

UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HYDELO WAGNER SOUZA MELO

PROPOSTA DE UM SISTEMA DE NEGOCIAÇÃO PARA AUXILIAR NA  
TOMADA DE DECISÃO NO MERCADO DE AÇÕES UTILIZANDO REDES  
NEURAS DINÂMICAS AUTO-REGRESSIVAS

MANAUS

2018

UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

HYDELO WAGNER SOUZA MELO

PROPOSTA DE UM SISTEMA DE NEGOCIAÇÃO PARA AUXILIAR NA  
TOMADA DE DECISÃO NO MERCADO DE AÇÕES UTILIZANDO REDES  
NEURAS DINÂMICAS AUTO-REGRESSIVAS

Dissertação apresentada ao Curso de  
Mestrado em Engenharia Elétrica, área de  
concentração Controle e Automação de  
Sistemas do Programa de Pós-Graduação em  
Engenharia Elétrica da Universidade Federal  
do Amazonas.

Orientador: Prof. Dr. Cícero Ferreira Fernandes Costa Filho  
Co-Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Marly Guimarães Fernandes Costa

MANAUS

2018

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

M528p Melo, Hydelo Wagner Souza  
Proposta de um sistema de negociação para auxiliar na tomada de decisão no mercado de ações utilizando redes neurais dinâmicas auto-regressivas / Hydelo Wagner Souza Melo. 2018  
95 f.: il. color; 31 cm.

Orientador: Cícero Ferreira Fernandes Costa Filho  
Coorientadora: Marly Guimarães Fernandes Costa  
Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas.

1. Redes neurais. 2. Mercado financeiro. 3. Sistemas de negociação. 4. Ibovespa. 5. Séries históricas. I. Costa Filho, Cícero Ferreira Fernandes II. Universidade Federal do Amazonas III. Título

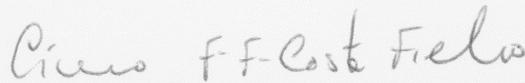
HYDELO WAGNER SOUZA MELO

PROPOSTA DE UM SISTEMA DE NEGOCIAÇÃO PARA AUXÍLIO NA TOMADA DE DECISÃO NO MERCADO DE AÇÕES UTILIZANDO REDES NEURAIS DINÂMICAS AUTO-REGRESSIVAS.

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovado em 01 de agosto de 2018.

BANCA EXAMINADORA



Prof. Dr. Cícero Ferreira Fernandes Costa Filho, Presidente

Universidade Federal do Amazonas



Prof. Dr. Edleno Silva de Moura, Membro

Universidade Federal do Amazonas



Prof. Dr. Celso Barbosa Carvalho, Membro

Universidade Federal do Amazonas

## **AGRADECIMENTOS**

Aos meus orientadores, Prof. Dr. Cícero Ferreira Fernandes Costa Filho e Profa. Dra. Marly Guimarães Fernandes Costa, pela boa-vontade e suporte prestados mesmo eu estando em uma condição especial de regime de trabalho;

Aos meus pais e à minha esposa, Suellen, como incentivadora dessa pós-graduação;

Aos professores do curso de pós-graduação em engenharia elétrica e colegas de curso;

À Universidade Federal do Amazonas e ao Centro de Tecnologia Eletrônica e da Informação – CETELI pelo suporte oferecido.

## RESUMO

Desde que o patrimônio das empresas foi dividido em ações de fácil e rápida negociação, ou seja, com liquidez, há grande interesse de pesquisadores e investidores em todo o mundo de prever o comportamento futuro dos preços, a fim de obter recomendações de compra ou venda de tais ativos, com o objetivo final de alcançar lucratividade ou preservar seus patrimônios. Neste trabalho, uma rede neural auto-regressiva não linear - NAR (*Nonlinear AutoRegressive model*) - foi utilizada para realizar previsões de alguns passos à frente da série histórica do Índice da Bolsa de Valores de São Paulo (Ibovespa), de modo a embutir tais previsões em um sistema de negociação. A previsão precisa não foi uma exigência principal da rede, mas sim a possibilidade de revelar uma tendência de curto prazo (semanas) acertada. A fim de suportar as decisões de compras e vendas, foi proposto um sistema de negociação baseado no índice IMM<sub>N</sub>, Indicador de Mínimos e Máximos. Em função da previsão de mínimos e máximos pelo índice IMM<sub>N</sub>, são indicadas operações de compras ou vendas, respectivamente. Para o cálculo desse índice é utilizada a rede NAR e dados de uma série histórica do Ibovespa. O sistema de negociação proposto obteve retornos superiores ao crescimento do Ibovespa em períodos superiores a um ano. Na média, o sistema de negociação apresentou retorno de 26% enquanto que o Ibovespa, somente 3%. O trabalho foi realizado sobre o histórico de valores do Ibovespa. Na prática, as ações que compõem o Ibovespa seriam o alvo das operações de compras e vendas, nas proporções em que as mesmas compõem o índice. Outra opção é realizar essas mesmas operações em um fundo de investimento baseado no índice Ibovespa.

**Palavras-chave:** Redes Neurais Artificiais; Mercado Financeiro; Séries Históricas; Ibovespa; Sistema de Negociação.

## ABSTRACT

Since the equity of the companies have been divided into easy and quick trading, that is, with liquidity, there is a great interest of researchers and investors around the world to predict the future behavior of prices in order to obtain recommendations of purchase or sale of such assets with the ultimate objective of achieving profitability or preserving their assets. In this work, the Nonlinear AutoRegressive model (NAR) was used to predict a few steps ahead of the historical series of the Index of the São Paulo Stock Exchange (Ibovespa) in order to embed such predictions into a trading system. Precise prediction was not a primary requirement of the network, but rather the possibility of revealing a short-term (weeks) trend. It was proposed the  $IMM_N$  index that is calculated on the predictions made by the networks and this parameter is used to identify extreme points (maximum or minimum local) that allowed to support the decisions of purchases and sales. Operating the system in a simulated way on the historical series for determination of annual performances and the total period, the trading system obtained a higher return than the growth of the index in the total period observed for the eight combinations of conceived networks, and on average the trading system presented a return of 26% while the index, only 3%. The work was carried out on the historical value of the index, however, such an effect could be transported roughly to the practical world through the purchase or sale of shares in such proportions as to reproduce the index or through the purchase and sale of a similar investment fund to the index.

**Keywords:** Artificial Neural Networks; Financial market; Historical Series; Ibovespa; Trading System.

## ÍNDICE DE ILUSTRAÇÕES

Figura 2.1 - Evolução do índice Ibovespa: adaptado de Kerr (2011).....	21
Figura 3.1 – Neurônio biológico e suas partes principais.....	27
Figura 3.2 – Neurônio de múltiplas entradas com função de transferência $f = \text{hardlim}$ , também chamado de perceptron. ....	28
Figura 3.3 – Neurônio de múltiplas entradas com notação abreviada.....	29
Figura 3.4 – RNA com uma camada de S neurônios.....	30
Figura 3.5 – RNA de múltiplas entradas e três camadas .....	31
Figura 3.6 – Funções de transferência típicas .....	32
Figura 3.7 – Exemplo de normalização .....	37
Figura 3.8 – Rede NARX .....	38
Figura 3.9 – Tipos de modelos da rede NARX .....	39
Figura 4.1 – Figura explicativa do cálculo do $\text{IMM}_N$ para classificação de pontos .....	42
Figura 4.2 – Indicadores de máximo e mínimo determinados para $N=4, 8$ e $12$ e para um limiar de busca igual a $-0,2E6$ (curva tracejada em preto nos gráficos da esquerda). Pontos pretos e pontos verdes, correspondem, respectivamente, a indicadores de máximo e de mínimo nos gráficos da direita. ....	44
Figura 4.3 – Indicadores de máximo e mínimo determinados para $N=4, 8$ e $12$ e para um limiar de busca igual a $-0,15E6$ (curva tracejada em preto nos gráficos da esquerda). Pontos pretos e pontos verdes, correspondem, respectivamente, a indicadores de máximo e de mínimo nos gráficos da direita. ....	45
Figura 4.4 – Fluxograma Inicial do Sistema.....	47
Figura 4.5 – Ilustração da Variação do Estado.....	49
Figura 4.6 – Gráfico mostrando a evolução do capital, através da utilização da melhor combinação de parâmetros obtidos nas simulações anteriores. O valor inicial foi ajustado em 100. O valor final, após 220 semanas, foi de 371,8.....	53
Figura 4.7 – Fluxograma do Sistema.....	54
Figura 4.8 – Deslizamento da aplicação para treinamento curto e longo.....	57
Figura 4.9 – Arquitetura utilizada para a rede NAR (MATLAB®).....	58
Figura 4.10 – Rede C-ES-7-1 no primeiro período, predição do primeiro conjunto de 4 pontos .....	59
Figura 4.11 – Rede C-ES-7-1 no primeiro período, predição do segundo conjunto de 4 pontos .....	60
Figura 4.12 – Rede C-MSE-4-3 no terceiro período, predição do primeiro conjunto de 4 pontos .....	61
Figura 4.13 – Rede C-MSE-4-3 no terceiro período, predição do segundo conjunto de 4 pontos .....	61
Figura 5.1 – Comparação para as predições para o conjunto de redes C-MSE-7 .....	64
Figura 5.2 – Cálculo do indicador $\text{IMM}_N$ para os dados estimados para o conjunto de redes C- MSE-7.....	65
Figura 5.3 – Gráfico resumo das operações para o conjunto de redes C-MSE-7.....	65
Figura 5.4– Comparação para as predições para o conjunto de redes L-MSE-7.....	67
Figura 5.5 – Cálculo do indicador $\text{IMM}_N$ para os dados estimados para o conjunto de redes L- MSE-7.....	68

Figura 5.6 – Gráfico resumo das operações para o conjunto de redes L-MSE-7 .....	69
Figura 5.7– Comparação para as predições para o conjunto de redes C-MSE-4 .....	70
Figura 5.8– Cálculo do indicador $IMM_N$ para os dados estimados para o conjunto de redes C-MSE-4.....	71
Figura 5.9– Gráfico resumo das operações para o conjunto de redes C-MSE-4.....	72
Figura 5.10– Comparação para as predições para o conjunto de redes L-MSE-4.....	73
Figura 5.11– Cálculo do indicador $IMM_N$ para os dados estimados para o conjunto de redes L-MSE-4.....	74
Figura 5.12– Gráfico resumo das operações para o conjunto de redes L-MSE-4.....	75

## LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmos Genéticos
ARCH	<i>Autoregressive Conditional Heteroskedasticity</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
SA	<i>Sentiment Analysis</i>
BM&F	Bolsa de Mercadorias e Futuros
Bovespa	Bolsa de Valores de São Paulo
BPTT	<i>BackPropagation Through Time</i>
CVM	Comissão de Valores Mobiliários
DDM	<i>Drift Detection Mechanism</i>
DTW	<i>Dynamic Time Warping</i>
ELM	<i>Extreme Learning Machines</i>
EMD	<i>Empirical Mode Decomposition</i>
EMH	<i>Efficient Market Hypothesis</i>
FNN	<i>Feed-Forward Neural Network</i>
FTDNN	<i>Focused Time-Delay Neural Network</i>
GARCH	<i>Generalized Autoregressive Conditional Heteroskedasticity</i>
$IMM_N$	Indicador de Mínimos e Máximos de base N
IPO	<i>Initial Public Offering</i>
KNN	<i>K-Nearest Neighbor</i>
LPA	Lucro por ação
MACD	<i>Moving Average Convergence Divergence</i>
MLP	<i>Multi Layer Perceptron</i>
MME	Média Móvel Exponencial
MMS	Média Móvel Simples
NAR	<i>Nonlinear AutoRegressive model</i>
NARX	<i>Nonlinear AutoRegressive model with eXogeneous inputs</i>
NTN	<i>Neural Tensor Network</i>
NYSE	<i>New York Stock Exchange</i>
PG	Programação Genética
PIB	Produto Interno Bruto
RDP	<i>Relative Difference in Percentage of Price</i>

RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Networks</i>
RTRL	<i>Real-Time Recurrent Learning</i>
SBM	<i>Slope-Based Method</i>
SVM	<i>Support Vector Machine</i> ou Máquinas de Vetores de Suporte
TA	<i>Technical Analysis</i>

## SUMÁRIO

1.	Introdução.....	12
1.1.	Prolegômenos .....	12
1.2.	Justificativas .....	13
1.3.	Objetivos .....	17
1.4.	Organização do Trabalho .....	17
2.	Mercado Financeiro.....	19
2.1.	Introdução.....	19
2.2.	Ações ou Papéis.....	19
2.3.	Bolsa de Valores e Corretoras de Valores .....	20
2.4.	Índices de Desempenho.....	21
2.5.	A Hipótese de Mercado Eficiente ( <i>Efficient Market Hypothesis</i> - EMH).....	22
2.6.	Índices Futuros .....	23
2.7.	Avaliação de ações .....	23
2.7.1.	Análise Fundamentalista .....	24
2.7.2.	Análise técnica (gráfica).....	24
2.8.	Séries do Mercado Financeiro .....	24
3.	Rede Neural Artificial (RNA) .....	27
3.1.	Introdução.....	27
3.2.	Representação das Redes.....	28
3.3.	Função de Transferência .....	31
3.4.	Treinamento das Redes .....	32
3.5.	Redes Dinâmicas Recorrentes .....	35
3.6.	Critério de Parada no Treinamento das Redes .....	36
3.7.	Pré-processamento dos dados.....	37
3.8.	Rede do tipo NARX e NAR .....	37
4.	Sistema de Negociação.....	40
4.1.	Visão geral.....	40
4.2.	Proposição do indicador $IMM_N$ .....	41
4.3.	Funcionamento Inicial do Sistema de Negociação.....	46
4.4.	Escolha dos parâmetros básicos .....	49
4.5.	Sistema Completo.....	54
4.6.	Treinamento da Rede Neural.....	55

5.	Operação do Sistema e Resultados.....	63
5.1.	Introdução.....	63
5.2.	Rede 1 - NAR C-MSE-7 .....	63
5.3.	Rede 2 - NAR L-MSE-7.....	66
5.4.	Rede 3 - NAR C-MSE-4 .....	70
5.5.	Rede 4 - NAR L-MSE-4.....	73
5.6.	Rede 5 - NAR C-ES-7 .....	76
5.7.	Rede 6 - NAR L-ES-7 .....	77
5.8.	Rede 7 - NAR C-ES-4 .....	78
5.9.	Rede 8 - NAR L-ES-4 .....	78
5.10.	Comparações .....	80
6.	Conclusões.....	82
7.	Bibliografia.....	84
8.	Anexos.....	89
8.1.	Código para avaliação e escolha dos parâmetros $N$ do $IMM_N$ , o limiar $\epsilon$ , o grau de alocação por operação $\theta$ e o período $\tau$ .....	89
8.2.	Código do sistema de negociação com as RNA's embutidas .....	92

# 1. Introdução

## 1.1. Prolegômenos

O Mercado Financeiro detém um papel muito importante na sociedade moderna, estruturada e organizada nos moldes capitalistas. Empresa, ou atividade empresarial, é uma atividade econômica exercida profissionalmente pelo empresário, ou empresários, por meio da articulação dos fatores produtivos para produção ou circulação de bens ou serviços (COELHO, 2010). Para iniciar uma atividade empresarial, faz-se necessário o emprego de capital, recursos que tenham um valor monetário, e que poderão ser convertidos, por exemplo, em equipamentos, salários, bens imóveis etc. Para adquirir novos recursos financeiros, algumas empresas podem fracionar parte do capital da empresa, colocando-o à venda por meio das bolsas de valores. Dessa forma, então nascem as ações, ou papéis. Os papéis então são livremente negociados no âmbito das bolsas de valores, podendo qualquer pessoa interessada adquiri-los e, uma vez possuindo-os, vendê-los. Algumas empresas têm quantidades consideráveis de papéis a venda no mercado a preços baixos e negociadas todo dia, às vezes, a cada minuto, a cada segundo. Devido a isso, os preços flutuam a todo momento, ora aumentando, ora reduzindo, ora se mantendo estável.

A flutuação dos preços das ações é um tópico muito estudado em vários campos do conhecimento, tais como finanças, engenharia, estatística e ciência da computação, dentre outros. A razão disso é muito simples: negociar uma fração do capital das empresas pode gerar ganhos de capital para quem o faz com precisão. Deste modo, há instituições financeiras (bancos, corretoras, seguradoras) ou mesmo pessoas físicas que se dedicam, em algum nível de profundidade, à missão de prever o comportamento futuro do preço das ações com o fito de conseguir ganhos financeiros. Não é à toa que, nas últimas décadas, o assunto da análise do movimento do mercado financeiro já foi amplamente estudado, conforme mostra o estudo de Yoo, Kim e Jan (2005), em uma conhecida revisão sobre o assunto. Contudo, há ainda uma gama de técnicas disponíveis para serem aplicadas no estudo desse movimento (GAMBOGI, 2013).

A previsão do comportamento futuro do mercado financeiro não é um problema fácil de ser resolvido, pois os preços dos papéis são considerados por muitos como caóticos e imprevisíveis (RAO *et al*, 2015).

No campo da análise do movimento das ações, existem duas principais vertentes: (i) análise fundamentalista e (ii) análise técnica. No primeiro caso, os parâmetros que retratam a saúde financeira da empresa são utilizados com o objetivo de se prever as oscilações dos valores de suas ações. Como exemplo de parâmetros, podemos citar indicadores que são calculados a partir do balanço patrimonial ou dos resultados da empresa, tais como lucro líquido do período, nível de endividamento, evolução do patrimônio líquido, dentre outros. No segundo caso, o histórico dos preços das ações é avaliado, seja diretamente ou por meio de indicadores técnicos, de forma que sejam extraídos padrões comportamentais do passado com o intuito de se prever os preços futuros. Trata-se de uma previsão baseada no histórico das ações de uma empresa.

## 1.2. Justificativas

A Hipótese dos Mercados Eficientes ou *Efficient Market Hypothesis (EMH)* afirma (KERR, 2011) que todas as informações sobre determinada empresa são incorporadas automaticamente aos preços dos papéis e que somente informações futuras podem alterar seus valores. Uma vez que o futuro é imprevisível, então os preços das ações também seriam. Dessa forma, argumenta-se que os métodos que utilizam o histórico dos preços das ações para prever preços futuros, no caso a análise técnica, são ineficazes.

Conquanto tal teoria seja de grande relevância no meio científico, diversos investidores, economistas financeiros, engenheiros financeiros e empresas do setor têm utilizado a análise técnica com desempenho satisfatório. Lui e More (1998, *apud* CAVALCANTE *et al*, 2015, p. 196) realizaram uma pesquisa em 1995 sobre a utilização da análise técnica e fundamentalista em Hong Kong. O resultado mostrou que 85% dos participantes responderam que ambos os métodos são utilizados e que o método da análise técnica é mais frequentemente utilizado para aplicações de curto prazo e para a definição de pontos de ajuste.

Na Tabela 1.1 segue um resumo estruturado das mais recentes dissertações de mestrado apresentadas sobre o tema de predição no país. Menezes (2015) utilizou variantes de redes neurais para prever o nível do Rio Negro, no Amazonas. Adentrando em sérias financeiras, Pommerenzenbaum (2014) aplicou redes neurais sobre o Ibovespa, sem, contudo, associar a um sistema de negociação. Em Souza (2017) é investigada a técnica de análise sobre os títulos de notícias financeiras atreladas aos métodos de aprendizado de máquinas para predição do índice S&P 500. Com exceção de Souza (2017), verifica-se a utilização de indicadores tradicionais da análise técnica e dados da série histórica. Tais informações são utilizadas como dados de entrada dos algoritmos elaborados para previsão de valores futuros de papéis. Em função dessas previsões os algoritmos sugerem a compra ou venda de papéis ou de contratos de índices e, ao final de um período, alguns apresentam a rentabilidade alcançada com o uso do algoritmo empregado, a exemplo de Santos (2014). Resumidamente, as técnicas utilizadas que compõem os algoritmos de negociação podem ser organizadas do seguinte modo (GAMBOGI, 2013):

- Modelos estatísticos
  - Lineares (ARIMA, GARCH, Filtros de Kalman, Suavização Exponencial)
  - Não-lineares (Teorema de Taken, Modelos de Markov, Autorregressão limiar, dentre outros)
- Modelos de Inteligência Computacional
  - Métodos de aprendizado de máquinas (RNA, SVM, SVR)
  - Algoritmos Evolutivos (AG, PG, Estratégias Evolutivas)
  - Lógica *Fuzzy*

Tabela 1.1 – Resumo das dissertações sobre predição

<b>Autor (ano)</b>	<b>Técnicas</b>	<b>Objeto</b>
SOUZA (2017)	SA, RNA, KNN	Ações do S&P 500
MENEZES (2015)	FNN	Nível do Rio Negro
POMMER. (2014)	MLP	Série Ibovespa
SANTOS (2014)	SVM, KNN com L <sub>MIN</sub> MAX	Diversos papéis da Bovespa
GAMBOGI (2013)	Previsão de um passo com MLP	Índice S&P 500
COSTA (2012)	Rede NARX e FTDNN	Diversos papéis da Bovespa

No âmbito internacional, o número de trabalhos sobre o tema parece ser mais abundante. Pommeranzenbaum (2014) destaca e considera que é uma surpresa o fato do Brasil, comparado aos países desenvolvidos, apresentar poucos trabalhos sobre o tema, uma vez que a Bolsa de Valores de São Paulo (Bovespa), a maior do Brasil, é a oitava maior do mundo em capitalização de mercado (US\$ 1,3 trilhão), sendo a americana *New York Stock Exchange* (NYSE) a maior do mundo, de acordo com publicação da revista *Exame*<sup>1</sup> em 2016. Ainda mais, sendo o Brasil um mercado emergente, apresenta muitas oportunidades de investimento.

