de dados em tempo real com necessidade de alta *performance*, ou ainda, no caso de fontes de dados distribuídas, é possível utilizar as mesmas interfaces elaboradas neste trabalho bastando apenas a alteração da

implementação para comunicação entre ambientes remotos, seja via RMI, *webservices*, seja via *sockets*.

## 7 VALIDAÇÃO DO MODELO

Visando validar a hipótese da pesquisa, o modelo proposto foi implementado para realizar a previsão do Índice da Bolsa de Valores de São Paulo – Índice Bovespa, por intermédio da utilização do comportamento emergente da comunidade de agentes, alimentada com os dados das 65 ações do índice, na carteira teórica de setembro a dezembro de 2009. Foram realizados vários testes com várias configurações de agentes diferentes, além disso, foram realizados testes em períodos de tempo distintos. Também é importante ressaltar que todos os testes foram realizados visando comparar o desempenho da previsão do SMA com a previsão baseada apenas nas cotações do próprio índice.

Na implementação, a validação ocorre dentro da classe SMA, pois essa classe tem dois papéis distintos. Primeiro ela troca mensagens com os agentes investidores e chega a uma previsão baseada na comunidade de agentes (SMA). Depois ela consulta a previsão do agente decisor, o qual realiza a previsão sobre uma população de agentes consultores que têm acesso apenas às cotações do Índice Bovespa, sem ter acesso às cotações de cada ação do índice. Comparando o desempenho dessas duas previsões pode-se validar a hipótese desta pesquisa.

### 7.1 RESULTADOS OBTIDOS

No primeiro período de testes, a série histórica utilizada inicia-se em 1 de janeiro de 2009 e termina em 1 de novembro de 2009. Os testes de previsão foram feitos da seguinte maneira: Começaram os testes em janeiro levando em consideração três meses consecutivos de dados, ou seja, janeiro, fevereiro e março. Os últimos dez dias desse conjunto de dados foram reservados para os testes de previsão do sistema, e o restante dos dados foi utilizado no treinamento da população de agentes do SMA. Após os testes nesse período, o passo seguinte foi avançar um mês, pegando os três meses consecutivos fevereiro, março e abril; novamente os últimos dez dias desse conjunto foram utilizados para testar o poder de previsão do sistema em dados desconhecidos e o

restante dos dias foram utilizados para o treinamento dos agentes do SMA. Dessa forma, os testes foram realizados sucessivamente até os últimos três meses de dados disponíveis, finalizando em setembro, outubro e novembro. Cada conjunto de dados de três meses foi testado três vezes.

Para este teste, a configuração das redes neurais dos agentes consultores contou com uma configuração *multilayer perceptron* (MLP) acíclica do tipo *feedforward* tendo como algoritmo de treinamento o *resilient backpropagation*. Além disso, as redes contaram com uma camada de entrada de 10 neurônios para 10 dias de cotações e uma camada intermediária (*hidden layer*) com 5 neurônios. Por fim, o treinamento foi realizado sempre contando com a técnica do *early stopping* conforme descrito no item 5.5.1.2 Configurações de treinamento, onde o parâmetro  $p_{es}$  e a quantidade de ciclos do contador foram configurados para 80% e 100, respectivamente.

O resultado foi o seguinte: usando a população de agentes investidores com acesso individual a cada ação do índice, o sistema indicou a direção dos movimentos de maneira correta com uma média de acertos de 60,82%. O resultado foi melhor que a média de acertos do agente decisor, que baseia a previsão apenas nas cotações do próprio índice, e que acertou a direção apenas 52,08% das vezes. A diferença de 8,74% no desempenho mostra que o sistema proposto pode prever mais eficientemente a direção dos preços do que a abordagem baseada somente no histórico de cotações do próprio índice. Esse é um resultado que valida a hipótese desta pesquisa.