Para realizar um breve resumo do que ocorre no âmbito internacional, a tabela 1.2 apresenta um breve resumo dos artigos publicados em nível internacional. Uma revisão completa sobre o assunto foi publicada por Cavalcante *et al* (2016), que fez um apanhado dos trabalhos sobre o tema no período compreendido entre 2009 e 2015. Nesse estudo, os autores apresentam uma tabela com 56 artigos publicados neste período, que foram considerados estudos seminais sobre o tema. A maioria dos trabalhos faz uso de indicadores técnicos, ou seja, da análise técnica, que de algum modo usam exclusivamente os valores passados das séries, não acrescentando informações extras, tais como indicadores de análise fundamentalista ou outras variáveis que interferem no cenário macroeconômico, como inflação, juros etc.

Tabela 1.2 – Alguns artigos publicados sobre o tema

<b>Autor (ano)</b>	<b>Técnicas</b>	<b>Objeto</b>
MOTLAGH e KHALOOZADEH (2016)	RNN, RTRL, NARX	Ações de Teerã
CAVALCANTE e OLIVEIRA (2015)	ELM, DDM	Redes Financeiras
DING <i>et al</i> (2015)	SA, NTN	Índice S&P 500
CHANG <i>et al</i> (2014)	SA, TA	Ações de Taiwan
XIONG <i>et al</i> (2013)	EMD, SBM, FNN	Cotação preço petróleo
ZHU e WEI (2013)	AG, SVM	Preço do carbono
LIANG <i>et al</i> (2013)	SVR e notícias da <i>internet</i>	Valor de índices
EVANS <i>et al</i> (2013)	MLP, AG	Taxas de câmbio
OLIVEIRA <i>et al</i> (2011)	MLP	Preço de ações
BAO <i>et al</i> (2011)	SVR	Cotação preço petróleo

<sup>1</sup> Disponível em: <http://exame.abril.com.br/mercados/as-10-maiores-bolsas-do-mundo-em-capitalizacao-de-mercado>. Acesso em: 21/06/2017.

Na maioria das vezes que a técnica de Redes Neurais é utilizada para predição, emprega-se com mais frequência a rede *Multi Layer Perceptron* (MLP). Em Oliveira *et al* (2011) foram investigadas várias configurações de MLP, variando-se o tamanho da janela e o horizonte de predição. Nesse trabalho o preço de uma ação de uma empresa brasileira do ramo do petróleo, de código PETR4, e chegou-se à conclusão que, neste caso, o melhor resultado se deu para predição de um dia a frente. Por sua vez, em Evans *et al* (2013), um modelo baseado em Redes Neurais MLP e Algoritmos Genéticos (AG) foi proposto para prever taxas de câmbio de diferentes moedas com base em um histórico de 70 semanas de dados. Em Chang *et al* (2014) é apresentado um sistema de negociação que usa redes neurais baseadas em *Technical Analysis* (TA) e *Sentimental Analysis* (AS), através de processamento de notícias dos ativos na internet, bem como uma aplicação em conjunto das técnicas, isso para o grupo de ações negociadas na bolsa de valores em Taiwan. Ainda no âmbito de processamento de notícias, Ding *et al* (2015) conseguiu, para o índice S&P 500 e ações individuais, através de uso de *Neural Tensor Network* (NTN) prever movimentos diários com margem satisfatória de acertos. Motlagh e Khaloozadeh (2016) utilizaram a rede NARX para realizar previsões do mercado de ação de Teerã, no Irã. Cavalcante e Oliveira (2015) investigaram o efeito de escorregamento (*drift*) que é observado quando, por exemplo, uma companhia muda sua política de investimentos ou quando as expectativas dos investidores são alteradas quando ocorrem mudanças na estrutura ou direção das companhias. Os autores propuseram um algoritmo que usa a detecção de tal efeito para melhorar a estimativa dos valores futuros.

Com base no que foi apresentado nos parágrafos anteriores, verifica-se que as possibilidades de aplicação nesta área do conhecimento são abundantes e já muito exploradas. No entanto, este trabalho propõe uma nova metodologia para previsão do comportamento futuro dos valores de ações ainda não abordada na literatura. Faz-se necessário que academia brasileira desenvolva o tema a fim de fornecer as bases para que os investimentos em renda variável, seja através de órgãos públicos ou privados, possam ser realizados de forma criteriosa.

### 1.3. Objetivos

O principal objetivo desse trabalho é propor uma metodologia original de aconselhamento de operações de compra e venda de papéis, objetivando o lucro do investidor no mercado de ações. A proposta consiste de um sistema de negociação com regras que utilizam como entrada as previsões da série Ibovespa, fornecidas por uma rede *Nonlinear AutoRegressive model* (NAR) e aplicação do indicador de mínimos e máximos desenvolvido neste trabalho para tomada de decisão de investir e desinvestir.

É importante ressaltar que o método proposto não tem o objetivo de alcançar acertos integrais e, com isso, gerar rentabilidades altas, isentas de risco. Trata-se de uma abordagem que utiliza informações de uma série histórica de valores de cotação de ações. Neste sentido, a EMH é posta à prova, mesmo que em um cenário pontual, limitado a um intervalo de tempo do mercado que não coexiste com nenhuma grande crise mundial, normalmente responsáveis pelas grandes perdas financeiras dos vários *players*.

Como contribuição deste trabalho, podemos dizer que, ao longo da explanação do sistema de negociação e suas regras, será proposto um indicador técnico baseado em ajuste polinomial de curvas que pode ser utilizado para indicação de mínimos e máximos de séries temporais.

### 1.4. Organização do Trabalho

No Capítulo 1, direcionado a uma breve revisão bibliográfica, é também apresentado alguns aspectos que justificam a escolha do tema, bem como um breve relato de suas contribuições.

No Capítulo 2 é apresentado um resumo dos principais tópicos acerca do mercado financeiro. Apresenta-se um maior detalhamento sobre o papel de uma empresa, o que são as bolsas de valores e como surgem os índices nas bolsas de valores. Apresenta-se, ainda, a título de exemplo, algumas séries temporais do mercado financeiro dos últimos anos, e uma breve explanação sobre cada uma. Também são apresentados alguns indicadores da análise técnica e da análise fundamentalista.

Uma teoria sobre as Redes Neurais Artificiais é apresentada no Capítulo 3. De forma resumida, mostra-se alguns exemplos de redes neurais, desde um caso simples, o *perceptron* com duas entradas, até os casos mais completos, como o MLP. uma das ferramentas mais utilizadas na literatura para predição. O algoritmo de treinamento das redes neurais é apresentado na sua forma mais básica e, em seguida, são apresentados exemplos de redes dinâmicas recorrentes, a rede *Nonlinear AutoRegressive model with exogeneous inputs* (NARX) e a rede NAR, a rede que efetivamente é utilizada nesse trabalho para efetuar as predições do sistema de negociação proposto.

No Capítulo 4, apresenta-se o novo algoritmo de negociação proposto nesse trabalho, detalhando-se as regras que o compõem. Apresenta-se também um novo método para a extração de pontos de mínimos e máximos de uma série temporal conhecida, com base em ajustes de curvas de pontos anteriores e posteriores ao ponto examinado. Além disso, apresenta-se neste capítulo o “janelamento móvel”, que consiste da técnica utilizada para geração de diferentes séries históricas, que servem como dados de entrada às ferramentas de predição.

Na continuidade, o Capítulo 5 mostra o sistema de negociação proposto em operação, através de gráficos que mostram o seu desempenho. Mostra-se também esse sistema operando com uma rede NAR utilizando-se de dois critérios de parada do treinamento. Por fim, compara-se o desempenho desse sistema com outro apresentado em Santos (2014). Esse último utiliza uma metodologia baseada em SVM, porém, com objetivo idêntico ao do trabalho ora desenvolvido. No capítulo 6 apresentam-se as conclusões do trabalho.

No capítulo 7 encontra-se o registro de toda a base bibliográfica utilizada para o desenvolvimento deste trabalho, assim como os sítios da internet que serviram de fonte para a base de dados da série temporal utilizada na simulação. Nos anexos estão as principais funções do MATLAB® versão R2011a que foram utilizadas para o desenvolvimento da rotina de simulação do sistema de negociação.

## **2. Mercado Financeiro**

### **2.1. Introdução**

Mercado pode ser entendido como um espaço no qual as pessoas interessadas em vender algum produto ou serviço encontram-se com pessoas interessadas em comprar esse mesmo produto ou serviço. O espaço não precisa ser físico, podendo ser virtual. Nos mercados financeiros os produtos que estão à venda são os ativos financeiros (KERR, 2011). Os mercados financeiros são divididos em duas modalidades, de acordo com o prazo das operações: mercado de crédito e mercado de capitais. Os mercados de créditos, onde estão a maior parte das operações envolvendo instituições financeiras, visam suprir as necessidades de capitalização de empresas (capital de giro e ativo permanente), e o financiamento de consumo dos indivíduos, abrangendo empréstimos e financiamentos, entre outros. Nos mercados de capitais são realizadas operações de longo prazo por meio das quais os bancos fazem a intermediação entre empresas que necessitam de recursos e investidores interessados em aplicações de longo prazo, abrangendo as ações ou papéis.

### **2.2. Ações ou Papéis**

Ações são título que representam a menor fração em que se subdivide o capital social de uma empresa organizada sob a forma de sociedade anônima, representando um investimento permanente na empresa. O acionista é, portanto, um proprietário da companhia, participando dos resultados alcançados pela empresa, proporcionalmente à quantidade de ações que possui.

As ações podem ser classificadas em ordinárias, preferenciais e de gozo ou fruição. As ações ordinárias, como o próprio nome diz, são ações comuns, e seus possuidores têm todos os direitos e obrigações de legítimos proprietários da empresa. Naturalmente, tais acionistas têm direito a voto nas assembleias de acionistas, nas quais cada ação equivale a um voto. Ações preferenciais são, ao contrário do que o nome sugere, aquelas em que os seus possuidores têm restrição de direitos em relação aos acionistas comuns

(possuidores de ações ordinárias), não podendo votar nas assembleias de acionistas. Os acionistas preferenciais têm prioridade no recebimento de dividendos e, em caso de liquidação, também têm prioridade no recebimento do reembolso de capital. Ação de gozo ou fruição, praticamente não existem no Brasil. São ações de posse e propriedade dos sócios-fundadores da sociedade, já amortizadas, pois o titular recebeu, antecipadamente, o valor contábil que elas representavam e, portanto, não são negociadas em bolsa.

### **2.3. Bolsa de Valores e Corretoras de Valores**

As Bolsas de Valores são instituições privadas cujo objetivo é manter um local ou um sistema adequado para a realização de operações de compra e venda de títulos e valores mobiliários. As bolsas de valores no Brasil são fiscalizadas pela Comissão de Valores Mobiliários (CVM) e regulamentadas pela Resolução do Conselho Monetário Nacional (CMN) 2.690 de 2000.

A Bolsa de Valores de São Paulo (Bovespa) e a Bolsa de Mercadorias e Futuros (BM&F) uniram-se em 2008, criando a BM&F-Bovespa. A Bovespa havia aberto seu capital no dia 26 de outubro de 2007, e a BM&F havia feito o mesmo em 30 de novembro do mesmo ano. Em 26 de março de 2008, os jornais noticiaram a fusão e a criação da BM&F-Bovespa, na ocasião a segunda maior bolsa da América, atrás apenas da *Chicago Mercantile*, nos Estados Unidos (KERR, 2011).

As bolsas de valores têm grande importância para os agentes econômicos e a sociedade, pois, através delas, é possível que as empresas consigam capital para aplicação em projetos de investimento que podem aumentar a produção de bens ou mesmo a oferta de serviços. Mais do que isso, através delas é possível que pequenos investidores possam fazer parte de grandes corporações, recebendo os benefícios que venham a ter, proporcionalmente as suas participações.

O mercado de ações pode ser classificado como primário e secundário. Diz-se que o mercado é primário quando as ações são lançadas pela primeira vez, através de um *Initial Public Offerings* (IPO), e o dinheiro arrecadado, livre de custos, vai para a empresa emitente. Diz-se que o mercado é secundário quando essas ações mudam de mãos: quando

negociados pelos seus proprietários para outros acionistas. Os valores envolvidos apenas trocam de mãos, de uma acionista para outro, sem financiar projetos de investimento da empresa emitente.

A figura 2.1 mostra os valores históricos do índice Ibovespa, que é uma carteira composta das ações mais negociadas na BM&F-Bovespa, entre janeiro de 1995 e novembro de 2010. O índice se valorizou significativamente no longo prazo, embora tenha havido turbulências durante todo o período. A maior foi causada pela última crise imobiliária nos Estados Unidos da América, conhecida como *subprime*.

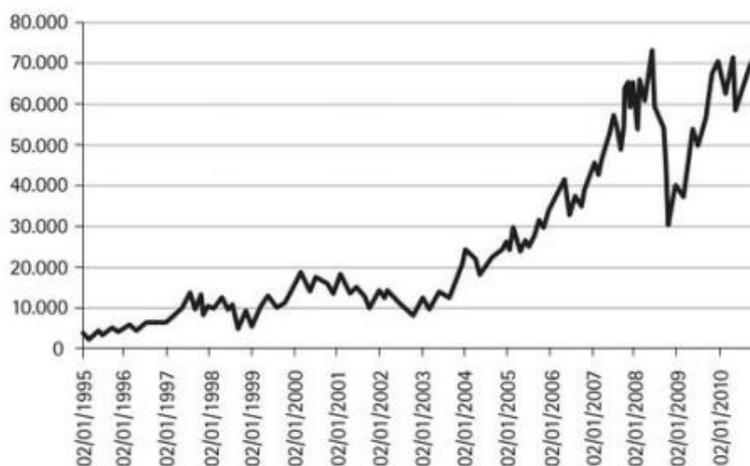


Figura 2.1 - Evolução do índice Ibovespa: adaptado de Kerr (2011)

As corretoras de títulos e valores imobiliários são instituições típicas do mercado de ações têm vários objetivos, dentre os quais destacamos: comprar e vender títulos e valores mobiliários por conta própria e de terceiros; encarregar-se da administração de carteiras e da custódia de títulos e valores mobiliários; exercer funções de agente fiduciário; instituir, organizar fundos e clubes de investimento; emitir certificados de depósito de ações e cédulas pignoratícias de debêntures, que são títulos de dívidas de uma empresa; intermediar operações de câmbio.

## 2.4. Índices de Desempenho

O desempenho médio das ações listadas em uma bolsa costuma ser medido por um índice de valorização das ações. Quase todos já ouviram falar do índice *Dow Jones* da *New York Stock Exchange* (NYSE), ou do S&P500 publicado pela *Standard & Poor's*. No Brasil, quase todos conhecem, ou já ouviram falar, do índice Bovespa (Ibovespa). Ele é o índice mais conhecido e mais utilizado, calculado desde 4 de junho de 1986 pela Bovespa, sem alterações de metodologia de cálculo (KERR, 2011). O **Ibovespa** é calculado pela seguinte fórmula:

$$Ibovespa_t = \sum_{i=1}^n P_{i,t} Q_{i,t}, \quad (2.1)$$

Onde:

$Ibovespa_t$  = Ibovespa no instante t;

$n$  = número total de ações componentes do Ibovespa;

$P_{i,t}$  = último preço da ação i no instante t;

$Q_{i,t}$  = quantidade teórica da ação i no Ibovespa, no instante t;

Existem alguns critérios para que a ação pertença ao índice. Caso algum deles não seja obedecido, a ação sai do índice.

## 2.5. A Hipótese de Mercado Eficiente (*Efficient Market Hypothesis* - EMH)

A **avaliação de ações** tem vez quando se compra ações e se espera obter retorno através de sua valorização e distribuição de dividendos, caso tenham ocorrido. Dividendos são uma parcela dos lucros auferidos que são distribuídos aos acionistas. Em um mercado perfeito ou eficiente, dividendos e valorização não deveriam fazer nenhuma diferença (KERR, 2011).

Diz-se que um mercado é eficiente quando os preços se ajustam rapidamente à chegada de novas informações. Portanto, um mercado eficiente é aquele em que os preços das ações refletem todas as informações disponíveis sobre aquele ativo. Nesse contexto, não seria possível prever com eficiência o movimento futuro dos valores dos ativos, uma vez que o mercado é eficiente e não deixa margem para tanto.

## 2.6. Índices Futuros

As expressões “termos” ou “futuros” indicam contratos que preveem a entrega de um determinado ativo (denominado ativo-objeto), seja ele uma *commodity* ou não, em uma certa data futura, contra o pagamento de um certo valor pré-estipulado. Existem mercados futuros de índices, em que são negociados contratos futuros dos preços de índices, como o Ibovespa. Quanto mais próximo da data de vencimento, mas próximo o preço do contrato estará do índice que é o ativo-objeto. A BM&F-Bovespa explica, através de seu sítio eletrônico, que:

“como comprador ou vendedor do contrato a termo, você se compromete a comprar ou vender certa quantidade de um bem (mercadoria ou ativo financeiro) por um preço fixado, na data de realização do negócio. A data de realização do negócio e a realização são pré-estabelecidos para uma data futura. Os contratos a termo somente são liquidados integralmente no vencimento. Podem ser negociados em bolsa ou mercado de balcão.

[...] deve-se entender o mercado futuro como uma evolução do mercado a termo. Você se compromete a comprar ou vender certa quantidade de um ativo por um preço estipulado para liquidação em data futura. A definição é semelhante, tendo como principal diferença a liquidação de seus compromissos somente na data de vencimento, no caso do mercado a termo. Já no mercado futuro, os compromissos são ajustados diariamente às expectativas do mercado referentes ao preço futuro daquele bem, por meio do ajuste diário (mecanismo que apura perdas e ganhos). Além disso, os contratos futuros são negociados somente em bolsas.”

## 2.7. Avaliação de ações

Não só a abertura de capital de uma empresa, mercado primário, mas também as suas negociações posteriores, mercado secundário, podem trazer benefícios econômicos para quem as pratica. Além de diversos indicadores que foram criados com o intuito de auxiliar na tomada de decisão, são duas as principais subdivisões de avaliação de ação: análise fundamentalista e análise técnica.

### **2.7.1. Análise Fundamentalista**

Este método pressupõe que é possível prever o valor futuro dos ativos a partir das demonstrações contábeis publicadas e informações microeconômicas e macroeconômicas, como o Produto Interno Bruto (PIB). As demonstrações contábeis são de publicação obrigatória pelas empresas de capital aberto, ou seja, que tenham suas ações negociadas em bolsa de valores. O volume de informações é grande, de tal forma que os analistas tendem a se especializar em determinados ramos ou empresas.

### **2.7.2. Análise técnica (gráfica)**

Neste tipo de análise, sustenta-se a ideia de que o comportamento dos preços passadas podem ajudar a prever o comportamento dos preços futuros. Não se leva em consideração as causas, mas somente o movimento dos preços. Para tal análise, os analistas usam normalmente gráficos históricos, alguns contendo o chamado *candlestick* japonês, que são símbolos atribuídos ao movimento dos preços e que podem indicar o momento de comprar ou vender um papel. Aqui não se considera a EMH. Considera-se que: o preço é função da oferta e demanda; os motivos das ações de oferta e demanda são ora racionais, ora irracionais; os mercados seguem uma tendência, estando sujeito apenas a oscilações desconsideráveis.

## **2.8. Séries do Mercado Financeiro**

A predição de séries financeiras tem sido bastante estudada por matemáticos, engenheiros, economistas etc. A razão é bastante simples: negociar os ativos financeiros tomando como base a predição de valores dos mesmos pode gerar benefícios econômicos razoáveis. O que se procura predizer são as cotações dos preços das ações, índices, indicadores e taxa de câmbio das moedas.

A série temporal utilizada neste trabalho é a série do índice Ibovespa. Para facilitar as operações, sem perda de generalidade, será simulado a compra e a venda do índice que tem um resultado semelhante a comprar e vender um fundo de investimento que tenha a

composição semelhante ao índice e que, portanto, tem desempenho semelhante. Conforme visto anteriormente, o índice é calculado pela equação 2.1. Abaixo, na tabela 2.1, segue a relação dos ativos que compõem o mesmo, com seus respectivos códigos. Importante notar que as quatro maiores empresas a compor o índice em 18/04/2017 eram: Itaú, Bradesco, Petrobras, Vale e Ambev.

Tabela 2.1 – Carteira teórica do Ibovespa (em 18/04/2017)

Código	Ação	Tipo	Part. (%)	Código	Ação	Tipo	Part. (%)
ABEV3	AMBEV S/A	ON	7,452	ITSA4	ITAUSA	PN N1	3,482
BBAS3	BRASIL	ON NM	3,701	ITUB4	ITAUUNIBANCO	PN N1	11,534
BBDC3	BRADESCO	ON N1	1,699	JBSS3	JBS	ON NM	1,514
BBDC4	BRADESCO	PN N1	8,098	KLBN11	KLABIN S/A	UNT N2	0,619
BBSE3	BBSEGURIDADE	ON NM	1,842	KROT3	KROTON	ON NM	1,861
BRAP4	BRADSPAR	PN N1	0,403	LAME4	LOJAS AMERIC	PN	1,011
BRFS3	BRF SA	ON NM	2,892	LREN3	LOJAS RENNER	ON NM	1,762
BRKM5	BRASKEM	PNA N1	0,776	MRF3	MARFRIG	ON NM	0,175
BRML3	BR MALLS PAR	ON NM	0,788	MRVE3	MRV	ON NM	0,404
BVMF3	BMFBovespa	ON NM	3,733	MULT3	MULTIPLAN	ON N2	0,524
CCRO3	CCR SA	ON NM	1,841	NATU3	NATURA	ON NM	0,501
CIEL3	CIELO	ON NM	2,575	PCAR4	P.ACUCAR-CBD	PN N1	0,888
CMIG4	CEMIG	PN N1	0,735	PETR3	PETROBRAS	ON	3,742
CPFE3	CPFL ENERGIA	ON NM	0,79	PETR4	PETROBRAS	PN	5,436
CPLE6	COPEL	PNB N1	0,287	QUAL3	QUALICORP	ON NM	0,409
CSAN3	COSAN	ON NM	0,554	RADL3	RAIADROGASIL	ON NM	1,167
CSNA3	SID NACIONAL	ON	0,433	RAIL3	RUMO S.A.	ON NM	0,627
CYRE3	CYRELA REALT	ON NM	0,312	RENT3	LOCALIZA	ON NM	0,63
ECOR3	ECORODOVIAS	ON NM	0,175	SANB11	SANTANDER BR	UNT	0,937
EGIE3	ENGIE BRASIL	ON NM	0,668	SBSP3	SABESP	ON NM	1,037
ELET3	ELETROBRAS	ON N1	0,382	SMLE3	SMILES	ON NM	0,354
EMBR3	EMBRAER	ON NM	1,116	SUZB5	SUZANO PAPEL	PNA N1	0,456
ENBR3	ENERGIAS BR	ON NM	0,3	TIMP3	TIM PART S/A	ON NM	0,78
EQTL3	EQUATORIAL	ON NM	1,1	UGPA3	ULTRAPAR	ON NM	2,714
ESTC3	ESTACIO PART	ON NM	0,484	USIM5	USIMINAS	PNA N1	0,181
FIBR3	FIBRIA	ON NM	0,594	VALE3	VALE	ON N1	3,8
GGBR4	GERDAU	PN N1	0,778	VALE5	VALE	PNA N1	4,847
GOAU4	GERDAU MET	PN N1	0,242	VIVT4	TELEF BRASIL	PN	1,807
HYPE3	HYPERMARCAS	ON NM	1,131	WEGE3	WEG	ON NM	0,92

Fonte: Sítio da internet da BM&F-Bovespa<sup>2</sup>

A série em si é a matriz que relaciona data e valor do índice. Todo dia útil em que há pregão na bolsa de valores o índice é calculado. Aliás, o cálculo do mesmo é feito a todo momento, durante o horário das operações. Os bancos de dados das empresas que armazenam os históricos dessas séries, para cada dia, normalmente guardam quatro

<sup>2</sup> Disponível em: <http://www.bmfbovespa.com.br>. Acesso em: 18/04/2017.

valores principais de um dia de pregão, quais sejam: o valor de abertura, o valor de fechamento, o valor mínimo e o valor máximo. Os valores que serão utilizados neste trabalho advêm da série que representa **o valor de fechamento do índice Ibovespa nas segundas-feiras**, ajustados aos dividendos (seção 2.5) e desdobramentos, pela conveniência, já que são as séries disponíveis no sítio da internet consultado.

Desdobramento são operações que alteram o número de ações e o valor de cada ação em posse dos sócios, porém, não alteram o montante que os mesmos possuem, por exemplo, suponha que um sócio A possua 50 ações que tem o preço de R\$ 20,00 cada, portanto, o mesmo possui um montante de R\$ 1.000,00 em ações. Os controladores da empresa ao realizarem o desdobramento das ações, por exemplo, podem transformar cada ação em 4. Portanto, o sócio A terá agora  $50 \times 4 = 200$  ações. Para equilibrar a operação, o valor de cada ação será reduzido para R\$ 5,00, de modo que o montante em posse do sócio A será o mesmo de antes, ou seja,  $200 \times \text{R\$ } 5,00 = \text{R\$ } 1.000,00$ .

Ajustar aos desdobramentos é importante, caso contrário, o papéis analisados sem o ajuste terão variações bruscas – no exemplo acima a variação é de R\$ 20,00 para R\$ 5,00 de um dia para o outro – nos preços em função dos desdobramentos. Estas variações não terão relação com o movimento do valor do ativo por parte de demanda e oferta, mas sim, com o desejo de a empresa negociar cada papel a valores menores, tornando-o mais acessível aos pequenos investidores.

## 3. Rede Neural Artificial (RNA)

### 3.1. Introdução

Redes Neurais Artificiais (RNA) são inspiradas no funcionamento do cérebro humano. Embora os cientistas tenham pouco conhecimento acerca do funcionamento cerebral, sabe-se que os neurônios são a base de todo o processamento de informação que ocorre nele. A base das RNA's também são os neurônios, porém, não os biológicos, mas uma simplificada abstração destes (HAYKIN, 1999). Na figura 3.1 há um desenho simplificado de dois neurônios biológicos com suas principais partes citadas: dendritos; corpo celular; axônio; fenda sináptica. Os dendritos são como fios que recebem sinais elétricos proveniente de outros neurônios e enviam-nos ao corpo celular. Este corpo soma os sinais elétricos provenientes de vários dendritos. Se o valor dessa soma ultrapassa um limiar biológico de tensão, um pulso é produzido e conduzido através do axônio para os dendritos conectados ao corpo de outros neurônios. A conexão entre o axônio de um neurônio e os dendritos de outros é realizada pela fenda sináptica, onde ocorre um processo químico complexo, resultando na transmissão do sinal elétrico entre duas células de neurônios.

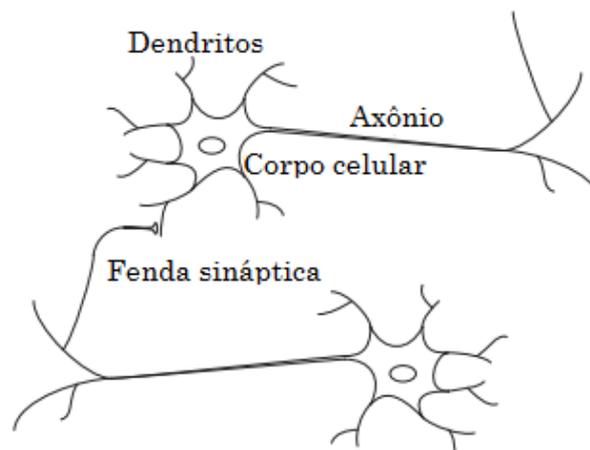


Figura 3.1 – Neurônio biológico e suas partes principais

Ao longo do processo de aprendizagem dos seres humanos, a força das conexões sinápticas se modifica. Acredita-se que a memória é formada pela mudança da intensidade dessas conexões. Exemplificando, decorar o nome de um novo professor se dá pela mudança na intensidade de tais conexões sinápticas.

A complexidade do neurônio matemático não se compara nem de longe à do neurônio biológico. No entanto, procurou-se, no primeiro, reproduzir conceitualmente algumas características do último, dentre as quais destacamos um grande número de conexões entre os neurônios artificiais e a funcionalidade do processamento incorporada aos pesos existentes nessas conexões (GUYON, 1991).

### 3.2. Representação das Redes

Um neurônio com múltiplas entradas, também chamado de *perceptron*, utiliza a função de transferência degrau (*hardlim*) e pode ser visto na figura 3.2. Nessa figura, as entradas individuais  $u_1, u_2, u_3, \dots, u_R$ , constituem-se nas coordenadas do vetor de entrada  $\mathbf{u}$ . O valor de cada entrada é multiplicado pelo respectivo peso, que pode ser  $w_{1,1}, w_{1,2}, w_{1,3}, \dots, w_{1,R}$ . Esses pesos formam a matriz de pesos  $\mathbf{W}$ . Há também a entrada unitária, que é multiplicada por  $b$ , chamado de polarização (*bias*), que é somada com as entradas multiplicadas pelos pesos para formar a entrada líquida  $n$  da função de transferência  $f$ :

$$n = w_{1,1}u_1 + w_{1,2}u_2 + w_{1,3}u_3 + \dots + w_{1,R}u_R + b = \mathbf{W}\mathbf{u} + b. \quad (3.1)$$

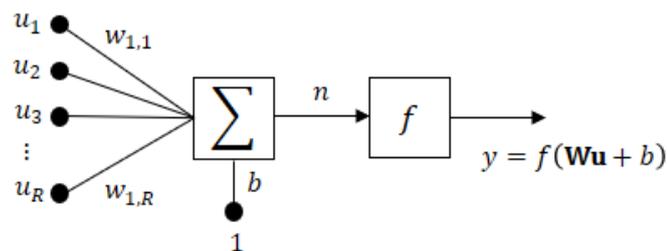


Figura 3.2 – Neurônio de múltiplas entradas com função de transferência  $f = \text{hardlim}$ , também chamado de perceptron.

Como mostrado na figura 3.2 o valor de  $n$  constitui-se na variável independente da função  $f$ . A saída da rede é então dada por:

$$y = f(\mathbf{W}\mathbf{u} + b). \quad (3.2)$$

Na figura 3.3, tem-se a chamada *notação abreviada*, que é outra forma de representar o neurônio de múltiplas entradas. Esta notação será utilizada neste trabalho e é apresentada na obra de Hagan *et al* (2014), autores do *toolbox* de redes neurais no MATLAB®. Nesta notação, o vetor de entrada  $\mathbf{u}$  tem dimensões  $R \times 1$ . O vetor  $\mathbf{u}$  é multiplicado pela matriz  $\mathbf{W}$  que, nesse caso, tem  $R$  colunas e uma linha, já que a arquitetura da rede é constituída de apenas um neurônio. Observamos que, na notação abreviada, a matriz de pesos  $\mathbf{W}$ , a polarização  $b$  e a função de transferência  $f$  são representados cada um por um bloco.

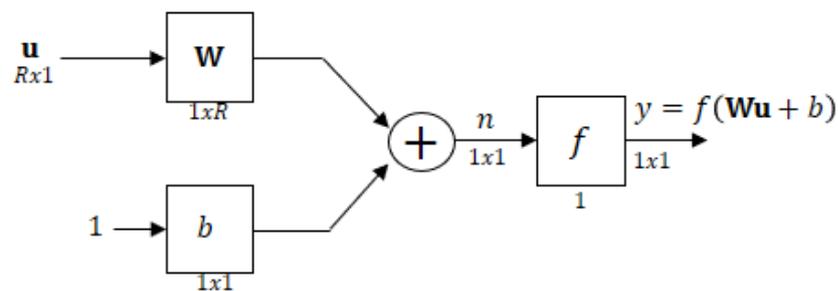


Figura 3.3 – Neurônio de múltiplas entradas com notação abreviada

O poder computacional de uma arquitetura com um único neurônio é muito pequeno. Em termos de complexidade, uma arquitetura com vários neurônios na primeira camada, todos operando em paralelo, tem um poder computacional bem maior. Uma RNA com uma arquitetura de uma camada com  $S$  neurônios é representada do lado esquerdo da figura 3.4, enquanto que, do lado direito, mostra-se a notação abreviada da mesma. Nesse caso, é evidente que a notação abreviada gera uma representação mais compacta da RNA. É possível verificar que cada uma das  $R$  entradas está conectada a cada um dos  $S$  neurônios e que, dessa vez, a matriz de pesos  $\mathbf{W}$  terá  $S$  linhas, uma para cada neurônio.

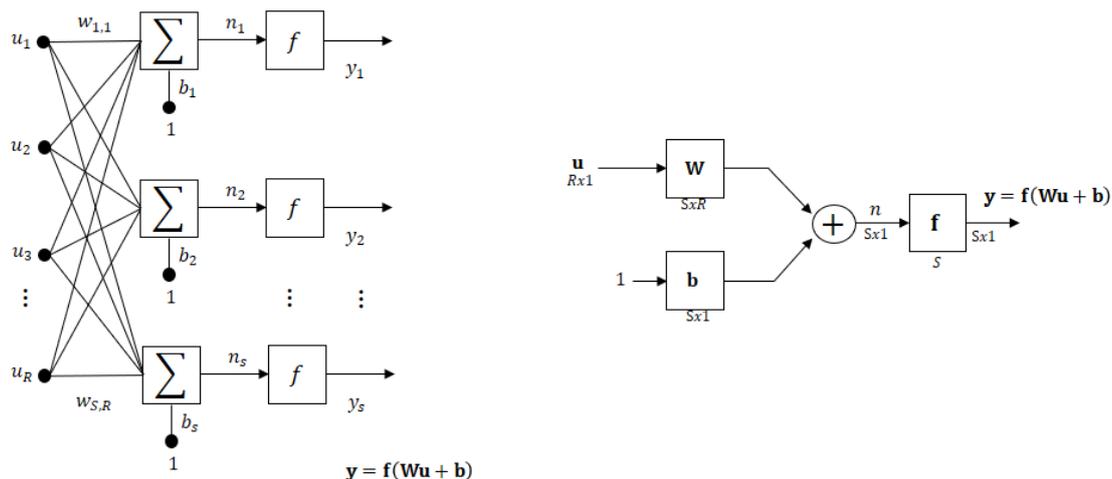


Figura 3.4 – RNA com uma camada de S neurônios

O nível de complexidade seguinte é termos uma RNA com uma arquitetura com várias camadas. Do ponto de vista da notação simplificada, a representação de cada camada inclui uma matriz de pesos, os somadores, o vetor de bias  $\mathbf{b}$ , o bloco de funções de transferência e o vetor de saída  $\mathbf{y}$ . Na figura 3.5 mostramos a representação de uma RNA com três camadas, utilizando a notação simplificada. A indicação que uma variável pertence a uma camada é feita através do índice sobrescrito.

Na figura 3.5 pode-se notar que existem  $R$  entradas,  $S^1$  neurônios na primeira camada,  $S^2$  neurônios na segunda e  $S^3$  neurônios na terceira. As saídas das camadas um e dois são também as entradas das camadas dois e três, respectivamente. A arquitetura da rede é descrita como:  $R - S^1 - S^2 - S^3$ , em que  $R$  representa o número de entradas da rede.

A camada que contém as saídas da RNA é chamada de camada de saída. As demais camadas são chamadas de camadas escondidas. Na figura 3.5, portanto, há uma camada de saída e duas camadas escondidas de neurônios. O poder computacional de uma RNA com múltiplas camadas é bem superior que o poder computacional de uma RNA com apenas uma camada, podendo as mesmas aproximarem funções, implementarem classificadores não lineares, etc.

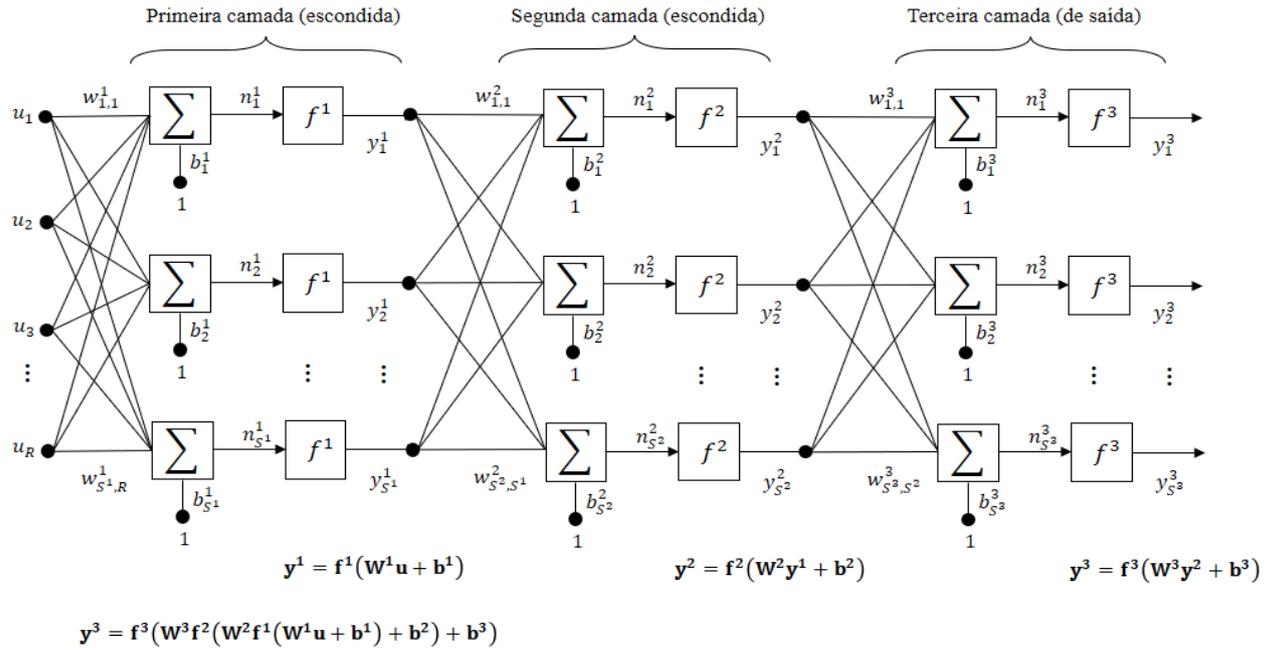


Figura 3.5 – RNA de múltiplas entradas e três camadas

### 3.3. Função de Transferência

A função de transferência  $y^N = f^N()$  citada nas seções anteriores pode ser linear ou não linear. A mesma é escolhida dependendo do tipo de problema que se quer solucionar. A função *hardlim* retorna zero se o argumento da função for menor do que zero e retorna um se o argumento for maior ou igual a zero. É utilizada quando se deseja, em um problema em que as classes são linearmente separáveis e se deseja classificar as entradas em duas ou mais categorias. Existe também a função linear que retorna o mesmo valor do argumento, ou seja,

$$y = n \quad (3.3)$$

Essa função, utilizada nas redes ADALINE, é chamada de *purelin* no Matlab.

A função denominada de *log-sigmoid* no Matlab coleta o argumento  $n$ , que pode variar de menos infinito a mais infinito, e gera uma saída que excursiona entre zero e um, de acordo com a expressão:

$$y = \frac{1}{1+e^{-n}}. \quad (3.4)$$

Esta última função é amplamente utilizada em RNA's com múltiplas camadas, pois, diferentemente da função *hardlim*, é diferenciável, e, portanto, pode ser utilizada no método de aprendizado de propagação reversa (*backpropagation*), usado onipresentemente para o treinamento das RNA's. Esse método de treinamento faz uso da técnica do gradiente descendente (RUMELHART *apud* GUYON, 1991, p. 224). Na figura 3.6 mostramos graficamente as funções citadas nessa seção.

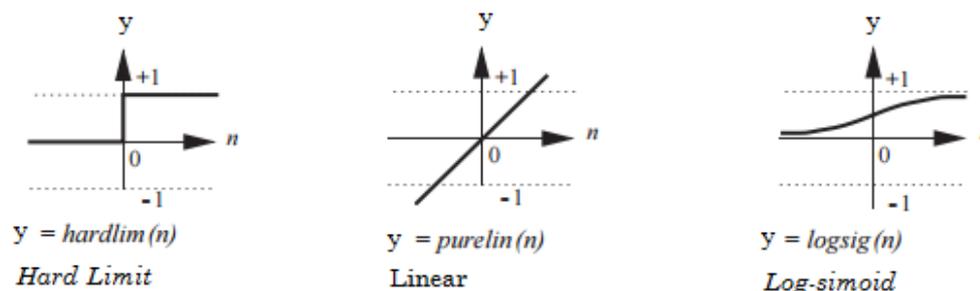


Figura 3.6 – Funções de transferência típicas

### 3.4. Treinamento das Redes

O treinamento das redes pode se dar através de dois métodos distintos: métodos de aprendizado supervisionados e métodos de aprendizado não supervisionados. Na categoria dos métodos supervisionados, apresenta-se à rede vários pares de vetores entrada-saída desejados, de modo que um algoritmo ajusta os pesos para fazer com que a rede consiga, a partir de um vetor apresentado à sua entrada, reproduzir o vetor de saída desejado. Na categoria dos métodos não supervisionados, as saídas desejadas não são apresentadas. Tais métodos realizam um agrupamento dos vetores em um número finito de classes com características semelhantes. Nesse trabalho utilizaremos o método de aprendizado supervisionado, uma vez que se dispõe de uma base de dados, com pares de vetores entrada-saída.

O método de treinamento supervisionado mais utilizado é o de propagação reversa. Conforme já dito, na propagação reversa atualiza-se o valor dos pesos através do algoritmo do gradiente descendente. O método de propagação reversa pode ser utilizado para o treinamento de redes com uma ou várias camadas. Este método é uma generalização de um outro mais simples, o *Least Mean Square* (LMS), que é utilizado

para redes com apenas uma camada (HAGAN *et al*, 2014). A diferença entre os mesmos, é que o primeiro faz uso de um mecanismo para atualização dos pesos das camadas escondidas, a “regra da cadeia”, enquanto que o método LMS não.

Como pode ser visto pela figura 3.5, em que uma rede com três camadas foi apresentada, a saída da RNA, generalizada para  $M$  camadas, é dada pela seguinte equação:

$$\mathbf{y}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1}\mathbf{y}^m + \mathbf{b}^{m+1}) \text{ para } m = 0, 1, \dots, M - 1. \quad (3.5)$$

No treinamento de uma rede RNA, apresenta-se a mesma vários pares de treinamento constituídos por vetores entrada-saída desejados. Estes pares irão determinar como a rede deve se comportar. Os pares estão representados pela expressão 3.6:

$$\{\mathbf{u}_1, \mathbf{a}_1\}, \{\mathbf{u}_2, \mathbf{a}_2\}, \dots, \{\mathbf{u}_Q, \mathbf{a}_Q\}. \quad (3.6)$$

Quando cada entrada é aplicada à entrada da RNA, a saída da mesma é calculada, representada por  $\mathbf{a}_o$ , e comparada com a saída desejada, representada pela letra  $\mathbf{a}_q$ . O método de treinamento deve ajustar os parâmetros da RNA de tal forma a minimizar o erro quadrático médio, dado pela expressão 3.7.

$$E_{QM} = \frac{\sum_{n=1}^Q (a_{on} - a_{qn})^2}{n} \quad (3.7)$$

Em que  $n$  é o índice do par entrada-saída apresentado à RNA.