Foram ainda realizados testes em janelas de tempo diferentes, nos últimos 30 dias da série histórica que correspondem ao “conjunto de teste”. O restante dos dias da série histórica foi utilizado como “conjunto de treinamento” para treinar os agentes de decisão. Todas as séries de dados apresentadas às redes neurais foram normalizadas no intervalo de 0 a 1, o mesmo intervalo da função *sigmoid* utilizada na camada intermediária e na camada de saída.

Além disso, foram realizados outros testes. Dessa vez, a série de dados utilizada inicia em 1 de janeiro de 2009 e vai até 24 de novembro de 2009; foram utilizados para testes de desempenho os últimos 30 dias úteis da série. Neste teste, utilizou-se a seguinte configuração para o sistema multiagente: para os agentes neurais, criou-se uma configuração com 15 neurônios na camada de entrada, ou seja, 15 dias de cotações. Para a camada oculta, foi utilizada uma configuração de 5 neurônios.

Quanto à função de ativação, tanto a camada de entrada quanto a camada oculta continuaram utilizando a função sigmoideal. O treinamento das redes neurais foi feito com o algoritmo *resilient backpropagation*, que apresentou melhor desempenho que os demais. Esse algoritmo não exige outros parâmetros de configuração, além da quantidade de épocas que vai rodar. Aí entra em ação o artifício do *early stopping* que foi utilizado com o parâmetro  $p_{es}$  em 80% com o contador, sendo configurado para 100 ciclos, ou seja, a cada ciclo, a rede era interrogada com os dados do próprio conjunto de treinamento, e o treinamento somente termina quando a rede passa por 100 ciclos sem que a *performance* do acerto sobre o conjunto de treinamentos aumente. Há, assim, claramente definido o ponto de parada do *early stopping*. Outro ponto importante é que o agente investidor elimina automaticamente os agentes consultores com redes neurais que não conseguem obter uma taxa superior a 80% (parâmetro  $p_{es}$ ) de acerto sobre o conjunto de treinamento. Ou seja, apenas os agentes neurais mais aptos são utilizados. Para cada agente investidor, ou seja, para cada ação dentro do índice são inicialmente criados dez agentes consultores, contudo, caso nenhum desses dez agentes consiga terminar o treinamento com uma taxa de acerto superior a 80% para o parâmetro  $p_{es}$  então o agente investidor cria automaticamente outros agentes consultores até encontrar um que termine o treinamento com sucesso. Durante todos os testes realizados, em no máximo 50 tentativas, pelo menos, um agente consultor conseguiu terminar o treinamento com sucesso.

Com essas configurações, obtiveram-se 57,66% de acertos da direção dos movimentos para o SMA em 30 dias de testes contra apenas 51,34% de acerto para a previsão utilizando o índice isoladamente. Esse é um resultado que também comprova a eficácia do SMA proposto.

Buscando melhorar a *performance* do SMA, foram alterados alguns parâmetros e realizados novos testes. Os agentes neurais foram reconfigurados com redes neurais de 10 neurônios na primeira camada e 10 neurônios na segunda camada. As funções de ativação e a camada de saída permaneceram inalteradas, bem como os demais parâmetros; o período dos testes permaneceu exatamente o mesmo. Dessa forma, o resultado do sistema foi de 62,07% de acertos de movimento para o SMA contra 53,45% de acertos para a previsão isolada do índice. Novamente o sistema proposto demonstrou desempenho superior.

Por fim, visando garantir uma janela de tempo maior para a busca de padrões nos preços, foi utilizada uma configuração nos agentes neurais com 22 dias úteis de entrada de dados, ou seja, 22 neurônios na camada de entrada. Também foi alterada a camada oculta que passou a ter 5 neurônios. Além disso, o parâmetro  $p_{es}$  foi configurado para 90%. Com essa configuração obteve-se um total de 62,07% de acertos do SMA contra 55,17% de acerto para a previsão somente com a série histórica do índice.

Foram também realizados testes com redes de Elmann e Jordan, contudo, não foram obtidos resultados melhores. Porém, em todos os testes realizados, foi clara a superioridade do sistema multiagente sobre a previsão do índice isoladamente. A Tabela 1 apresenta um resumo dos resultados obtidos nos testes:

Tabela 1: Resultados obtidos

Camada de entrada	Camada oculta	Early Stopping	Desempenho do SMA	Desempenho do Agente Decisor apenas utilizando a série histórica do índice
		$p_{es}$ ciclos	(% de acertos da previsão)	(% de acertos da previsão)
15	5	80% 100	57,66%	51,34%
10	10	80% 100	62,07%	53,45%
22	5	90% 100	62,07%	55,17%

## 8 CONCLUSÃO

No mercado de ações é importante prever ou possuir uma probabilidade de previsão dos acontecimentos futuros para obter maior segurança nos investimentos. Nesse sentido, vários trabalhos recentes têm contrariado a teoria dos mercados eficientes que alega que os movimentos do mercado são aleatórios, não sendo possível executar qualquer tipo de previsão (FARMER; LO, 1996; KALYVAS, 2001; KUTSURELIS, 1998; MALKEI, 1999; SANTOS, 2005).

Este trabalho apresenta um modelo de sistema multiagente (SMA) para previsão do Índice Bovespa que se mostra mais eficiente do que a previsão do índice baseada exclusivamente em redes neurais ou métodos lineares tradicionais. O SMA proposto utiliza, em uma primeira etapa, uma população de agente realizando previsões individuais sobre cada ação que compõe o índice, para, em uma segunda etapa, essas previsões serem unidas em uma única previsão do movimento do próprio índice. Nesse caso, o sistema utiliza uma série histórica de cotações para cada uma das 65 ações que compõem o índice.

As previsões do SMA proposto foram comparadas com a previsão realizada exclusivamente com a série histórica do índice. A conclusão final é de que a previsão do SMA proposto é mais performática do que a previsão isolada do índice, já que o SMA captura melhor a microestrutura do mercado, prevendo um passo a frente de maneira mais eficaz. Além disso, os resultados obtidos são compatíveis com trabalhos recentes (KALYVAS, 2001; KUTSURELIS, 1998; QIAN, 2007; SANTOS, 2005), apesar de, neste trabalho, serem utilizadas estruturas de redes neurais mais simples como motor de decisão dos agentes.

Existe um grande campo de pesquisa quando se trata de sistemas multiagentes aplicados no sistema financeiro. O poder de capturar a microestrutura dos mercados traz um novo horizonte neste campo de pesquisa. Em pesquisas futuras, podem-se incrementar os resultados obtidos neste trabalho da seguinte forma:

- a) realizar outros testes com outras séries de dados, alterando o tamanho dos conjuntos de testes e de treinamento;

- b) adicionar aos agentes consultores outras fontes de dados com indicadores estatísticos como médias móveis sobre os preços ou volume de negócios dos ativos;
- c) usar outras arquiteturas de redes neurais, como redes com função de base radial;
- d) usar outros algoritmos de treinamento como, por exemplo, o algoritmo da têmpera simulada para realizar o *early stopping* do treinamento para um melhor desempenho sem o supertreinamento (*overfitting*);
- e) utilizar outro modelo de decisão do agente agrupador para melhorar a captura do comportamento emergente da população de agentes consultores.

## REFERÊNCIAS

ARAÚJO, Ricardo Matsumura de. **Aprendizado de máquina em sistemas complexos multiagentes:**

estudo de caso em um ambiente sob racionalidade limitada. Porto Alegre: UFRGS, 2004.

AZEVEDO, Fernando Mendes de; BRASIL, Lourdes Mattos; OLIVEIRA, Roberto Célio Limão de. **Redes Neurais com Aplicações em Controle e em Sistemas Especialistas.** Florianópolis: Visual Books, 2000.

BAK P.; PACZUSKI M.; SHUBIK, M. **Price Variations in Stock Market with Many Agents**, Santa Fé Institute Working Paper, n. 96-09-075, p. 1-59, 1996.

BAR-YAN Y. **Dynamics of Complex Systems**, Massachusetts: Addison-Wesley, 1997.