O algoritmo irá ajustar os pesos que compõem a matriz de pesos  $\mathbf{W}$  para fazer com que o erro quadrático médio seja minimizado, de forma a tentar obter uma rede que reproduza, com fidedignidade, os valores de saída dos pares entrada-saída.

Isso é conseguido da seguinte forma. Primeiramente, é necessário inicializar os pesos da matriz de pesos. Essa inicialização é feita de forma aleatória. A entrada da rede ( $\mathbf{y}^0$ ) é feita então igual a um vetor de entrada, conforme mostrada na expressão 3.8.

$$\mathbf{y}^0 = \mathbf{u}_i \quad (3.8)$$

Ocorre então, a propagação direta, com a saída de cada camada ( $\mathbf{y}^{m+1}$ ) sendo calculada utilizando-se, como entrada, a saída da camada anterior ( $\mathbf{y}^m$ ), conforme mostrado na equação 3.9. A saída da rede,  $\mathbf{y}$ , será a saída da última camada  $M$ ,  $\mathbf{y}^M$ .

$$\mathbf{y}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1}\mathbf{y}^m + \mathbf{b}^{m+1}) \text{ para } m = 0, 1, \dots, M - 1,$$

$$\mathbf{y} = \mathbf{y}^M. \quad (3.9)$$

Depois da propagação direta, inicia-se a propagação reversa. Na mesma, calcula-se primeiramente  $\mathbf{s}^M$ , definida como a sensibilidade da última camada. Em seguida, dispondo-se da sensibilidade da última camada  $\mathbf{s}^M$ , calcula-se a sensibilidade da camada  $\mathbf{s}^{M-1}$ . Esse processo se repete até se chegar ao cálculo da sensibilidade da primeira camada,  $\mathbf{s}^1$ . O cálculo da sensibilidade da camada  $\mathbf{s}^M$  é feito através da expressão 3.10. O cálculo das sensibilidades, através da propagação reversa, é feito através da expressão 3.11.

$$\mathbf{s}^M = -2\dot{\mathbf{F}}^M(\mathbf{n}^M)(\mathbf{a} - \mathbf{y}), \quad (3.10)$$

Em que:

$\dot{\mathbf{F}}^M$ : matriz de derivadas das funções de transferência dos neurônios da camada  $m$ .

$\mathbf{n}^M$ : entrada líquida da camada  $m$ .

$$\mathbf{s}^m = \dot{\mathbf{F}}^m(\mathbf{n}^m)(\mathbf{W}^{m+1})^T \mathbf{s}^{m+1}, \text{ para } m = M - 1, \dots, 2, 1. \quad (3.11)$$

Por último, os pesos e polarizações são atualizados usando o algoritmo do gradiente descendente. Nesse algoritmo, o parâmetro  $\alpha$  (alfa) é a taxa de aprendizado utilizada para atualização dos pesos e polarizações, conforme mostrado nas expressões 3.12 e 3.13. Para evitar-se oscilações, o valor de  $\alpha$  é normalmente feito bem menor do que 1.

$$\mathbf{W}^m(k + 1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{y}^{m-1})^T, \quad (3.12)$$

$$\mathbf{b}^m(k + 1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m. \quad (3.13)$$

O método anteriormente descrito corresponde a versão original do algoritmo de propagação reversa. Ao longo do tempo, várias modificações foram realizadas no intuito

de aumentar sua velocidade e a capacidade de convergência para um ponto de mínimo que minimize o valor do erro quadrático médio. As melhorias foram alcançadas através da utilização de outros métodos de treinamento, tais como: método do gradiente conjugado; método de *Newton*; método de *Gauss-Newton*; método de *Levenberg-Marquadt*, dentre outros, sendo este último o método aplicado neste trabalho.

Normalmente, a arquitetura da rede neural é customizada para cada problema, sendo necessário definir: o número de camadas, o número de neurônios nas camadas, as funções de transferência a serem utilizadas nas diversas camadas, e assim por diante (HAYKIN, 1999). É natural pensar que quanto mais complexo o problema, maior a quantidade de dados que serão necessários para o treinamento e maior será a estrutura da rede. Nem sempre, no entanto, estruturas maiores correspondem a um melhor desempenho. O segredo está em se determinar uma rede com menor estrutura que seja capaz de resolver o problema. Normalmente, essa rede com menor estrutura é que terá um melhor poder de generalização.

### 3.5. Redes Dinâmicas Recorrentes

As redes neurais podem ser classificadas em duas categorias: estáticas ou dinâmicas. Nas redes neurais estáticas a saída é calculada diretamente das entradas, no que é conhecido como propagação direta (*feedforward*). Numa rede estática, uma saída no instante  $n$  depende apenas da entrada no instante  $n$ . Já nas redes dinâmicas, há uma dependência da saída não somente com as entradas atuais, mas também com as entradas passadas, que normalmente são realimentadas através de malhas de realimentação (*feedback*). Dizemos que uma rede neural dinâmica tem memória. Devido a essa característica, pode ser treinada para captar padrões sequenciais ou variantes no tempo. Essas redes são normalmente aplicadas, com bom desempenho nos seguintes tipos de problemas: predição no mercado financeiro (COSTA, 2012); controle de sistemas dinâmicos (CLAUMANN *et al*, 2001); detecção de harmônicos em sistemas de potência (TERMUTAS *et al*, 2004); predição de vazão e nível de reservatórios (CHEN *et al*, 2013); etc.

Uma rede dinâmica contém blocos de atraso e integradores, de tal sorte que os valores futuros dependerão de valores passados. Uma rede dinâmica é denominada de

recorrente quando contém realimentação (*feedback*): algumas de suas saídas são realimentadas para as entradas.

O algoritmo de propagação reversa é utilizado para o treinamento de redes dinâmicas, porém, algumas alterações são necessárias para o cálculo das derivadas. Existem duas principais formas de proceder o treinamento das redes dinâmicas: *BackPropagation Through Time* (BPTT) e *Real Time Recurrent Learning* (RTRL). Esta última requer uma maior quantidade de cálculos que a primeira, sendo, no entanto, mais propícia para uma aplicação em tempo real (HAGAN *et al*, 2014), pois exige menor uso de memória. Neste trabalho se utiliza o treinamento do tipo BPTT.

### 3.6. Critério de Parada no Treinamento das Redes

Na maioria das aplicações de redes neurais, os erros que balizam o processo de treinamento não convergem identicamente para zero. Sendo assim, ao invés de se utilizar o próprio erro quadrático médio (*Mean Square Error* - MSE), pode-se utilizar, alternativamente, a norma do gradiente do mesmo. Normalmente o valor de  $10^{-6}$  pode ser usado como limiar (HAGAN *et al*, 2014, p. 22-15).

No método de **parada antecipada** (*early stopping*), o conjunto de dados de treinamento é utilizado para calcular os gradientes e atualizar pesos e polarizações, durante a propagação reversa. No entanto, outro conjunto de dados, o conjunto de validação, é utilizado para monitorar o término do treinamento. O método de parada antecipada é normalmente utilizado para prevenir o sobreajuste (*overfitting*) no treinamento da RNA. Nesse método, para-se o treinamento quando o valor do erro quadrático médio no conjunto de dados de validação aumentar seguidamente, por um determinado número de iterações.

O método de parada antecipada melhora a generalização da rede reduzindo o esforço computacional, pois normalmente ele irá parar o processo de treinamento antes do critério MSE.

As redes utilizadas neste trabalho terão dois critérios de parada: o erro quadrático médio e o critério da parada antecipada.

### 3.7. Pré-processamento dos dados

O pré-processamento dos dados tem o objetivo de facilitar a etapa de treinamento da rede neural. Tipicamente, algumas operações são realizadas sobre os dados, quais sejam: normalização; transformações lineares; extração de características; etc. Nesse trabalho aplica-se uma operação de normalização sobre os dados. A normalização aplicada faz com que todos os valores de entrada se situem na faixa entre -1 a 1. A figura 3.7 mostra o resultado da normalização. Isso pode ser realizado com a utilização da expressão 3.14:

$$S_a = 2(S - S^{min} \cdot [1 \dots 1]_{1 \times k}) / (S^{max} - S^{min}) - 1. \quad (3.14)$$

Onde  $S_a$  é o vetor contendo os valores normalizados,  $S$  é o vetor contendo os valores originais da série,  $S^{min}$  e  $S^{max}$  são o menor e o maior, respectivamente, valores contidos em  $S$ .

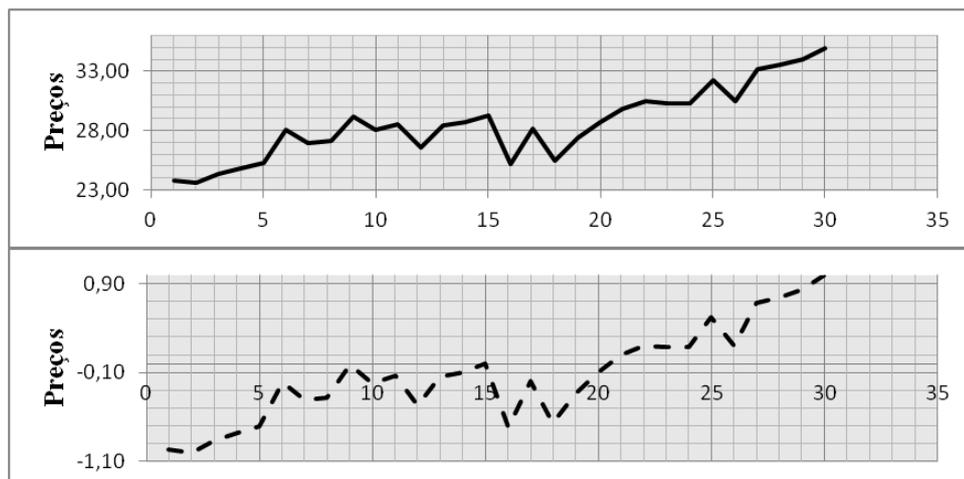


Figura 3.7 – Exemplo de normalização

### 3.8. Rede do tipo NARX e NAR

Para realizar predição de séries temporais, uma das arquiteturas de rede mais adequadas são as dinâmicas (HAGAN *et al*, 2014). O modelo de rede *Nonlinear AutoRegressive model with eXogeneous inputs* (NARX) é muito popular. Na figura 3.8, pode-se visualizar uma rede NARX com duas camadas, em notação abreviada.

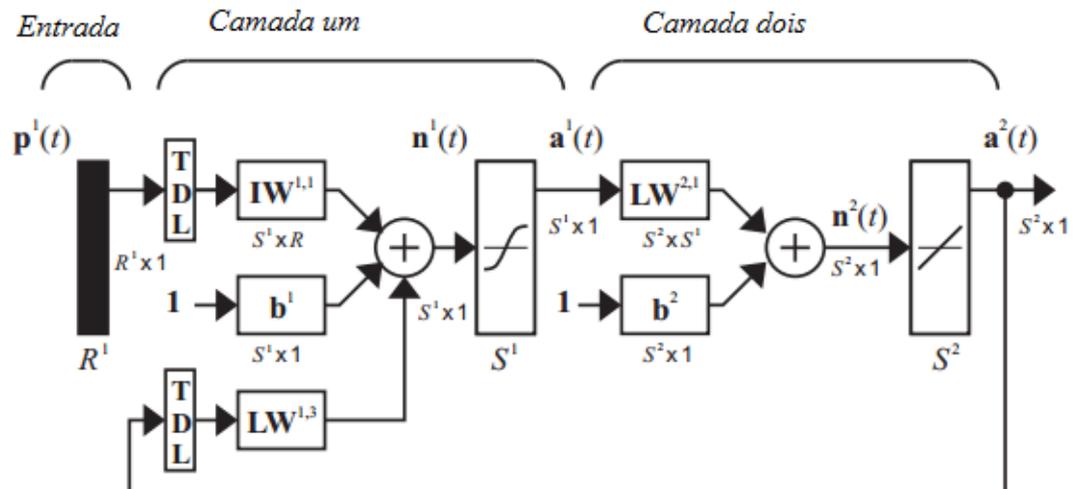


Figura 3.8 – Rede NARX

Fonte: HAGAN *et al*, 2014.

Pelo exposto anteriormente nesse capítulo, conclui-se que a esta rede mostrada na figura 3.8 é recorrente e dinâmica, por conta da realimentação (*feedback*) mostrada da saída para a entrada. A rede NARX é baseada no modelo ARX, que é comumente utilizado para predição de séries temporais. A equação que define o modelo NARX é escrita como

$$y(t) = f[y(t-1), \dots, y(t-n_y), u(t-1), u(t-2) \dots, u(t-n_u)], \quad (3.15)$$

Na expressão 3.16, o próximo valor na saída da rede,  $y(t)$ , depende de todos os valores de saída anteriores da rede,  $y(t-i)$ , bem como de todas as entradas as entradas externas  $u(t-i)$ . A rede neural vai a aproximar a função  $f(\cdot)$ .

O treinamento desta rede NARX não pode ser realizado pelo algoritmo de propagação reversa clássico. A saída da rede será uma estimativa da saída do sistema dinâmico e não linear que está se tentando modelar. A saída é realimentada para a entrada de uma rede de propagação direta, como parte da arquitetura padrão do modelo NARX, como pode ser visto no lado esquerdo da figura 3.9. Estando as saídas reais disponíveis durante o treinamento da rede, pode ser criado uma estrutura série-paralelo, na qual a saída real é usada em vez da saída estimada realimentada, como pode ser visto do lado direito da figura 3.9. Esta última estrutura da rede terá duas vantagens: a primeira é que os valores de entrada serão mais precisos; a segunda é que a arquitetura resultante terá na

realidade uma rede de propagação direta e dessa forma, o método estático do algoritmo de propagação direta pode ser utilizado.

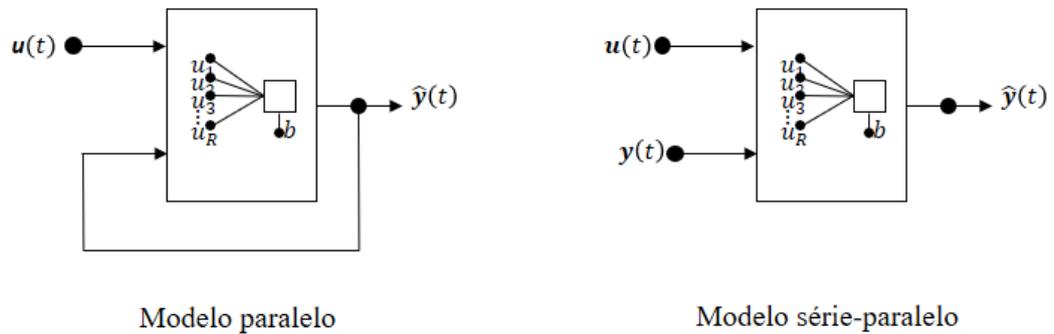


Figura 3.9 – Tipos de modelos da rede NARX

A previsão do sistema de negociação será feita utilizando o modelo paralelo de uma rede NAR, sem uso de dados externos, o que configuraria uma rede NARX. Para o treinamento, os dados serão divididos em conjunto de pontos que serão atualizados ao longo do tempo, em cinco atualizações para treinamento. Esta técnica é conhecida como janelamento móvel, e será melhor ilustrado no próximo capítulo. A cada iteração principal de um ponto à frente, a previsão é realizada utilizando apenas entradas passadas reais da série. Algumas das próximas previsões, em subiterações, são feitas utilizando os pontos preditos anteriormente, realimentando. Executando dessa forma somente pelo número de iterações necessárias ao cálculo do Indicador de Mínimos e Máximos de  $N$  períodos ( $IMM_N$ ), pelo fato de previsão de vários pontos à frente acumular erro, sendo este maior quanto mais pontos forem preditos dessa forma. Na próxima iteração, o processo é reiniciado. O cálculo do  $IMM_N$  será introduzido no próximo capítulo.

## 4. Sistema de Negociação

### 4.1. Visão geral

Um sistema de negociação é formado essencialmente por um conjunto de regras que definem quando e em que condições um valor monetário pode ser utilizado para adquirir uma quantidade de um determinado ativo disponível e com liquidez, ou, quando já se tem a propriedade do ativo, vendê-lo.

A aceitabilidade do sistema é maior quando se utiliza técnicas avançadas de predição, como exemplos, as redes neurais ou modelos de regressão linear, pois tornam o mesmo mais confiável. Através destas técnicas, predições dos valores futuros feitas por um sistema de negociação podem ser utilizadas como base para a decisão de compra ou venda de ativos. Assim, o uso de técnicas mais avançadas, e não apenas simples indicadores estáticos, tornam o processo decisório mais confiável.

Além das técnicas avançadas, que podem ser identificadas como o coração do sistema de negociação, há ainda regras que visam delimitar o grau de risco aceitável quando em operação. Dentre essas regras citamos aquela que limita eventuais perdas (*stop loss*). Tal regra sugere a venda do ativo quando um prejuízo é reconhecido e o mesmo já ultrapassa um percentual sobre o capital empregado. Há também regras para realização de lucros (*profit taking*), quando se verifica que o ganho já ultrapassou um valor considerado razoável, com vistas a evitar que eventuais desvalorizações não previstas diminuam a rentabilidade de longo prazo.

Outra regra que pode ser empregada é limitar o valor da operação a um percentual do montante disponível ou inicial, para que se diminua o risco de empregá-lo todo no início das negociações, podendo perder oportunidades futuras. Um sistema de negociação pode ser testado, aplicando-o a dados de uma série histórica e investigando se o mesmo levou a resultados satisfatórios. O resultado, contudo, não deve ser considerado como uma certeza universal, mas sim como uma certeza relativa: se o comportamento do mercado verificado no passado se mantiver, os ganhos auferidos poderão ser novamente alcançados.

## 4.2. Proposição do indicador $IMM_N$

Na seção 2.7.3 alguns indicadores foram apresentados, a exemplo da Média Móvel Exponencial (MME). Para o sistema de negociação em gestação, propõe-se um novo indicador. Não se vislumbra que este indicador tenha utilidade para a análise técnica tradicional. O cálculo do mesmo necessita de dados de previsão, obtidos a partir de um sistema treinado com dados de uma série temporal. A utilidade do mesmo é para classificação de regiões de máximos e mínimos locais. Para o sistema de negociação ora gestado, os valores futuros são estimados através de redes neurais artificiais.

Nos parágrafos seguintes, ao citarmos o termo “série temporal”, estaremos nos referindo a uma série discreta de valores de um índice de desempenho, conforme citado na seção 2.4. No caso dessa dissertação, estaremos nos referindo ao índice Ibovespa.

O novo indicador proposto nesse trabalho é descrito através da equação (4.1). O indicador mostrado é nomeado nesse trabalho por Indicador de Mínimos e Máximos (IMM).

$$IMM_N(\mathbf{n}) = \alpha_{A,N}(\mathbf{n})\alpha_{P,N}(\mathbf{n}), \quad (4.1)$$

Onde  $\alpha_{A,N}(\mathbf{n})$  é o coeficiente angular do ajuste de curva linear dos N valores de uma série temporal anteriores ao valor atual,  $\mathbf{n}$  e  $\alpha_{P,N}(\mathbf{n})$  é o coeficiente angular do ajuste de curva linear dos N valores de uma série temporal posteriores ao valor atual,  $\mathbf{n}$ . O primeiro pode ser calculado facilmente usando valores passados de uma série temporal. Já para o cálculo do último, que envolve valores futuros de uma série temporal, é necessário dispormos de um método capaz de efetuar previsões.

Na figura 4.1 foi demonstrado graficamente como ocorre a classificação. É intuitivo compreender que em um ponto de máximo, o indicador fará a multiplicação de um coeficiente positivo,  $\alpha_{A,4}(5) > 0$ , por um negativo,  $\alpha_{P,4}(5) < 0$ , o resultado sendo então negativo. Idem para o ponto de mínimo. A distinção entre máximo e mínimo se verifica pela observação do primeiro coeficiente, pois esse será negativo para um ponto de mínimo e positivo para um ponto de máximo. Ressaltamos que estamos nos referindo a pontos extremos locais. A existência desses pontos extremos depende da região utilizada da série temporal. Para algumas regiões, é possível que não existam pontos extremos e, dessa forma, o indicador apresentará um valor positivo.