BELTRATTI, A.; MARGARITA, S.; TERNA, P. **Neural Networks for economic and financial modeling.** International Thomson Computer Press, London, UK, 1996.

BOSAIPO, Cláudia Rödel. **Aplicação das redes neurais na previsão do comportamento de mercados financeiros.** Rio de Janeiro: COPPE UFRJ, 2001.

BOVESPA. **BMF&Bovespa.** A bolsa do Brasil. Disponível em: <[www.bovespa.com.br](http://www.bovespa.com.br)>. Acesso em: 10 nov. 2009.

BRAGA, Antônio de Pádua; CARVALHO, André Ponce de Leon F.; LUDERMIR, Teresa Bernarda. **Fundamentos de Redes Neurais Artificiais**. Rio de Janeiro: UFRJ, 1998.

BRAGA, Antônio de Pádua; CARVALHO, André Ponde de Leon F.; LUDERMIR, Teresa Bernarda. **Redes Neurais Artificiais – Teoria e Aplicações**. Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora, 2000.

CARVER, N.; LESSER, V. **A First Step Toward the Formal Analysis of Solution Quality in FA/C Distributed Interpretation Systems**. Proceedings of the 13th International Workshop on Distributed Artificial Intelligence, July, 1994.

CHALLET, Damien; ZHANG Yi-Cheng. **Emergence of Cooperation and Organization in an Evolutionary Game**. Fribourg, Switzerland: Institut de Physique Théorique, Université de Fribourg, 1700, 1997.

CHALLET, Damien; MARSILI, Matteo; ZHANG Yi-Cheng. Modeling Market Mechanism with Minority Game. Fribourg: Institut de Physique Théorique, Université de Fribourg, CH-1700, 1999.

CHIARELLA, C.; HE, X-Z. Asset Price and Wealth dynamics under heterogeneous expectations. **Quantitative Finance**, v. 1, p. 509-526, 2001.

DELOACH, S. A.; WOOD, M. Developing Multiagent Systems with agentTool. **Proceedings of Lecture Notes in Artificial Intelligence**. Berlin: Springer – Verlag, 2001.

DEMAZEU, Y.; MÜLLER, J. Decentralized Artificial Intelligence. In: EUROPEAN WORKSHOP ON MODELLING AUTONOMOUS

AGENTS IN A MULTI-AGENT WORLD, 1., 1989, Cambridge. **Anais Eletrônicos...** North-Holland: Elsevier Science Publishers, 1989.

ELMAN, Jeffrey L. Finding Structure in Time. **Cognitive Science**, v. 14, p. 179-211, 1990.

ENCOG. **Encog Artificial Intelligence Framework for Java and DotNet**. Disponível em: <[www.heatonresearch.com/encog](http://www.heatonresearch.com/encog)>. Acesso em: 10 nov. 2009.

FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. **Journal of Finance**, v. 25, n. 2, p. 383-417, 1970.

FAMA, E. F. Efficient Capital Markets II. **Journal of Finance**, v. 46, n. 5, p. 1575-1617, 1991.

FARIA, Elisângela Lopes de et al. **Previsão do Mercado de Ações Brasileiro utilizando Redes Neurais Artificiais**. Rio de Janeiro: Pontifícia Universidade Católica, 2008.

FARMER, J. D. Market Force, **Ecology, and Evolution**. Santa Fé Institute Working Paper, v. 98-12-116, 1998.

FARMER J. D.; LO, A. Frontiers of Finance: Evolution and efficient markets. **Proceedings of the National Academy of Sciences**, v. 96, p. 9991-9992, 1996.

GALLA, Tobias; MOSETTI, Giancarlo Mosetti; ZHANG, Yi-Cheng. Anomalous fluctuations in Minority Games and related multi-agent models of financial markets. **The Abdus Salam International Center for Theoretical Physics**, Italy, 2006.

GODE, D. K.; SUNDER, S. Allocative efficiency of markets with zero intelligence traders, **Journal of Political Economy**, v. 101, p. 119-137, 1993.