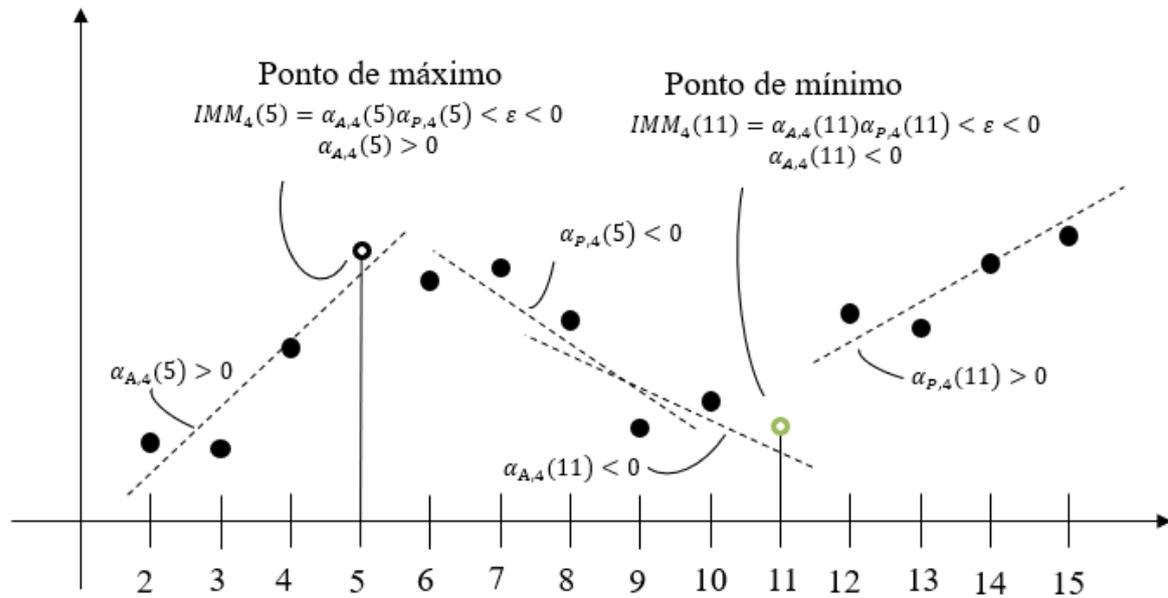


Figura 4.1 – Figura explicativa do cálculo do  $IMM_N$  para classificação de pontos

Dada uma série temporal, é necessário realizar um trabalho prévio, para se determinar um limiar para busca de pontos extremos máximo e mínimo. O significado desse limiar é definir regiões de valores da série temporal, na qual são procurados os pontos de máximo e mínimo. Acima desse limiar, são procurados os pontos de máximo. Abaixo desse limiar são procurados os pontos de mínimo. Esse limiar, em conjunto com as predições, é utilizado pelo sistema de negociação para iniciar as indicações de compra e venda de ativos. Doravante denominaremos esse limiar por “limiar de busca” e seu valor será designado pela letra grega  $\varepsilon$ . Métodos tais como LMINMAX, RDP e SOBEDESCE que auxiliam na classificação de dados com esse mesmo intuito foram apresentados em Santos (2014). Sendo RDP originalmente apresentado em Cao e Tay (2003).

### Método dos mínimos quadrados

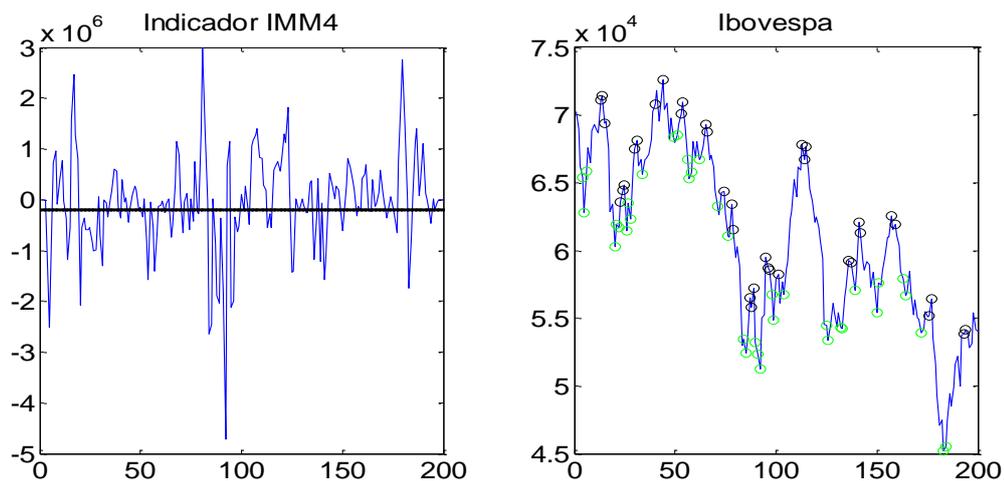
O ajuste de curvas é uma operação bastante comum em engenharia, matemática, economia etc. O método dos mínimos quadrados foi utilizado para o cálculo dos coeficientes  $\alpha_{A,N}(n)$  e  $\alpha_{P,N}(n)$  que compõem o  $IMM_N$ .

Sejam as coordenadas  $x_i$  e  $y_i$  dos pontos de uma série temporal, onde a primeira coordenada representa o tempo em semanas e a segunda representa o valor de um índice de desempenho ao longo deste tempo. A determinação do coeficiente angular da melhor

reta que se ajusta a esses pontos, utilizando o critério de minimização do erro médio quadrático, pode ser feita através da equação 4.2, apresentada em Ruggiero (1996). Ressaltamos que, para o cálculo do  $IMM_N$  é necessário o coeficiente angular de duas retas: um deles referente aos pontos anteriores ( $\alpha_{A,N}(n)$ ) e o outro, referente aos pontos posteriores ( $\alpha_{P,N}(n)$ ).

$$\alpha_1 = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2} \quad (4.2)$$

A base de dados da série Ibovespa utilizada ao longo do trabalho foi conseguida através da página da internet do Yahoo Finanças<sup>3</sup>. Na figura 4.2 mostramos o resultado do cálculo realizado do indicador  $IMM_N$  para o índice Ibovespa, no período de 04/01/2010 a 28/10/2013. Utilizou-se uma série temporal correspondente ao valor de fechamento da segunda-feira, perfazendo um total de 200 pontos de uma série histórica. Há três linhas de gráficos. Para cada linha, o gráfico à esquerda corresponde ao indicador  $IMM_N$ , enquanto que o gráfico à direita corresponde ao índice Ibovespa. As três linhas de gráficos correspondem, de cima para baixo, a valores de  $IMM_N$  calculados com  $N=4, 8$  e  $12$ , respectivamente. Como um mês tem aproximadamente 4 semanas, poder-se-ia considerar que a  $IMM_4$  corresponde a um mês, a  $IMM_8$  ao bimestre e a  $IMM_{12}$  ao trimestre, aproximadamente.



<sup>3</sup> Disponível em: <https://br.financas.yahoo.com>. Acesso em: 20/05/2017.

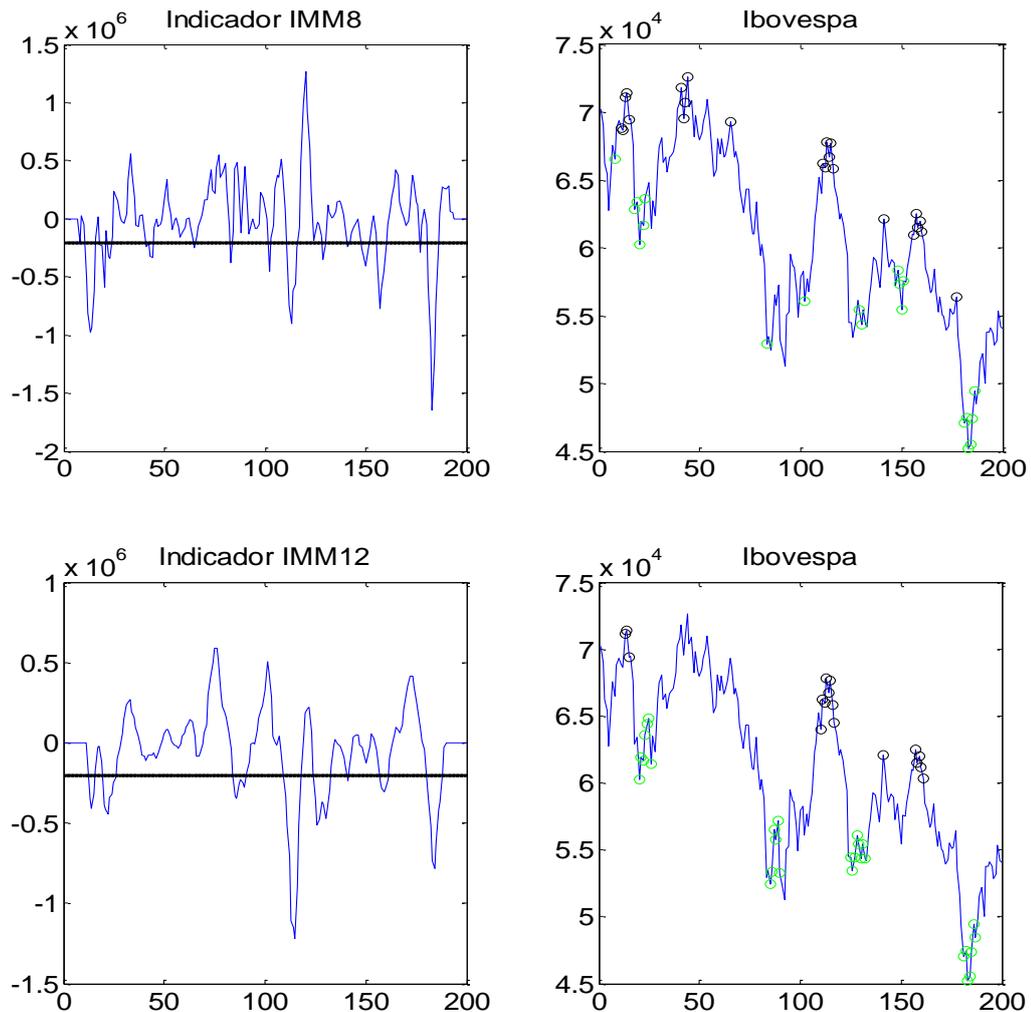


Figura 4.2 – Indicadores de máximo e mínimo determinados para  $N=4, 8$  e  $12$  e para um limiar de busca igual a  $-0,2E6$  (curva tracejada em preto nos gráficos da esquerda). Pontos pretos e pontos verdes, correspondem, respectivamente, a indicadores de máximo e de mínimo nos gráficos da direita.

Na figura 4.2 (o eixo horizontal representa as semanas) definimos um limiar de busca  $\varepsilon = -0,2E6$ . Os pontos classificados como indicadores de máximo foram destacados com círculos na cor preta nos gráficos da direita. Já os pontos classificados como indicadores de mínimo foram destacados com círculos na cor verde. Observa-se que quanto menor o valor de  $N$ , do indicador  $IMM_N$ , mais sensível é o mesmo, classificando uma quantidade maior de pontos extremos. O limiar de busca para pontos extremos está plotado nos gráficos à esquerda, como uma reta tracejada na cor preta.

O valor do limiar de busca tem uma grande influência na detecção dos pontos extremos. Por exemplo, a utilização de um limiar inferior em termos absolutos, exemplo  $-0,15E6$ , levará a uma geração de um maior número de pontos extremos, conforme se

verifica através dos gráficos mostrados na figura 4.3, que são análogos àqueles mostrados na figura 4.2.

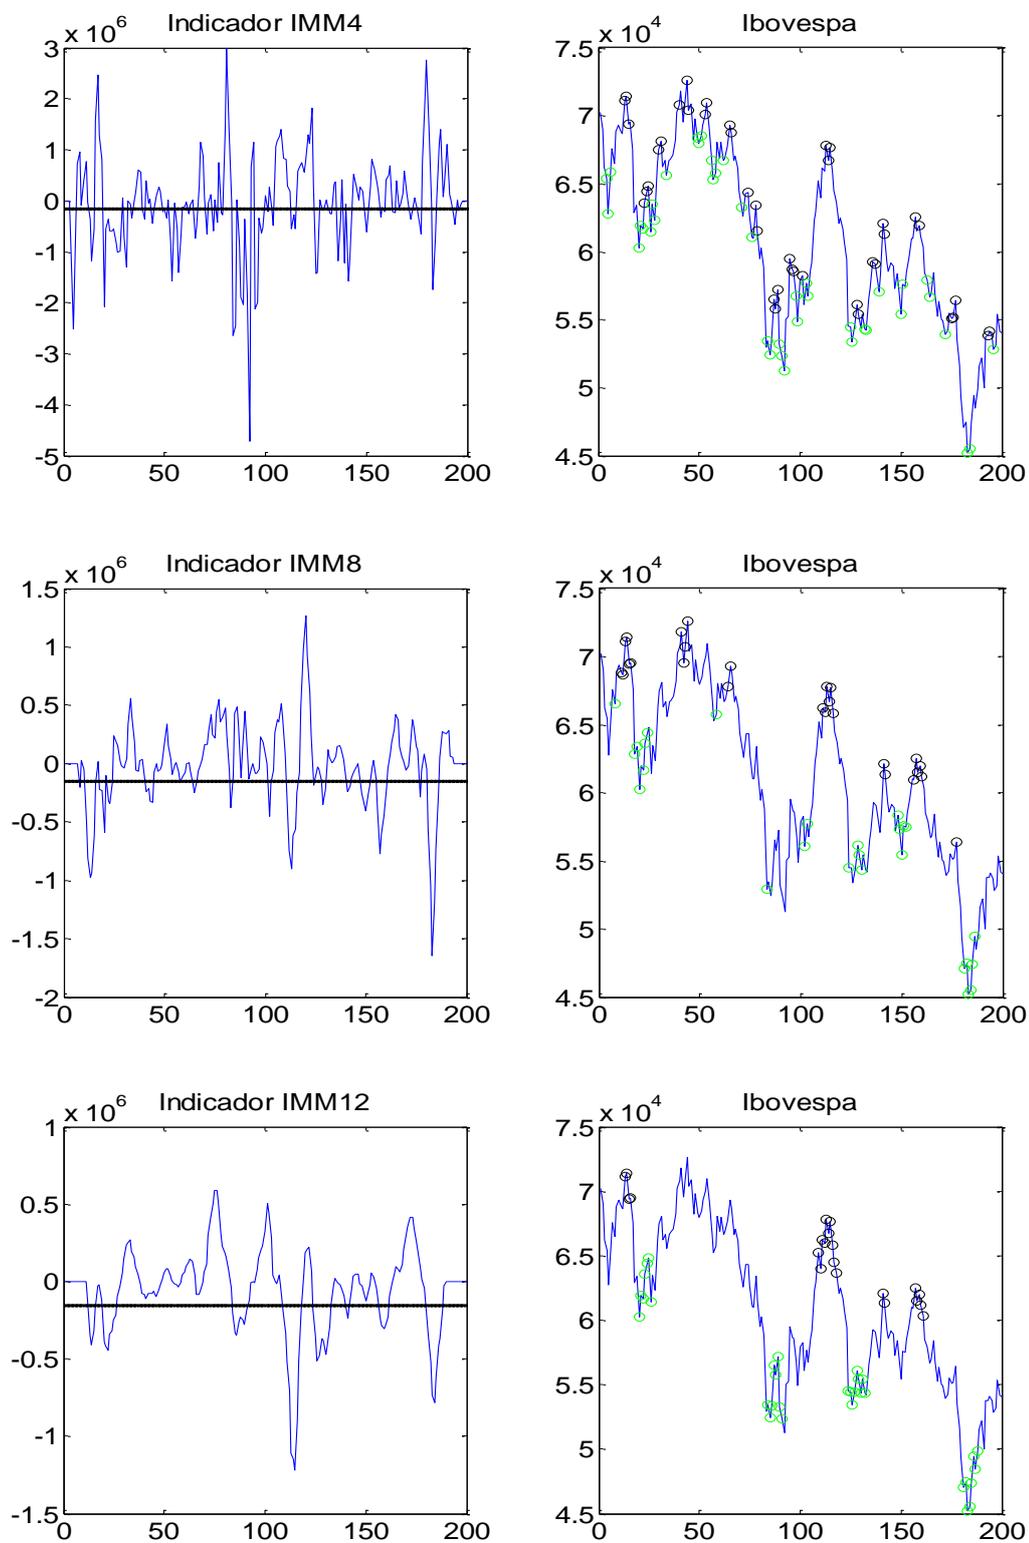


Figura 4.3 – Indicadores de máximo e mínimo determinados para  $N=4, 8$  e  $12$  e para um limiar de busca igual a  $-0,15E6$  (curva tracejada em preto nos gráficos da esquerda).

Pontos pretos e pontos verdes, correspondem, respectivamente, a indicadores de máximo e de mínimo nos gráficos da direita.

Na Tabela 4.1 mostra-se a quantidade de pontos extremos obtidos para o período mostrado nos gráficos das figuras 4.2 e 4.3 em função do número de período do indicador  $IMM_N$ ,  $N=4, 8$  e  $12$ , e dos limiares escolhidos,  $\varepsilon = -0,2E6$  e  $\varepsilon = -0,15E6$ . A sensibilidade do indicador é de extrema importância, pois ela influenciará na quantidade de operações que serão realizadas em função de uma região estar sendo apontada como de máximo ou de mínimo.

Tabela 4.1 – Quantidade de pontos extremos encontrados utilizando o  $IMM_N$

Limiar	$\varepsilon = -0,2E06$			$\varepsilon = -0,15E06$		
	Máximo	Mínimo	Total	Máximo	Mínimo	Total
<b>4</b>	37	38	75	41	41	82
<b>8</b>	23	20	43	26	26	52
<b>12</b>	17	28	45	21	31	52

### 4.3. Funcionamento Inicial do Sistema de Negociação

O algoritmo que deve indicar quando investir ou desinvestir é composto por um conjunto de regras que visam diversos objetivos secundários, porém com um único objetivo principal, que é o de alcançar um bom retorno sobre o capital investido, acima do *benchmark* que é o próprio índice Ibovespa ora em análise. Neste sistema de negociação, duas regras foram criadas visando atingir dois objetivos secundários, quais sejam, limitar o montante percentualmente disponível para operações de renda variável e limitar o excesso de operações. O fluxograma do sistema de negociação, com suas operações detalhadas, é mostrado na figura 4.4. Nesse fluxograma, os blocos foram numerados de 1 a 6.

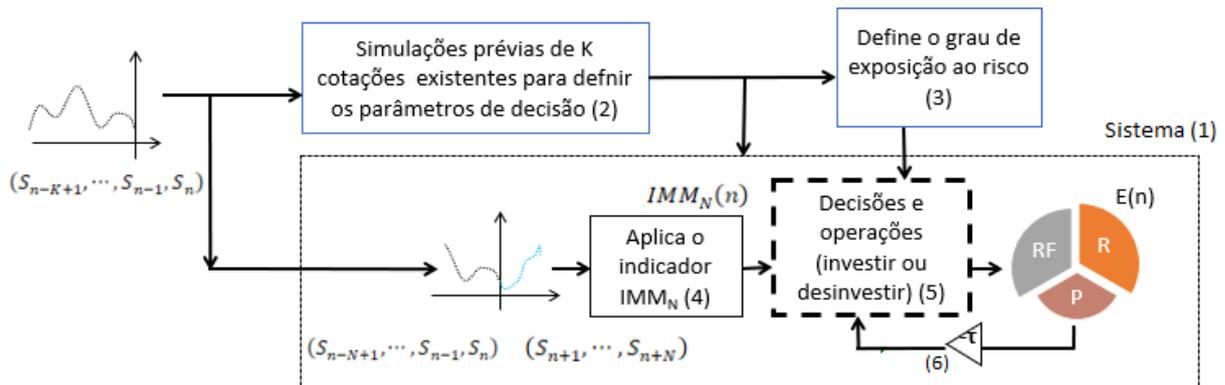


Figura 4.4 – Fluxograma Inicial do Sistema

O montante percentualmente disponível para operações de Renda Variável é definido através do bloco (3) do fluxograma mostrado. Esse bloco é nomeado por “Define o grau de exposição ao risco”. O grau de exposição de risco é definido externamente pelo usuário. O mesmo pode definir, por exemplo, que em cada operação realizada só será utilizado 10%, 20% ou mesmo 100% do montante disponível para investimento ou desinvestimento, no momento em que o sistema apontar como favorável realizar uma dessas operações. Lembramos que, no momento inicial, todo o montante está disponível para investimento. À medida em que o tempo passa, eventuais aplicações podem ser realizadas e o montante disponível para as operações de investimento ou desinvestimento diminui.

O limite do excesso de operações é efetuado através da retroalimentação marcada com  $-\tau$ , bloco (6). Esse bloco monitora o número de operações e não permite que seja realizada uma compra ou venda caso já tenham ocorridas um determinado número de operações dentro de um período determinado. Esse filtro evita, por exemplo, o pagamento em excesso de taxas de corretagem, dentre outras despesas relacionadas a operações de compra e venda. Evita também a alocação de todo capital em um único período. Ressaltamos, no entanto, que a implementação desse filtro é mais uma opção que fica nas mãos do usuário.

O bloco (1), que engloba os blocos (4), (5) e (6), constitui o sistema propriamente dito. No bloco (4) realiza-se o cálculo do indicador  $IMM_N$ . No bloco (5) são realizadas as decisões de investir ou desinvestir. O processo decisório é simples: se o sistema detecta

um ponto de máximo o mesmo recomenda a venda. Por outro lado, se o sistema detecta um ponto de mínimo ele sugere a compra.

O cálculo do indicador  $IMM_N$  mostrado no bloco (4) é de fundamental importância para a operação do sistema de negociação mostrado na figura 4.4. Em Santos (2014), para realizar essa tarefa, é proposto o método LMinMax. Os autores apresentam como resultado o crescimento de uma carteira composta por algumas das principais ações do Ibovespa. No mesmo trabalho avalia-se também o desempenho de outros métodos, como RDP (Cao e Tay, 2003) e SobeDesce (Jae e Kim, 2003). No entanto, avalia-se a cotação diária de ações e não a semanal do índice, como é a proposta do trabalho ora em gestação. Desta forma, claramente, no trabalho citado conseguir-se-á rentabilidade simulada maior (não rentabilidade real), pois haverá um maior número de operações em função da discretização diária. Porém, isso não diminui a necessidade do  $IMM_N$ . A necessidade do mesmo será mais evidente quando formos utilizar uma rede neural para previsão de valores futuros, ou seja, valores ainda não conhecidos.

No bloco (2) são realizadas avaliações prévias dos dados a fim de decidir quais os valores dos parâmetros base do sistema, que são: o período  $N$  do indicador  $IMM_N$ ; o limiar de busca  $\varepsilon$  que foi introduzido em 4.2; o grau de alocação por operação  $\theta$  (bloco 3 do fluxograma) e; o período  $\tau$  em espera sem operar. As escolhas de tais parâmetros foram realizadas em 4.4.

Quanto às variáveis mostradas no fluxograma da figura 4.4, o vetor  $S$  contém os valores dos índices ao longo das semanas, considerando o período de interesse.  $(S_{n-K+1}, \dots, S_{n-1}, S_n)$  é o vetor de  $K$  pontos passados incluindo o atual, enquanto que o vetor  $(S_{n-N+1}, \dots, S_{n-1}, S_n)$  são os  $N$  pontos passados e  $(S_{n+1}, \dots, S_{n+N})$  são os  $N$  pontos do “futuro”. Para os valores semanais do índice Ibovespa do período de 04/01/2010 a 28/10/2013 utilizados na seção 4.2, temos que  $K=200$  e data atual  $n$ , 28/10/2013. Para o cálculo do  $IMM_N$ , conforme feito nas figuras 4.2 e 4.3, trabalhamos com os  $N$  pontos anteriores e  $N$  pontos posteriores conhecidos da série semanal. Nesse cálculo, não utilizamos nenhum valor resultante da predição de uma rede neural.

A variável  $E(n)$  é uma matriz que mostra o estado da carteira no momento  $n$ . A matriz  $E(n)$  é constituída por 3 linhas. A 1ª linha armazena o montante sem alocação, ou seja, o montante parado. A 2ª linha armazena o montante alocado em Renda Fixa e a 3ª linha armazena o montante alocado em Renda Variável, denominado também de

montante em Risco. Conforme pode ser verificado na figura 4.5, o estado varia ao longo do tempo, iniciando 100% sem alocação, ou seja, com todo o montante parado. A composição do mesmo varia a medida em que as operações vão ocorrendo. Considera-se que o montante aplicado em renda fixa está sujeito a uma taxa considerada de 0,5% a.m. que é inferior à taxa de Poupança no Brasil nos últimos anos.

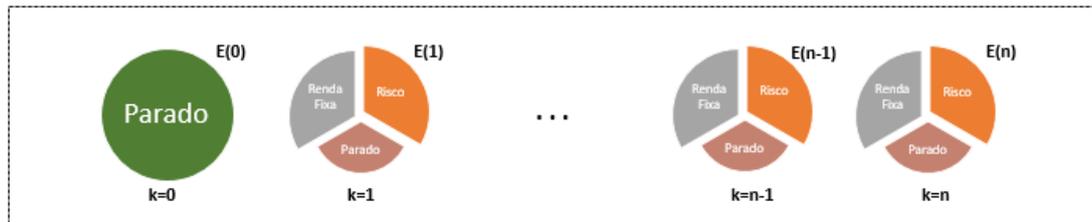


Figura 4.5 – Ilustração da Variação do Estado

No bloco (5) da figura 4.4 é onde são tomadas as decisões que causam a modificação no estado. Essas decisões são tomadas com base em diversas informações que são fornecidas como entrada do mesmo, provenientes dos blocos (3), (4) e (6). Para saber o crescimento percentual da carteira em um determinado ano basta utilizar a equação a seguir.

$$C_{ano\ k} = \frac{(\sum E(\text{final ano } k) - \sum E(\text{final ano } k-1))}{\sum E(\text{final ano } k-1)} \cdot 100, \quad (4.4)$$

Em que:

$\sum E(\text{final ano } k)$  significa somar os elementos da coluna correspondente ao final do ano  $k$ , que é na realidade o total monetário contido na carteira no final deste ano.

#### 4.4. Escolha dos parâmetros básicos

Os parâmetros básicos são aqueles utilizados para o cálculo do  $IMM_N$ , o valor de  $N$ ; o limiar  $\varepsilon$ ; o grau de alocação por operação  $\theta$  (bloco 3 do fluxograma) e o período  $\tau$  em espera sem operar, a contar de uma operação realizada, para evitar excessos de operações. O valor padrão é de quatro períodos, equivalente aproximadamente a um mês. A opção que adotamos para escolher tais parâmetros foi executar o algoritmo associado ao fluxograma da figura 4.3, para algumas combinações dos mesmos. Ao final escolheu-

se aquele conjunto de parâmetros que redundou no melhor resultado, ou seja, que trouxe mais lucro para o investidor. Nessas simulações utilizou-se 220 pontos semanais para englobar 4 anos completos, correspondendo ao período de 04/01/2010 a 17/03/2014. Na Tabela 4.2 mostramos os resultados dessas simulações para os anos de 2010 e 2011. Na Tabela 4.3 mostramos os resultados dessas simulações para os anos de 2012 e 2013. Na Tabela 4.4 mostramos os resultados dessas simulações para todo o período e 2010 a 2014.

Tabela 4.2 – Desempenho alcançado para 2010 e 2011 para algumas combinações dos parâmetros  $N$ ,  $\varepsilon$  e  $\theta$ .

Combinação	$N$	$\varepsilon$	$\theta(\%)$	Cresc. % no ano de 2010	Cresc. % no ano de 2011
1	4	-0,20e6	30	15,8	0,3
2	4	-0,20e6	60	26,9	13,9
3	4	-0,20e6	90	38,3	34,0
4	4	-0,20e6	100	39,7	35,0
5	4	-0,15e6	30	15,8	0,0
6	4	-0,15e6	60	26,9	13,0
7	4	-0,15e6	90	38,3	32,0
8	4	-0,15e6	100	39,7	32,7
9	8	-0,20e6	30	12,7	1,7
10	8	-0,20e6	60	18,4	7,8
11	8	-0,20e6	90	20,2	10,5
12	8	-0,20e6	100	20,1	11,2
13	8	-0,15e6	30	13,2	-2,0
14	8	-0,15e6	60	18,7	3,5
15	8	-0,15e6	90	20,2	10,2
16	8	-0,15e6	100	20,1	13,3
17	12	-0,20e6	30	11,8	-12,3
18	12	-0,20e6	60	14,5	-17,5
19	12	-0,20e6	90	15,7	-17,8
20	12	-0,20e6	100	16,1	-18,1
21	12	-0,15e6	30	11,8	-12,0
22	12	-0,15e6	60	14,5	-17,5
23	12	-0,15e6	90	15,7	-17,9
24	12	-0,15e6	100	16,1	-18,1

Verifica-se a partir da tabela 4.2 que as combinações 3, 4 e 8 apresentaram os melhores resultados para os anos de 2010 e 2011. Eles têm em comum o menor valor de  $N$ ,  $N = 4$  e altos valores de  $\theta$ , 90% e 100%. As rentabilidades anuais ficaram entre 30 e 40%. Já era esperado que os valores de  $\theta$  com melhores desempenhos fossem aqueles

mais altos, pois, como neste modo de operação do sistema de negociação, os pontos futuros do índice são conhecidos, a operação do mesmo é exitosa e não coloca em risco os investimentos realizados. O comportamento será diferente quando o sistema de negociação utilizar previsões dos valores futuros utilizando redes neurais, necessitando então de uma exposição menor do capital.

Tabela 4.3 – Desempenho alcançado para 2012 e 2013 para algumas combinações dos parâmetros  $N$ ,  $\varepsilon$  e  $\theta$ .

Combinação	$N$	$\varepsilon$	$\theta$ (%)	Cresc. % no ano de 2012	Cresc. % no ano de 2013
1	4	-0,20e6	30	18,6	1,5
2	4	-0,20e6	60	33,6	8,6
3	4	-0,20e6	90	51,5	17,4
4	4	-0,20e6	100	58,4	20,6
5	4	-0,15e6	30	18,4	2,7
6	4	-0,15e6	60	33,8	11,7
7	4	-0,15e6	90	54,7	21,3
8	4	-0,15e6	100	63,8	24,1
9	8	-0,20e6	30	18,3	5,8
10	8	-0,20e6	60	30,1	11,4
11	8	-0,20e6	90	37,9	11,7
12	8	-0,20e6	100	39,3	11,5
13	8	-0,15e6	30	21,6	6,7
14	8	-0,15e6	60	34,3	17,5
15	8	-0,15e6	90	40,3	21,5
16	8	-0,15e6	100	40,8	22,6
17	12	-0,20e6	30	23,0	7,9
18	12	-0,20e6	60	31,2	17,0
19	12	-0,20e6	90	32,5	18,9
20	12	-0,20e6	100	32,7	19,4
21	12	-0,15e6	30	27,1	10,0
22	12	-0,15e6	60	34,1	19,9
23	12	-0,15e6	90	35,0	20,4
24	12	-0,15e6	100	35,1	20,4

Verifica-se na Tabela 4.3 que as combinações 4 e 8 apresentaram os melhores resultados para os anos de 2012 e 2013. Eles têm em comum o menor valor para  $N$ ,  $N = 4$  e valores altos de  $\theta$ , 90% e 100%. A rentabilidade para 2012 ficou em torno de 60%, enquanto que a rentabilidade para 2013 ficou em 20%.

Tabela 4.4 – Desempenho alcançado para todo o período para algumas combinações dos parâmetros  $N$ ,  $\varepsilon$  e  $\theta$ .

Combinação	$N$	$\varepsilon$	$\theta$ (%)	N. op. compra	N. op. Venda	Cresc. % em 220 semanas
1	4	-0,20e6	30	26	25	37,0
2	4	-0,20e6	60	26	25	107,2
3	4	-0,20e6	90	25	25	230,6
4	4	-0,20e6	100	18	18	264,2
5	4	-0,15e6	30	28	27	36,7
6	4	-0,15e6	60	28	27	109,2
7	4	-0,15e6	90	27	27	237,1
8	4	-0,15e6	100	21	20	271,8
9	8	-0,20e6	30	12	14	37,0
10	8	-0,20e6	60	12	14	73,5
11	8	-0,20e6	90	11	10	91,3
12	8	-0,20e6	100	6	5	93,9
13	8	-0,15e6	30	17	15	39,7
14	8	-0,15e6	60	17	15	89,9
15	8	-0,15e6	90	14	12	125,6
16	8	-0,15e6	100	7	7	135,9
17	12	-0,20e6	30	15	9	30,1
18	12	-0,20e6	60	14	9	44,9
19	12	-0,20e6	90	8	6	49,8
20	12	-0,20e6	100	3	3	50,6
21	12	-0,15e6	30	17	12	37,5
22	12	-0,15e6	60	15	12	51,9
23	12	-0,15e6	90	8	8	54,4
24	12	-0,15e6	100	3	3	54,5

Verifica-se na Tabela 4.4 que as combinações 4 e 8 novamente apresentaram os melhores resultados para os períodos completos de 2010 ao início de 2014. Eles têm em comum o menor valor para a variável  $N$ ,  $N = 4$  e para  $\theta$ ,  $\theta = 100\%$ . A rentabilidade ficou em torno de 270% para todo o período. Observa-se, no entanto, que as combinações 2 e 6, de menor exposição ( $\theta = 60\%$ ), também se mostraram interessantes e de rentabilidade em torno de 110% para todo o período.

Com base nestas simulações prévias, de um período do passado, pode-se considerar que a escolha dos parâmetros  $N = 4$ ,  $\varepsilon = -0,15E6$  e  $\theta = 100\%$  ou  $60\%$ , em um modo mais conservador, seriam parâmetros razoáveis para um bom desempenho para o sistema de recomendação para o índice Ibovespa no período estudado. Na figura 4.6

mostramos o gráfico da evolução do capital (classificado como “Total” na legenda) ao longo do tempo, utilizando a melhor combinação dos experimentos anteriores. Mostra-se também a evolução do índice Ibovespa. Para favorecer a comparação visual, o valor inicial foi ajustado para 100. Verifica-se que neste período o índice Ibovespa só decresceu, enquanto o capital aumentou 270%.

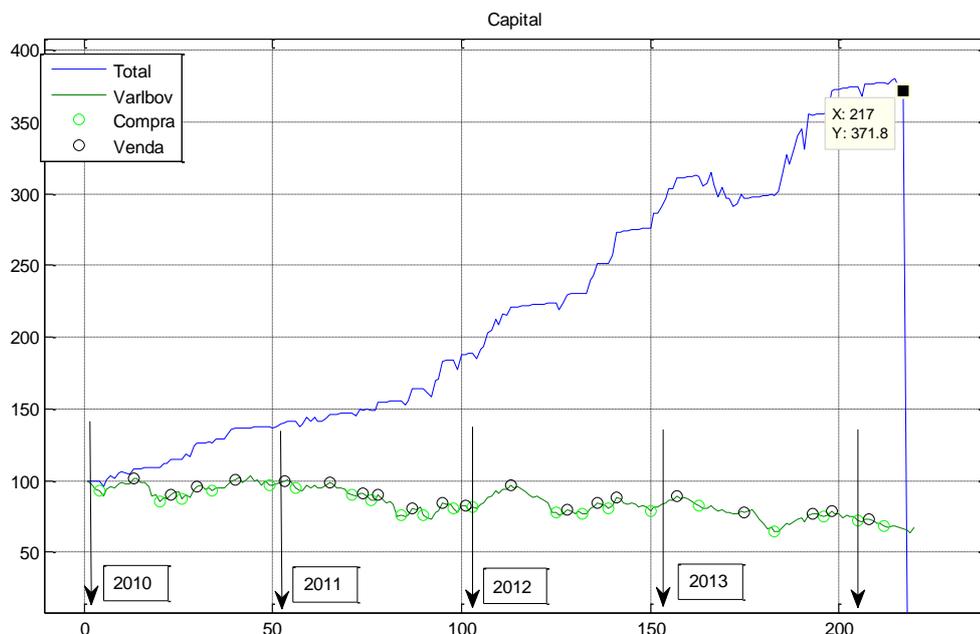


Figura 4.6 – Gráfico mostrando a evolução do capital, através da utilização da melhor combinação de parâmetros obtidos nas simulações anteriores. O valor inicial foi ajustado em 100. O valor final, após 220 semanas, foi de 371,8.

Observando a figura 4.6 verifica-se que foram realizadas 21 operações de compra e 20 operações de venda, corresponde a aproximadamente 10 operações por ano, o que satisfaz uma das conveniências destacadas, que é a realização de poucas operações. Isso permite que as taxas relacionadas às operações de compra e venda através de corretoras sejam minimizadas. Na figura as vendas são representadas por círculos pretos e as compras por círculos verdes. O processo levou a um rendimento acumulado de 271,8%. Esse valor é muito superior ao índice Ibovespa, que rendeu -32,6%, caindo de 70263 pontos para 47381.

A partir dessas simulações verificou-se que a utilização do sistema de negociação com o conhecimento prévio da série, ou seja, conhecendo tanto os N valores anteriores como os N valores posteriores a um dado momento, redundava em um alto crescimento da

carteira. Nesse caso, espera-se, de fato, rendimentos positivos e consideravelmente maiores que o *benchmark*.

#### 4.5. Sistema Completo

Até este ponto do trabalho, o sistema de negociação apresentou resultados muito satisfatórios, pois estão sendo submetidos ao algoritmo valores originais da série temporal, ou seja, é como se fosse possível prever perfeitamente os valores futuros da série. Mais ainda, se estivesse fazendo uso de alavancagem, multiplicar a rentabilidade através de endividamento, os resultados seriam ainda maiores. Apesar dessa hipótese ser interessante, não tem utilidade prática em um primeiro momento. Para integralizar a ferramenta, é necessário fazer uso de uma técnica que possa realizar previsões de valores futuros da série e apresentar tais valores ao algoritmo, de forma que ele decida se vale ou não a pena realizar uma operação de compra ou venda. Ao final analisaremos o resultado.

Para integralizar a ferramenta pode-se incluir mais um bloco ao fluxograma da figura 4.4. Este bloco é mostrado na figura 4.7, em vermelho, com numeração (7). Ele será o responsável por fornecer as previsões que serão apresentadas ao algoritmo de modo que, através da utilização do  $IMM_N$  e das demais regras, o sistema fará operações ao longo do tempo de modo a alterar o estado da carteira e com isso perseguir a geração de uma boa rentabilidade.

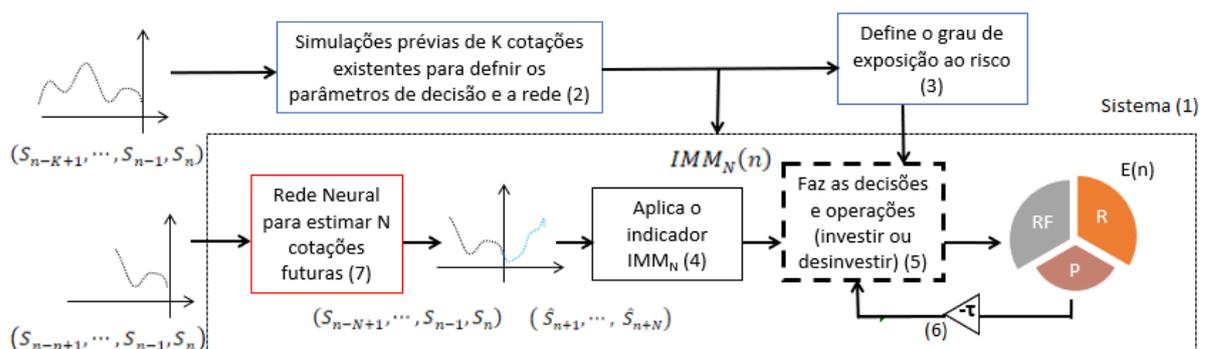


Figura 4.7 – Fluxograma do Sistema

A ideia é que a Rede Neural possa fornecer a predição dos  $N$  pontos futuros através de  $p$  pontos passados. Quanto às variáveis mostradas no fluxograma da figura 4.7, o vetor  $S$  contém os valores dos índices ao longo das semanas, considerando o período de interesse.

$(S_{n-p+1}, \dots, S_{n-1}, S_n)$  é o vetor de  $p$  pontos passados apresentados à rede para estimativa dos pontos futuros  $(\hat{S}_{n+1}, \dots, \hat{S}_{n+N})$ , que junto dos  $N$  pontos passados  $(S_{n-N+1}, \dots, S_{n-1}, S_n)$  são utilizados para cálculo do  $IMM_N$  que é a base para a sugestão de compra ou venda.

#### 4.6. Treinamento da Rede Neural

A Rede Neural com modelo *Nonlinear AutoRegressive model* (NAR) será utilizada neste sistema de negociação. Antes de embuti-la no sistema, é necessário escolher a sua arquitetura e realizar seu treinamento, ou seja, é necessário definir quais funções de ativação serão utilizadas, qual a quantidade de camadas internas, qual a quantidade de neurônios nas camadas e qual o número de coordenadas do vetor da entrada e do vetor da saída. Este último já foi definido e será igual a quatro, com base nos resultados obtidos através das simulações prévias com uso da  $IMM_N$ .

A estratégia será utilizar a Rede Neural para que esta possa fornecer a predição de valores futuros através de valores passados. Para cada nova predição da rede, a entrada da mesma é atualizada com os valores passados. Esse método também foi utilizado em Santos (2014), Pommerenzenbaum. (2014) e Gambogi (2015). Como os pontos futuros serão aplicados para o cálculo da  $IMM_N$ , somente há interesse em  $N$  pontos posteriores, ou seja,  $F = N$ . Intuitivamente, quanto maior o número de intervalos ou conjuntos de treinamento, melhor seria a qualidade da rede. Porém, tornaria obrigatório várias seções de treinamento. Isso se torna complicado ainda quando se considera que se pretende criar variantes do treinamento, em função do método de treinamento e do número de neurônios na camada interna. O treinamento da rede foi feito utilizando dados do Ibovespa referentes a 10 períodos distintos, 5 de 156 pontos (opção com conjunto de treinamento menor) e 5 de 300 pontos (opção com conjunto de treinamento maior), no intervalo entre

02/04/2007 a 19/12/2016. Esses conjuntos serão denominados, doravante, de conjuntos de treinamento. Esses cinco períodos escolhidos são mostrados a seguir.

- **Período 1.1** de 04/01/2010 a 26/12/2012 para treinamento. **Período 1.2** de 02/04/2007 a 26/12/2012 para treinamento. Para serem utilizados na previsão do período de 02/01/2013 até 23/12/2013.
- **Período 2.1** de 03/01/2011 a 23/12/2013 para treinamento. **Período 2.2** de 31/03/2008 a 23/12/2013 para treinamento. Para serem utilizados na previsão do período de 30/12/2013 até 22/12/2014.
- **Período 3.1** de 02/01/2012 a 22/12/2014 para treinamento. **Período 3.2** de 30/03/2009 a 22/12/2014 para treinamento. Para serem utilizados na previsão do período de 29/12/2014 até 21/12/2015.
- **Período 4.1** de 02/01/2013 a 21/12/2015 para treinamento. **Período 4.2** de 29/03/2010 a 21/12/2015 para treinamento. Para serem utilizados na previsão do período de 28/12/2015 até 19/12/2016.
- **Período 5.1** de 30/12/2013 a 19/12/2016 para treinamento. **Período 5.2** de 28/03/2011 a 19/12/2016 para treinamento. Para serem utilizados na previsão do período de 26/12/2016 até 10/04/2017.

Duas arquiteturas de Rede Neural foram testadas, sendo uma com 7 neurônios na camada interna e outra com 4 neurônios. Dois critérios para parada do treinamento foram utilizados, o *Early Stopping (ES)* e o critério com base no *Mean Squared Error (MSE)*.