GROTHMANN, Ralph. **Multi-agent market modelling based on neural networks**. Faculty of Economics, University of Bremen, 2002.

Disponível em:

<[http://elib.suub.uni-bremen.de/publications/dissertations/E-Diss437\\_grothmann.pdf](http://elib.suub.uni-bremen.de/publications/dissertations/E-Diss437_grothmann.pdf)>. Acesso em: 1 fev. 2009.

GRADUAL Investimentos. Disponível em:

<[www.gradualinvestimentos.com.br](http://www.gradualinvestimentos.com.br)>. Acesso em: 1 fev. 2009.

GUPTA, Nachi; JOHNSON, Neil F.; HAUSER, Raphael. **Robust Methods for Tracking Intelligent Agents Playing in an Artificial Financial Market**. The Sixth Intl. Joint Conf. on Autonomous Agents and Multi-Agent Systems (AAMAS 07), 1108a, 2001.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.

IGF Intellect. Disponível em:

<[http://www.igf.com.br/aprende/glossario/glo\\_Resp.aspx?id=1954](http://www.igf.com.br/aprende/glossario/glo_Resp.aspx?id=1954)>. Acesso em: 1 fev. 2009.

JENNINGS, N. R. Coordination Techniques for Distributed Artificial Intelligence. In: O'HARE, G. M. P.; JENNINGS, N. R. (Ed.).

**Foundations of distributed artificial intelligence**. New York: John Wiley & Sons, 1996.

JOONE. **Java Object Oriented Neural Engine**. The Complete Guide. 17 jan. 2007. Disponível em: <www.joone.org>. Acesso em: 1 fev. 2009.

JOHNSON, Neil F.; GUPTA, Nachi; HAUSER, Raphael. **Forecasting Financial Time-Series using Artificial Market Models**, Oxford: Oxford University, 2005.

KAIZOJI, T. Speculative bubbles and crashes in stock markets: an interacting-agent model of speculative activity. **Physica A**, Statistical Mechanics and its Applications, Special Issue, v. 287, n. 3-4, p. 493-506, 2000.

KALYVAS, Efstathios. **Using neural networks and genetic algorithms to predict stock market returns**. Manchester: University of Manchester, 2001.

KUTSURELIS, Jason E. **Forecasting financial markets using neural networks**: An analysis of methods and accuracy. Monterey, California: Naval Postgraduate School, 1998.

[LAHP97]. LeBaron, B.; Arthur, W. B.; Holland, J. H.; Palmer, R. G.; Tayler, P. Asset pricing under Endogenous Expectations in an Artificial Stock Market. Santa Fe Institute Working Paper, 96-12-093, 1996. Also published in: **The Economy as an Evolving Complex System II**, Ed. W.B. Arthur, S. Durlauf; D. Lane, Addison-Wesley, 1997.

[LAP99]. LeBaron, B.; Arthur, W. B.; Palmer, R. G. The Time Series Properties of an Artificial Stock Market. **Journal of Economy Dynamics and Control**, v. 23, p. 1487-1516, 1999.

LEBARON B. A Builder's Guide to Agent Based Financial Markets. **Quantitative Finance**, v. 1, n. 2, p. 254-261, 2001.

LEVY, M.; LEVY, H.; SOLOMON, S. A microscopic simulation model of the stock market: cycles, booms and crashes. **Economics Letters**, v. 45, p. 103-111, 1994.

LUX, T. The Socio-Economic Dynamics of Speculative Markets. Interacting Agents, Chaos, and the Fat Tails of Return Distributions. **Journal of Economic Behavior and Organization**, v. 33, p. 143-165, 1998.

MALKEI, B. G. **A random walk down wall street**. New York, London: W. W. Norton & Company, 1999.

MURPHY, John J. **Technical Analysis of the Financial Markets**. New York Institute of Finance, 1999.

NELOGICA. **ProfitChart**. Disponível em: <[www.nelogica.com.br](http://www.nelogica.com.br)>. Acesso em: 10 nov. 2009.