A figura 4.8 mostra graficamente, através de janelas móveis, os conjuntos de dados de treinamento e de teste, ou aplicação.

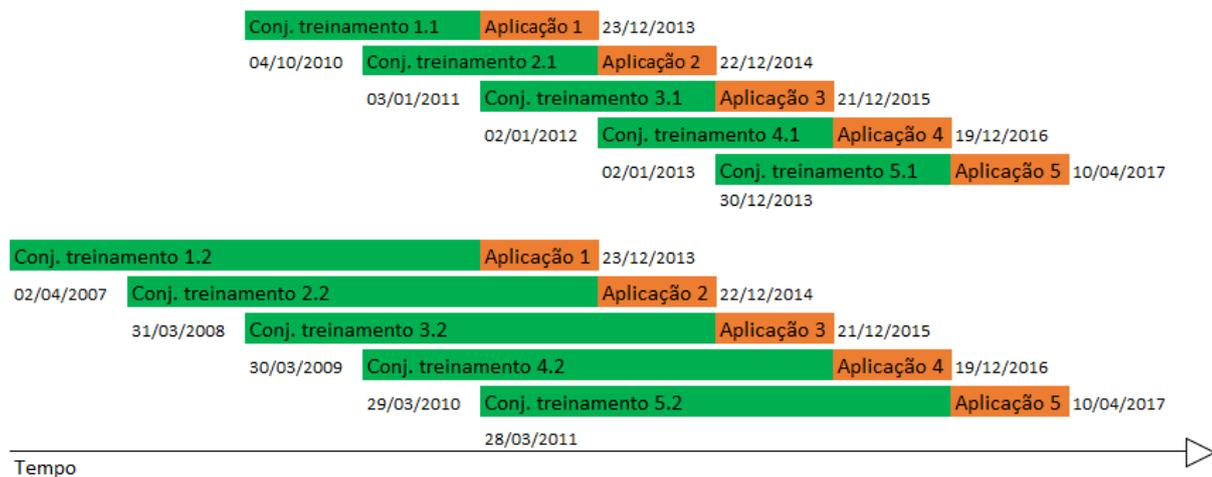


Figura 4.8 – Deslizamento da aplicação para treinamento curto e longo

A rede utilizou os 40 dados anteriores para prever os 4 pontos posteriores que são aplicados no cálculo do  $IMM_N$ . Não há uma regra bem estabelecida para a escolha deste número de pontos passados, somente que é razoável utilizar pelo menos 10 vezes o número de pontos que se deseja prever para, de alguma forma, tentar captar a dinâmica dos preços. Outras variações de tais parâmetros poderiam ser utilizadas e comparadas, mas esse não é o foco do trabalho.

Na figura 4.9 mostramos a arquitetura de uma das redes NAR utilizadas, com 7 neurônios na camada interna, 1 neurônio de saída e 40 entradas. Na Tabela 4.5 mostramos as redes simuladas nesse trabalho, detalhando o período utilizado para o treinamento, o método de parada do treinamento empregado, o número de neurônios da camada interna e o conjunto de treinamento.

Para facilitar a compreensão, utiliza-se uma padronização para a nomenclatura criando um termo composto por letras e números que indicará respectivamente: o tamanho do conjunto de treinamento, se menor usará a letra “C” de curto, se maior, utilizará a letra “L” de longo; o método de treinamento aplicado, se pelo *Mean Squared Error*, usará “MSE”, se *Early Stopping*, usará “ES”; a quantidade de neurônios na camada intermediária, se 7 ou 4; e o período de aplicação, de 1 a 5. Exemplo: C-MSE-7-2 (Período menor (curto), Método de treinamento MSE, 7 neurônios na camada interna, período 2 de 03/01/2011 a 23/12/2013).

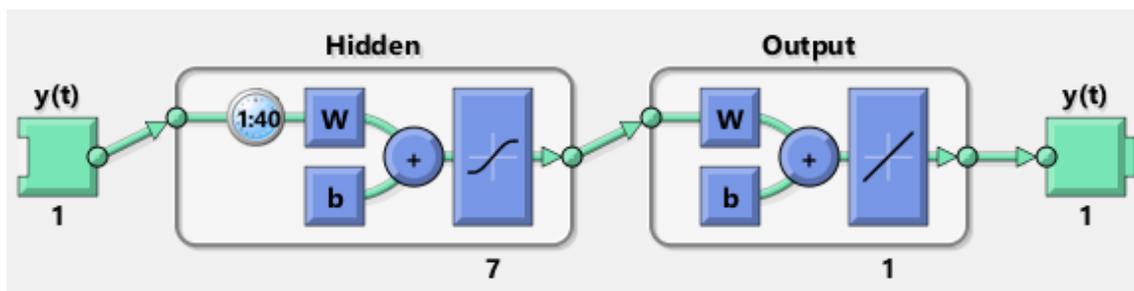


Figura 4.9 – Arquitetura utilizada para a rede NAR (MATLAB®)

Tabela 4.5 – Redes neurais simuladas: períodos utilizados para treinamento, método de parada de treinamento, número de neurônios na camada interna e o conjunto de treinamento.

Rede	Período Curto	Rede	Período Curto
C-MSE-7-1	04/01/2010 até 26/12/2012	L-MSE-7-1	02/04/2007 até 26/12/2012
C-MSE-4-1	04/01/2010 até 26/12/2012	L-MSE-4-1	02/04/2007) até 26/12/2012
C-ES-7-1	04/01/2010 até 26/12/2012	L-ES-7-1	02/04/2007 até 26/12/2012
C-ES-4-1	04/01/2010 até 26/12/2012	L-ES-4-1	02/04/2007 até 26/12/2012
C-MSE-7-2	03/01/2011 até 23/12/2013	L-MSE-7-2	31/03/2008 até 23/12/2013
C-MSE-4-2	03/01/2011 até 23/12/2013	L-MSE-4-2	31/03/2008 até 23/12/2013
C-ES-7-2	03/01/2011 até 23/12/2013	L-ES-7-2	31/03/2008 até 23/12/2013
C-ES-4-2	03/01/2011 até 23/12/2013	L-ES-4-2	31/03/2008 até 23/12/2013
C-MSE-7-3	02/01/2012 até 22/12/2014	L-MSE-7-3	30/03/2009 até 22/12/2014
C-MSE-4-3	02/01/2012 até 22/12/2014	L-MSE-4-3	30/03/2009 até 22/12/2014
C-ES-7-3	02/01/2012 até 22/12/2014	L-ES-7-3	30/03/2009 até 22/12/2014
C-ES-4-3	02/01/2012 até 22/12/2014	L-ES-4-3	30/03/2009 até 22/12/2014
C-MSE-7-4	02/01/2013 até 21/12/2015	L-MSE-7-4	29/03/2010 até 21/12/2015
C-MSE-4-4	02/01/2013 até 21/12/2015	L-MSE-4-4	29/03/2010 até 21/12/2015
C-ES-7-4	02/01/2013 até 21/12/2015	L-ES-7-4	29/03/2010 até 21/12/2015
C-ES-4-4	02/01/2013 até 21/12/2015	L-ES-4-4	29/03/2010 até 21/12/2015
C-MSE-7-5	30/12/2013 até 19/12/2016	L-MSE-7-5	28/03/2011 até 19/12/2016
C-MSE-4-5	30/12/2013 até 19/12/2016	L-MSE-4-5	28/03/2011 até 19/12/2016
C-ES-7-5	30/12/2013 até 19/12/2016	L-ES-7-5	28/03/2011 até 19/12/2016
C-ES-4-5	30/12/2013 até 19/12/2016	L-ES-4-5	28/03/2011 até 19/12/2016

A seguir mostramos o resultado do treinamento e uso da rede C-ES-7-1 para predição dos dados futuros do índice, ou seja, os primeiros 4 pontos após o término do primeiro conjunto de treinamento menor. Ver figura 4.10 e 4.11. A linha em azul é o histórico do índice utilizado no treinamento. Em seguida, o histórico do índice é mostrado na cor magenta, que é a parte do mesmo utilizada para teste e validação no treinamento. Ao final, em preto, através de uma marcação com círculos, são mostrados os pontos de predições, e em azul, com marcação de asteriscos, o valor real. Nas predições, visualmente não há um acerto 100%. Aparentemente há um *offset*, embora as oscilações tenham sido acertadas. Neste caso, as duas primeiras predições aparentemente não seguiram a tendência dos dados reais. No entanto, não se pode concluir sobre a qualidade do sistema somente a partir destas duas predições. Será necessário simular o algoritmo em todo o período de análise com o uso do indicador  $IMM_N$  e então avaliar o retorno obtido.

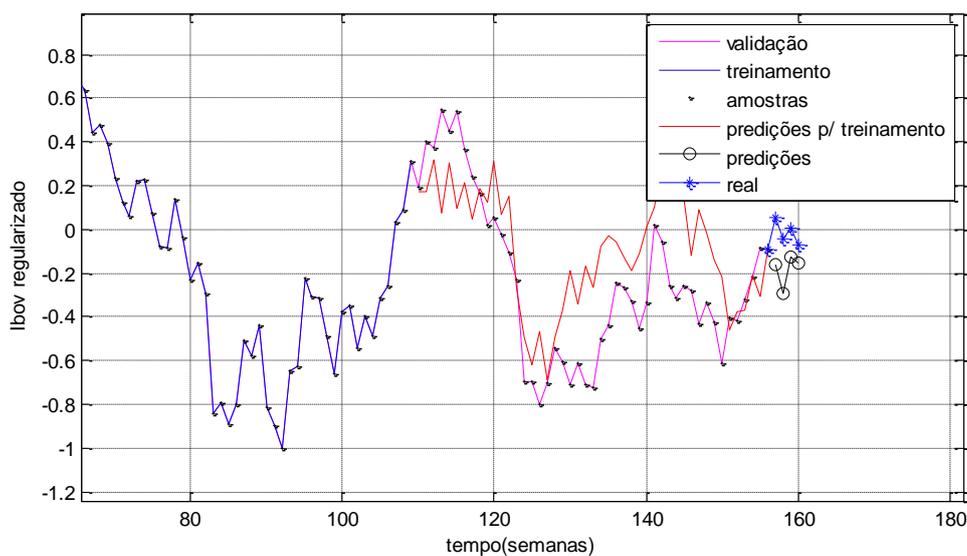


Figura 4.10 – Rede C-ES-7-1 no primeiro período, predição do primeiro conjunto de 4 pontos

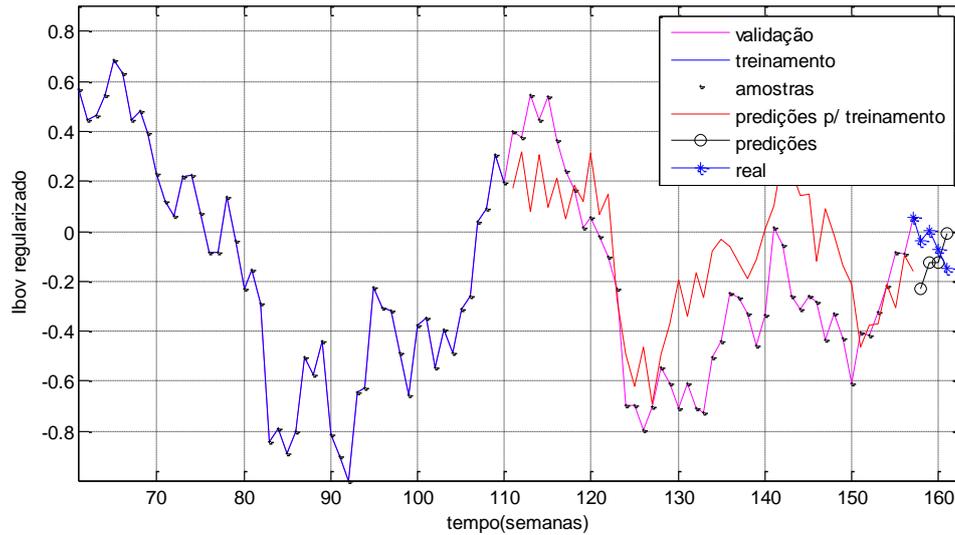


Figura 4.11 – Rede C-ES-7-1 no primeiro período, predição do segundo conjunto de 4 pontos

A seguir mostramos o resultado do treinamento e uso da rede C-MSE-4-3 para predição dos dados futuros do índice, ou seja, os primeiros 4 pontos após o término do terceiro conjunto de treinamento. Ver figura 4.12 e 4.13. A linha em azul é o histórico do índice utilizando no treinamento e depois o histórico do índice fica na cor magenta que é a parte do mesmo utilizada para teste e validação no treinamento. Ao final, em preto, através das marcações com círculos, são mostradas as predições, e em azul, com marcações de asteriscos, os valores reais. Visualmente não há um acerto de 100%. Neste exemplo, no entanto, diferentemente do exemplo anterior, não há um *offset*. O Sistema de Negociação não necessariamente precisará que os valores sejam totalmente idênticos. Se houver pelo menos um acerto de tendência recorrente ao longo das predições, ele poderá gerar um resultado satisfatório. Neste caso, aparentemente, essas duas primeiras predições não acertaram a tendência real. No entanto, não se pode concluir sobre a qualidade do sistema somente a partir de duas predições. Será necessário simular o algoritmo com o uso do indicador  $IMM_N$  e então avaliar o retorno obtido.

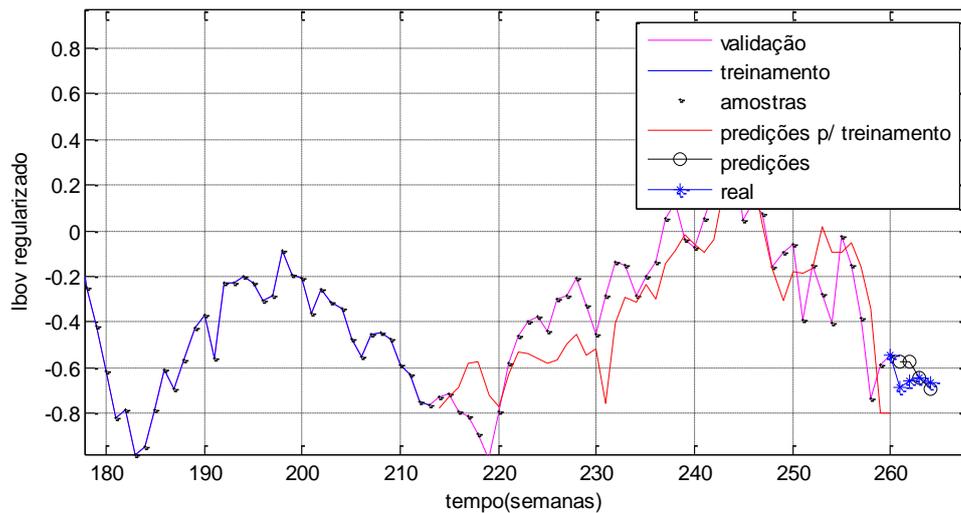


Figura 4.12 – Rede C-MSE-4-3 no terceiro período, predição do primeiro conjunto de 4 pontos

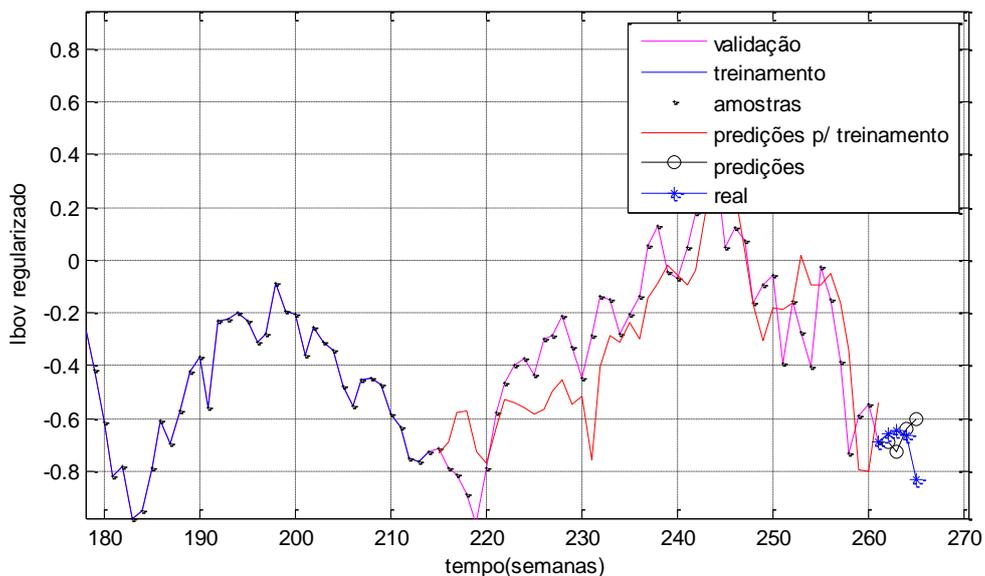


Figura 4.13 – Rede C-MSE-4-3 no terceiro período, predição do segundo conjunto de 4 pontos

As demais 38 redes não terão aqui seu gráfico de predição do primeiro e segundo conjunto de predições exposto, pois ocuparia muito espaço. As outras redes, assim como estas cujos gráficos foram mostrados, serão utilizadas no algoritmo de negociação e os retornos gerados serão expostos no capítulo de Resultados. A sequência com que o sistema de negociação usará a rede não será essa exposta na tabela 4.5, mas sim conforme

mostrado na tabela 4.6. Nesta tabela, é possível observar na sequência de execução no algoritmo de negociação.

Tabela 4.6 – Disposição das RN criadas de acordo com a ordem de execução

Período Curto		Período Longo	
Ordem	Rede	Ordem	Rede
1	C-MSE-7-1	1	L-MSE-7-1
2	C-MSE-7-2	2	L-MSE-7-2
3	C-MSE-7-3	3	L-MSE-7-3
4	C-MSE-7-4	4	L-MSE-7-4
5	C-MSE-7-5	5	L-MSE-7-5
6	C-MSE-4-1	6	L-MSE-4-1
7	C-MSE-4-2	7	L-MSE-4-2
8	C-MSE-4-3	8	L-MSE-4-3
9	C-MSE-4-4	9	L-MSE-4-4
10	C-MSE-4-5	10	L-MSE-4-5
11	C-ES-7-1	11	L-ES-7-1
12	C-ES-7-2	12	L-ES-7-2
13	C-ES-7-3	13	L-ES-7-3
14	C-ES-7-4	14	L-ES-7-4
15	C-ES-7-5	15	L-ES-7-5
16	C-ES-4-1	16	L-ES-4-1
17	C-ES-4-2	17	L-ES-4-2
18	C-ES-4-3	18	L-ES-4-3
19	C-ES-4-4	19	L-ES-4-4
20	C-ES-4-5	20	L-ES-4-5

## 5. Operação do Sistema e Resultados

### 5.1. Introdução

Os resultados das simulações do sistema de negociação, que internamente incluem as previsões realizadas pela rede NAR, foram obtidos a partir de 8 combinações de arquitetura-treinamento, de modo a gerar um número razoável e abranger um grande intervalo, quais sejam: sete neurônios na camada interna, treinamento com 156 pontos e critério de parada utilizando *Mean Squared Error* (rede C-MSE-7); sete neurônios na camada interna, treinamento com 300 pontos e critério de parada com base no *Mean Squared Error* (rede L-MSE-7); quatro neurônios na camada interna, treinamento com 156 pontos e critério de parada com base no *Mean Squared Error* (rede C-MSE-4); quatro neurônios na camada interna, treinamento com 300 pontos e critério de parada com base no *Mean Squared Error* (rede L-MSE-4); sete neurônios na camada interna, treinamento com 156 pontos e critério de parada *Early Stopping* (rede C-ES-7); sete neurônios na camada interna, treinamento com 300 pontos e critério de parada *Early Stopping* (rede L-ES-7); quatro neurônios na camada interna, treinamento com 156 pontos e critério de parada *Early Stopping* (rede C-ES-4); quatro neurônios na camada interna, treinamento com 300 pontos e critério de parada *Early Stopping* (rede L-ES-4).

Para melhor organizar os resultados, os subitens a seguir apresentam as tabelas e gráficos gerados para cada situação. No último item aborda-se uma comparação dos resultados entre si e com resultados de outros autores previamente publicados na literatura.

### 5.2. Rede 1 - NAR C-MSE-7

O conjunto de redes C-MSE-7 foi criado a partir da junção temporal das redes C-MSE-7-1, C-MSE-7-2, C-MSE-7-3, C-MSE-7-4 e C-MSE-7-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 156 pontos, com o mesmo critério de parada, o critério MSE, e são constituídas por sete neurônios na camada interna. Cada

uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. No gráfico da figura 5.1, são mostrados o índice estimado, em vermelho e o índice real, em azul. Em alguns momentos esses índices divergem em tendência. No entanto, o objetivo pretendido, que é calcular o indicador de mínimos e máximos, pôde ser satisfeito.