NETBEANS. Disponível em: <[www.netbeans.org](http://www.netbeans.org)>. Acesso em: 10 nov. 2009.

NEUNEIER R.; ZIMMERMANN, H. G. How to Train Neural Networks. **Neural Networks: Tricks of the Trade**, Springer, Berlin, 1998.

OLIVEIRA, F. M. Inteligência Artificial Distribuída. In: ESCOLA REGIONAL DE INFORMÁTICA, n. 4, 1996, Canoas. **Anais...** Canoas, 1996.

PODDIG, Th.; DICHTL, H.; PETERSMEIER, K. **Statistik, Okonometrie, Optimierung: Grundlagen und Anwendungen in Finanzanalyse und Portfoliomanagement**, Uhlenbruch, Bad Soden/Ts, 2000.

QIAN, Bo;RASHEED, Khaled. Stock market prediction with multiple classifiers. **Applied Intelligence**, v. 26, n. 1, p. 25-33, 2007.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: a Modern Approach**. 2. ed. Prentice Hall, 2004.

SANTOS, André Alves Portela. **Previsão não-linear da taxa de câmbio real/dólar utilizando redes neurais e sistema nebulosos**. 2005. Dissertação (Mestrado em Economia)–Universidade Federal de Santa Catarina, Florianópolis, 2005.

STEIGLITZ, Ken; CALLAGHAN, Liadan. **Microsimulation of Markets and Endogenous Price Bubbles**. 3rd International Conference on Computing in Economics and Finance, Stanford. 1997.

UM Investimentos. Disponível em: <[www.uminvestimentos.com.br](http://www.uminvestimentos.com.br)>. Acesso em: 1 fev. 2009.

VIEIRA, Renato S.; THOMÉ, Antonio C. G. **Avaliação de redes neurais aplicadas à previsão de índices de mercados de ações**. Rio de Janeiro: Universidade Federal do Rio de Janeiro, 1999.

WEISSMAN, Richard L. **Mechanical Trading Systems**. New Jersey: John Wiley & Sons, Inc., 2005.

WOOLDRIDGE, Michel. **An Introduction to MultiAgent Systems**. England: John Wiley & Sons, Inc., 2002.

YANG J. Heterogeneous Beliefs, Intelligent Agents, and Allocative Efficiency in an Artificial Stock Market, Society for Computational

Economics, **Series of Computing in Economics and Finance**, n. 612, 1999.

YOUSSEFMIR, M.; HUBERMAN, B. A. **Clustered Volatility in Multiagent Dynamics**, Working Paper, Santa-Fe Institute, v. 95-05-051, p. 1-23, 1995.

ZHANG, Y. C.; CHALLET, D. Emergence of Cooperation and Organization in an Evolutionary Game. **Physica A**, Amsterdam: [S.l.], v. 246, p. 407, 1997.

## ANEXO A – METODOLOGIA DO ÍNDICE BOVESPA (BOVESPA, 2009)

### **Apresentação**

O Índice Bovespa é o mais importante indicador do desempenho médio das cotações do mercado de ações brasileiro. Sua relevância advém do fato do Ibovespa retratar o comportamento dos principais papéis negociados na BOVESPA e também de sua tradição, pois o índice manteve a integridade de sua série histórica e não sofreu modificações metodológicas desde sua implementação em 1968.

### **O que é o Índice BOVESPA?**

É o valor atual, em moeda corrente, de uma carteira teórica de ações constituída em 02/01/1968 (valor-base: 100 pontos), a partir de uma aplicação hipotética\*. Supõe-se não ter sido efetuado nenhum investimento adicional desde então, considerando-se somente os ajustes efetuados em decorrência da distribuição de proventos pelas empresas emissoras (tais como reinversão de dividendos recebidos e do valor apurado com a venda de direitos de subscrição, e manutenção em carteira das ações recebidas em bonificação). Dessa forma, o índice reflete não apenas as variações dos preços das ações, mas também o impacto da distribuição dos proventos, sendo considerado um indicador que avalia o retorno total de suas ações componentes.

(\*) O Índice sofreu, unicamente para efeito de divulgação e sem prejuízo de sua metodologia de cálculo, as seguintes adequações:

- 1 – divisão por 100, em 03/10/1983;
- 2 – divisão por 10, em 02/12/1985;
- 3 – divisão por 10, em 29/08/1988;
- 4 – divisão por 10, em 14/04/1989;
- 5 – divisão por 10, em 12/01/1990;
- 6 – divisão por 10, em 28/05/1991;
- 7 – divisão por 10, em 21/01/1992;
- 8 – divisão por 10, em 26/01/1993;
- 9 – divisão por 10, em 27/08/1993;
- 10 – divisão por 10, em 10/02/1994;
- 11 – divisão por 10, em 03/03/1997.

Extremamente confiável e com uma metodologia de fácil acompanhamento pelo mercado, o Índice Bovespa representa fielmente o comportamento médio das principais ações transacionadas, e o perfil das negociações à vista observadas nos pregões da BOVESPA.

## **Finalidade**

A finalidade básica do Ibovespa é a de servir como indicador médio do comportamento do mercado. Para tanto, sua composição procura aproximar-se o mais possível da real configuração das negociações à vista (lote-padrão) na BOVESPA.

## **Representatividade do Ibovespa**

- Em termos de liquidez: As ações integrantes da carteira teórica do Índice Bovespa respondem por mais de 80% do número de negócios e do volume financeiro verificados no mercado à vista (lote-padrão) da BOVESPA.

- Em termos de capitalização bursátil: As empresas emissoras das ações integrantes da carteira teórica do Índice Bovespa são responsáveis, em média, por aproximadamente 70% do somatório da capitalização bursátil de todas as empresas com ações negociáveis na BOVESPA.

## **Divulgação e Acompanhamento**

A BOVESPA calcula seu índice em tempo real, considerando os preços dos últimos negócios efetuados no mercado à vista (lote-padrão) com ações componentes de sua carteira. Sua divulgação é feita pela rede de difusão da BOVESPA e também retransmitida por uma série de "vendedores", sendo possível, dessa forma, acompanhar "on line" seu comportamento em qualquer parte do Brasil ou do mundo.

## **Transparência**

Uma metodologia de cálculo simples, com seus dados à disposição do público investidor, assegura uma grande confiabilidade ao Índice Bovespa. Isto pode ser constatado pela chancela do mercado, traduzida pelo fato do Ibovespa ser o único dos indicadores de

performance de ações brasileiras a ter um mercado futuro líquido (um dos maiores mercados de contrato de índice do mundo).

### **Segurança, Confiabilidade e Independência**

A BOVESPA é responsável pela gestão, cálculo, difusão e manutenção do Ibovespa. Essa responsabilidade assegura a observância estrita às normas e procedimentos técnicos constantes de sua metodologia.

### **Metodologia de Cálculo**

#### **Critérios de Inclusão de Ações no Índice**

A carteira teórica do Ibovespa é composta pelas ações que atenderam cumulativamente aos seguintes critérios, com relação aos doze meses anteriores à formação da carteira:

- estar incluída em uma relação de ações cujos índices de negociabilidade somados representem 80% do valor acumulado de todos os índices individuais;
- apresentar participação, em termos de volume, superior a 0,1% do total;
- ter sido negociada em mais de 80% do total de pregões do período.

#### **Participação da ação na carteira teórica**

A participação de cada ação na carteira tem relação direta com a representatividade desse título no mercado à vista – em termos de número de negócios e volume financeiro – ajustada ao tamanho da amostra. Essa representatividade é obtida pelo índice de negociabilidade da ação, calculado pela seguinte fórmula:

$$in = \sqrt{\frac{ni}{N} * \frac{vi}{V}}$$

Onde:

in = índice de negociabilidade

$n_i$  = número de negócios com a ação "i" no mercado à vista (lote-padrão)

$N$  = número total de negócios no mercado à vista da BOVESPA (lote-padrão)

$v_i$  = volume financeiro gerado pelos negócios com a ação "i" no mercado à vista (lote-padrão)

$V$  = volume financeiro total do mercado à vista da BOVESPA (lote-padrão)

Nota: No cálculo do índice de negociabilidade não são considerados os negócios diretos.

### **Crítérios de Exclusão de Ações no Índice**

Uma ação selecionada para compor a carteira só deixará de participar quando não conseguir atender a pelo menos dois dos critérios de inclusão anteriormente indicados. Deve-se ressaltar que companhias que estiverem sob regime de recuperação judicial, processo falimentar, situação especial ou sujeitas a prolongado período de suspensão de negociação não integrarão o Ibovespa.

### **Apuração do Índice Bovespa**

O Índice Bovespa é o somatório dos pesos (quantidade teórica da ação multiplicada pelo último preço da mesma) das ações integrantes de sua carteira teórica. Assim sendo, pode ser apurado, a qualquer momento, por meio da seguinte fórmula:

$$Ibovespa_t = \sum_{i=1}^n P_{i,t} * Q_{i,t}$$

Onde:

Ibovespa t = Índice Bovespa no instante t

n = número total de ações componentes da carteira teórica

P = último preço da ação "i" no instante t

Q = quantidade teórica da ação "i" na carteira no instante t

### **Suspensão de Negociação**

No caso de suspensão de uma ação componente, o índice utilizará o preço do último negócio registrado em bolsa, até a normalização das negociações com o papel. Não havendo liberação para negociação por 50 dias, a contar da data da suspensão, ou em caso de ausência de perspectivas de reabertura dos negócios ou de rebalanceamento da carteira, a ação será excluída da carteira. Nesta eventualidade, serão efetuados os ajustes necessários para garantir a continuidade do índice.

### **Vigência da Carteira**

Para que a representatividade do Ibovespa mantenha-se ao longo do tempo, sua carteira é reavaliada ao final de cada quadrimestre, utilizando-se os procedimentos e critérios integrantes desta metodologia. Nas reavaliações, identificam-se as alterações na participação relativa de cada ação no índice, bem como sua permanência ou exclusão, e a inclusão de novos papéis. A carteira teórica do Ibovespa tem vigência de quatro meses, vigorando para os períodos de janeiro a abril, maio a agosto e setembro a dezembro.

### **Procedimentos para Rebalanceamento**

Nos rebalanceamentos quadrimestrais são adotados os seguintes procedimentos: • A BOVESPA calcula o índice de negociabilidade para cada uma das ações nela negociadas nos últimos doze meses. Esses índices são colocados em uma tabela em ordem decrescente, e uma coluna apresenta a soma de tais índices à medida que se percorre a tabela do maior para o menor. Calcula-se então a participação de cada índice de negociabilidade individual em relação à soma total, listando-se as ações até que o montante de suas participações atinja 80%.

- As ações listadas vão compor a carteira do índice, desde que atendam aos outros dois critérios de inclusão. Caso não os atendam, elas são substituídas pelas ações que vierem a seguir na listagem decrescente, e que consigam atender a tais parâmetros.
- O passo seguinte é identificar, entre as ações que pertencem à carteira vigente, se alguma delas será excluída.

- Os índices de negociabilidade das ações escolhidas são listados novamente, apurando-se o percentual de participação de cada papel em relação à soma dos índices de todas as ações da carteira.
- A participação ajustada de cada ação, aplicada sobre o valor do índice do último dia do quadrimestre anterior, determinará o "peso" inicial (número de pontos do índice) de cada ação.
- A quantidade teórica de cada ação, resultante da divisão de sua parcela na composição do índice (peso) pelo seu preço de fechamento no último dia do quadrimestre anterior, permanecerá constante pelos quatro meses de vigência da carteira, somente sendo alterada caso ocorra distribuição de proventos (dividendos, bonificações, subscrições, etc.) por parte da empresa.