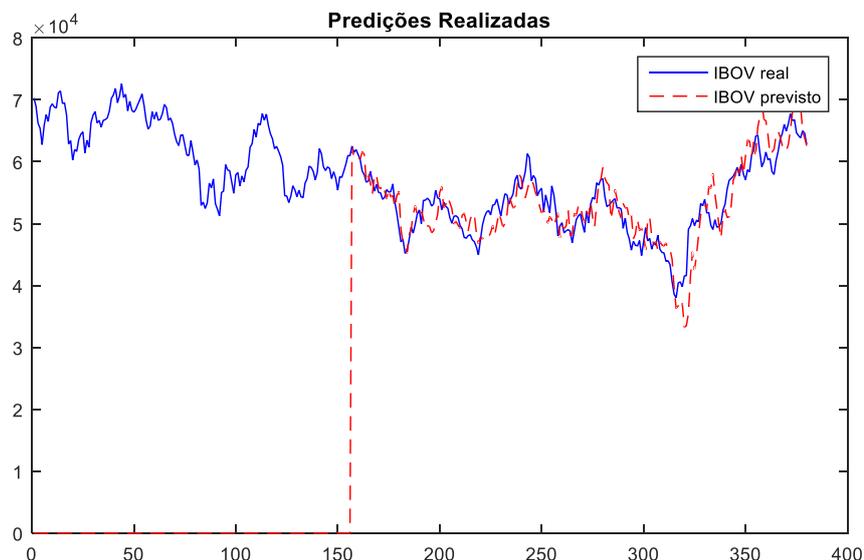


Figura 5.1 – Comparação para as predições para o conjunto de redes C-MSE-7

Com as previsões mostradas na figura 5.1 pode-se então proceder ao cálculo do  $IMM_N$ , sendo  $N$  igual a quatro. Pelo método proposto nesse trabalho, de posse do  $IMM_N$ , é possível realizar indicações de compra e venda. Na figura 5.2 plota-se o cálculo do indicador e seu limiar, conforme mostrado no capítulo 4, com a diferença de que, no capítulo 4, os dados utilizados para o cálculo foram os reais e não estes estimados através destas redes NAR's. Pode-se observar nessa figura que o limiar foi atingido diversas vezes, o que demonstra que os dados estimados causarão várias indicações de compra e venda.

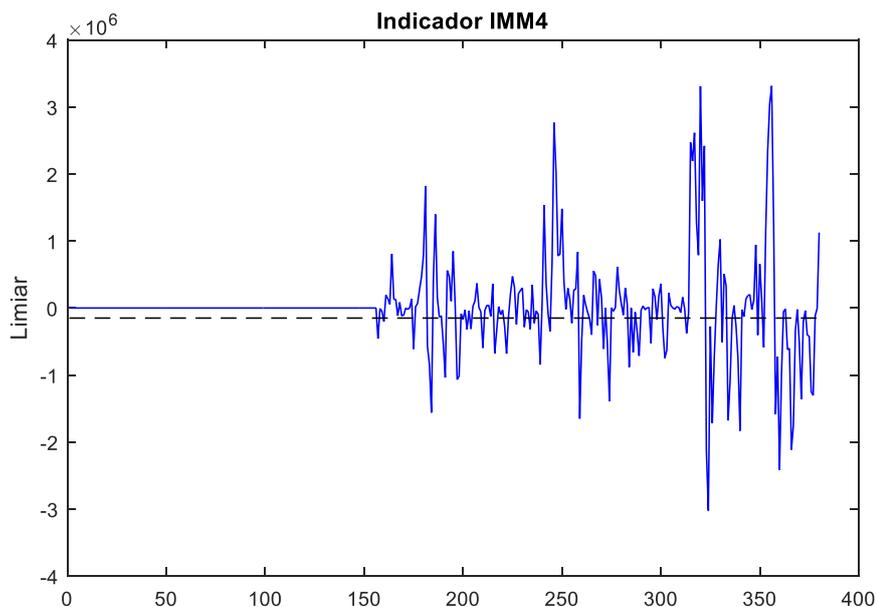


Figura 5.2 – Cálculo do indicador  $IMM_N$  para os dados estimados para o conjunto de redes C-MSE-7

Como parte final do processo de negociação, analisemos em seguida o que ocorre no módulo 5, responsável pelas operações de investir ou desinvestir, com a consequente apuração dos resultados dessas operações em termos do retorno alcançado ano a ano. Esse retorno é então comparado ao *benchmark*. As operações de compra e venda podem ser visualizadas através da figura 5.3, enquanto que os retornos alcançados, através da Tabela 5.1.

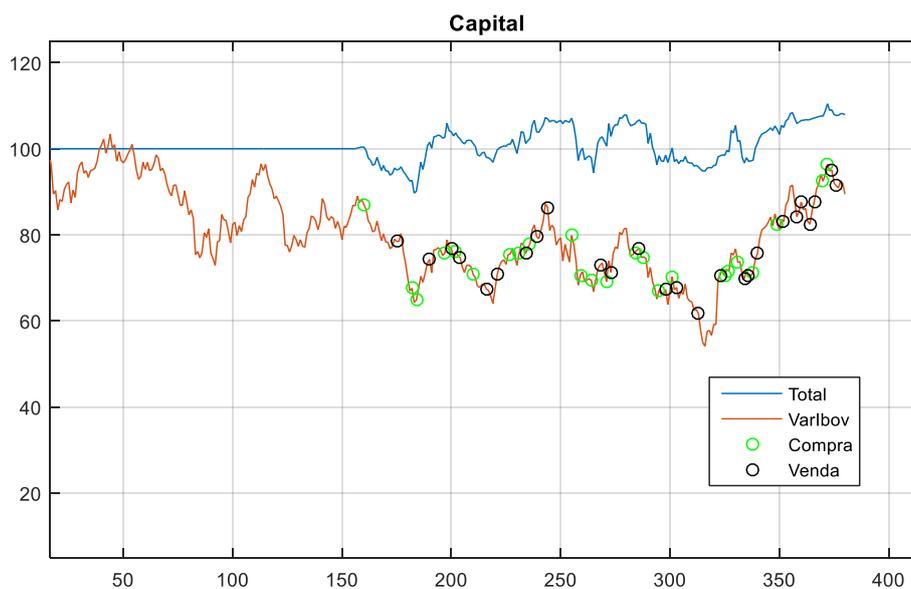


Figura 5.3 – Gráfico resumo das operações para o conjunto de redes C-MSE-7

Na figura 5.3, a série “Total” significa a evolução percentual do capital disponível que inicia em 100%, no período um, e pode sofrer a primeira alteração após o período 156, que corresponde ao treinamento, em virtude das operações de compra e venda. A série “VarIbov” é a variação percentual do índice Ibovespa ao longo do tempo, sendo que no período um corresponde a 100%. Por sua vez, as séries “Compra” e “Venda” são os momentos nos quais há a indicação por parte do sistema de realização de operações de compra e venda, respectivamente.

Tabela 5.1 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes C-MSE-7 (%)
2013	-15,5	1,91
2014	-2,90	-4,42
2015	-13,30	-1,16
2016	38,90	10,90
2017*	4,32	0,85
2017*-2013	3,07	7,69

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014 e 2015, porém, para os anos de 2016 e 2017 os resultados ficaram inferiores ao *benchmark*. Chama atenção o ano de 2013, em que o índice caiu 15,50%, enquanto que as operações renderam um valor positivo de 1,91%. Chama atenção também que, no acumulado dos anos, a metodologia levou a um resultado de 7,69%, superior em relação ao índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 51.

### 5.3. Rede 2 - NAR L-MSE-7

Este conjunto de rede L-MSE-7 foi criado a partir da junção temporal das redes L-MSE-7-1, L-MSE-7-2, L-MSE-7-3, L-MSE-7-4 e L-MSE-7-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 300 pontos, com o mesmo critério de parada, o critério MSE, e são constituídas por sete neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. No gráfico da figura 5.4, são mostrados o índice estimado, em vermelho e o índice real, em azul. Em alguns momentos esses índices divergem em

tendência. No entanto, o objetivo pretendido, que é calcular o indicador de mínimos e máximos, pôde ser satisfeito.

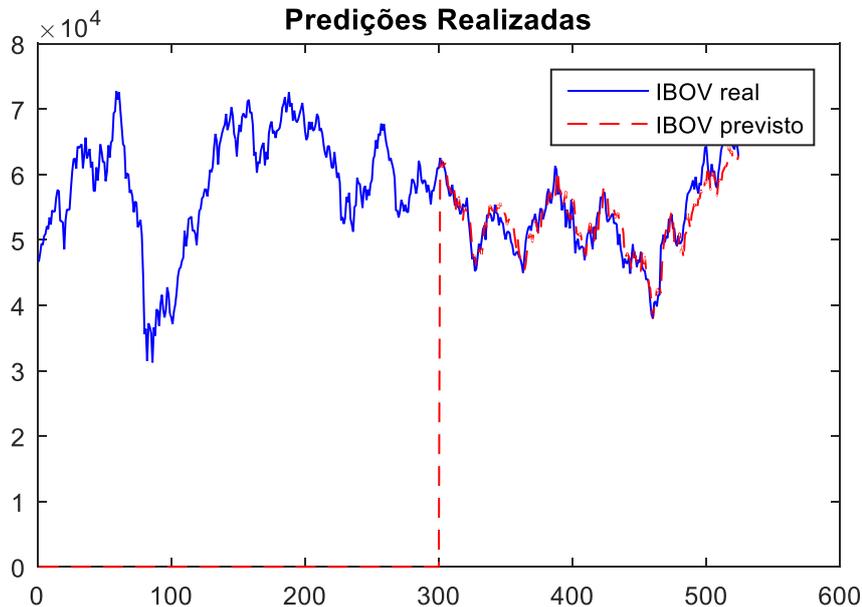


Figura 5.4– Comparação para as predições para o conjunto de redes L-MSE-7

Com as previsões mostradas na figura 5.4 pode-se então proceder ao cálculo do  $IMM_N$ , sendo N igual a quatro. Pelo método proposto nesse trabalho, de posse do  $IMM_N$ , é possível realizar indicações de compra e venda. Na figura 5.5 plota-se o cálculo do indicador e seu limiar, conforme mostrado no capítulo 4, com a diferença de que, no capítulo 4, os dados utilizados para o cálculo foram os reais e não estes estimados através destas redes NAR's. Pode-se observar nessa figura que o limiar foi atingido diversas vezes, o que demonstra que os dados estimados causarão várias indicações de compra e venda.

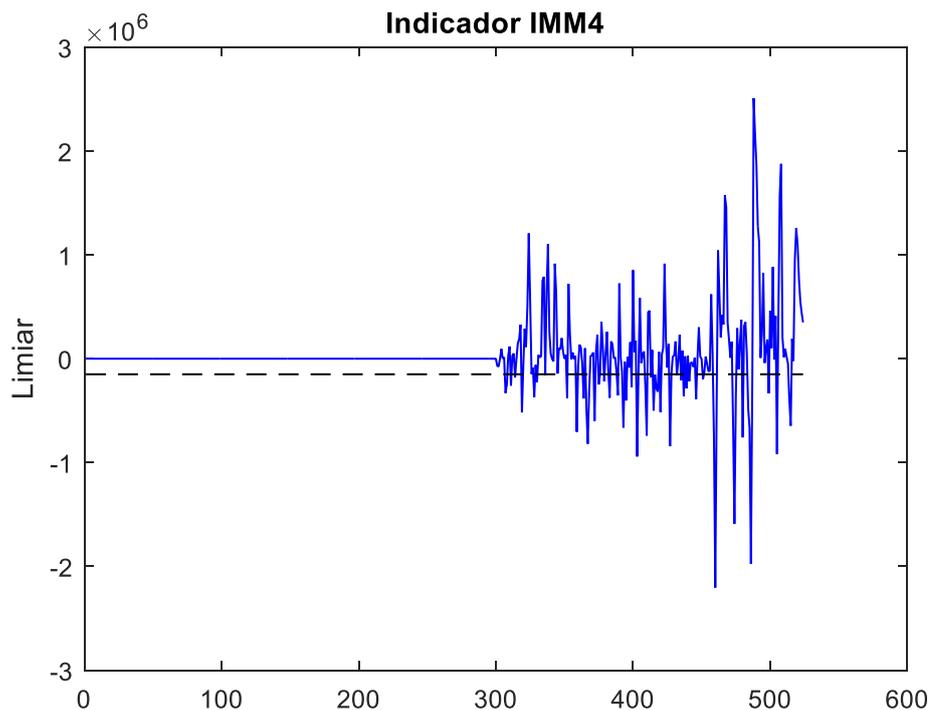


Figura 5.5 – Cálculo do indicador  $IMM_N$  para os dados estimados para o conjunto de redes L-MSE-7

Como parte final do processo de negociação, analisemos em seguida o que ocorre no módulo 5, responsável pelas operações de investir ou desinvestir, com a consequente apuração dos resultados dessas operações em termos do retorno alcançado ano a ano. Esse retorno é então comparado ao *benchmark*. As operações de compra e venda podem ser visualizadas através da figura 5.6, enquanto que os retornos alcançados, através da Tabela 5.2.

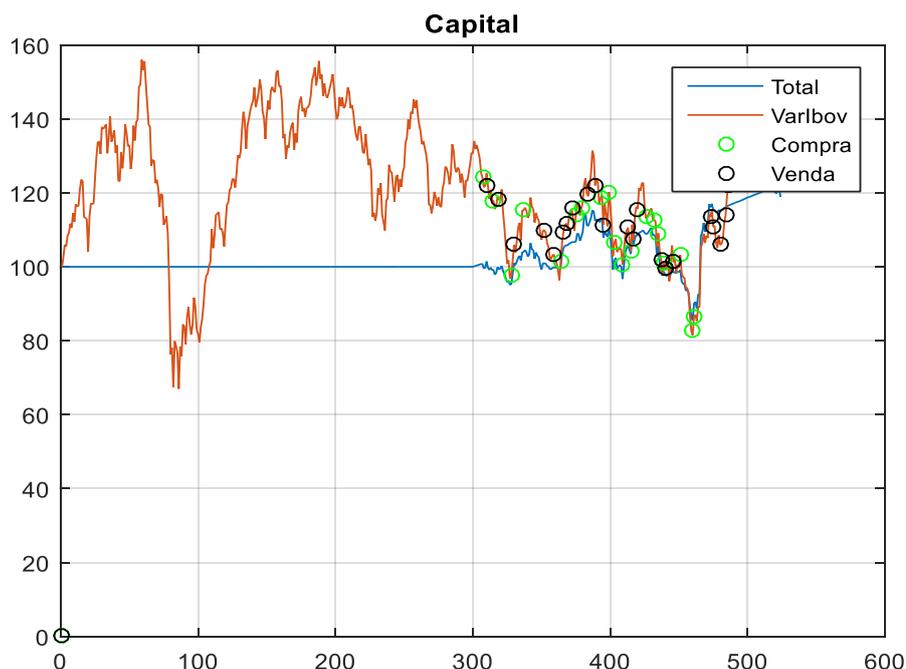


Figura 5.6 – Gráfico resumo das operações para o conjunto de redes L-MSE-7

Na figura 5.6, a série “Total” significa a evolução percentual do capital disponível que inicia em 100%, no período um, e pode sofrer a primeira alteração após o período 300, que corresponde ao treinamento, em virtude das operações de compra e venda. A série “VarIbov” é a variação percentual do índice Ibovespa ao longo do tempo, sendo que no período um corresponde a 100%. Por sua vez, as séries “Compra” e “Venda” são os momentos nos quais há a indicação por parte do sistema de realização de operações de compra e venda, respectivamente.

Tabela 5.2 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes L-MSE-7 (%)
<b>2013</b>	-15,5	0,89
<b>2014</b>	-2,90	-1,33
<b>2015</b>	-13,30	3,92
<b>2016</b>	38,90	28,25
<b>2017**</b>	4,32	-0,95
<b>2017**-2013</b>	3,07	31,40

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, ficou melhor para os anos de 2013, 2014 e 2015, porém, para os anos de 2016 e 2017 os resultados ficaram

inferiores ao *benchmark*. Chama atenção o ano de 2013, em que o índice caiu 15,50% enquanto que as operações renderam um valor positivo de 0,89%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 31,40%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi de 45.

#### 5.4. Rede 3 - NAR C-MSE-4

Este conjunto de rede C-MSE-4 foi criado a partir da junção temporal das redes C-MSE-4-1, C-MSE-4-2, C-MSE-4-3, C-MSE-4-4 e C-MSE-4-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 156 pontos, com o mesmo critério de parada, o critério MSE, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. No gráfico da figura 5.7, são mostrados o índice estimado, em vermelho e o índice real, em azul. Em alguns momentos esses índices divergem em tendência. No entanto, o objetivo pretendido, que é calcular o indicador de mínimos e máximos, pôde ser satisfeito.

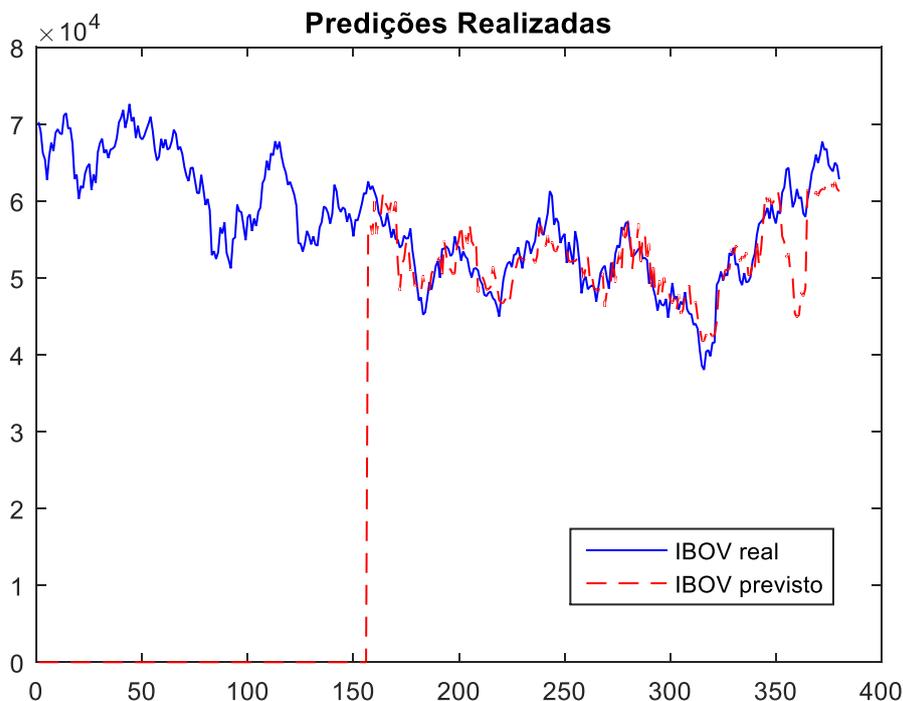


Figura 5.7– Comparação para as predições para o conjunto de redes C-MSE-4

Com as previsões mostradas na figura 5.7 pode-se então proceder ao cálculo do  $IMM_N$ , sendo  $N$  igual a quatro. Pelo método proposto nesse trabalho, de posse do  $IMM_N$ , é possível realizar indicações de compra e venda. Na figura 5.8 plota-se o cálculo do indicador e seu limiar, conforme mostrado no capítulo 4, com a diferença de que, no capítulo 4, os dados utilizados para o cálculo foram os reais e não estes estimados através destas redes NAR's. Pode-se observar nessa figura que o limiar foi atingido diversas vezes, o que demonstra que os dados estimados causarão várias indicações de compra e venda.

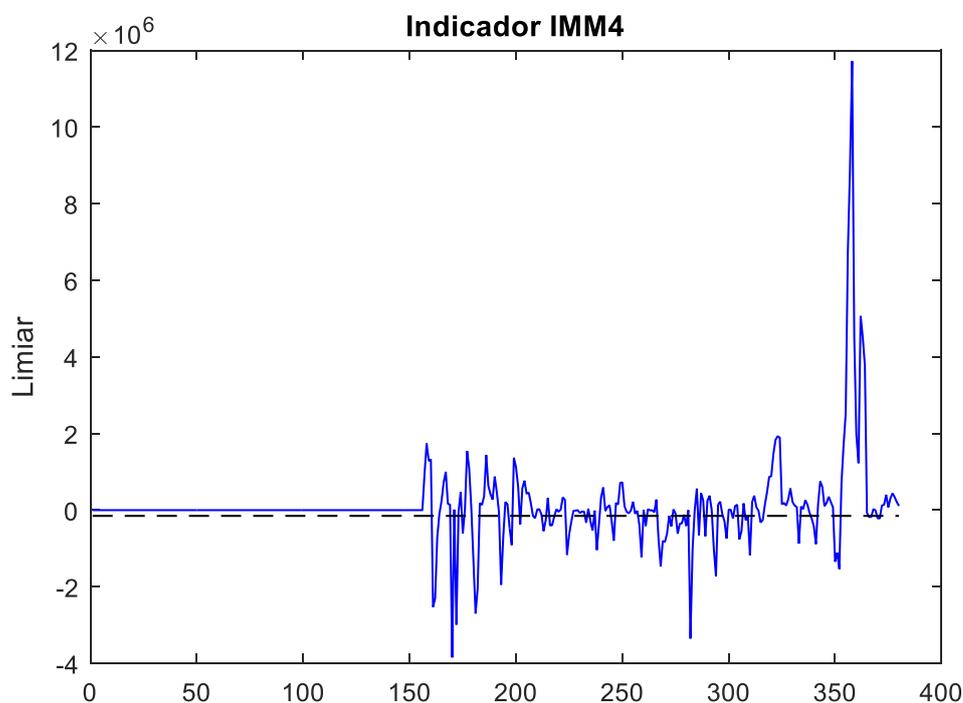


Figura 5.8– Cálculo do indicador  $IMM_N$  para os dados estimados para o conjunto de redes C-MSE-4

Como parte final do processo de negociação, analisemos em seguida o que ocorre no módulo 5, responsável pelas operações de investir ou desinvestir, com a consequente apuração dos resultados dessas operações em termos do retorno alcançado ano a ano. Esse retorno é então comparado ao *benchmark*. As operações de compra e venda podem ser visualizadas através da figura 5.9, enquanto que os retornos alcançados, através da Tabela 5.3.

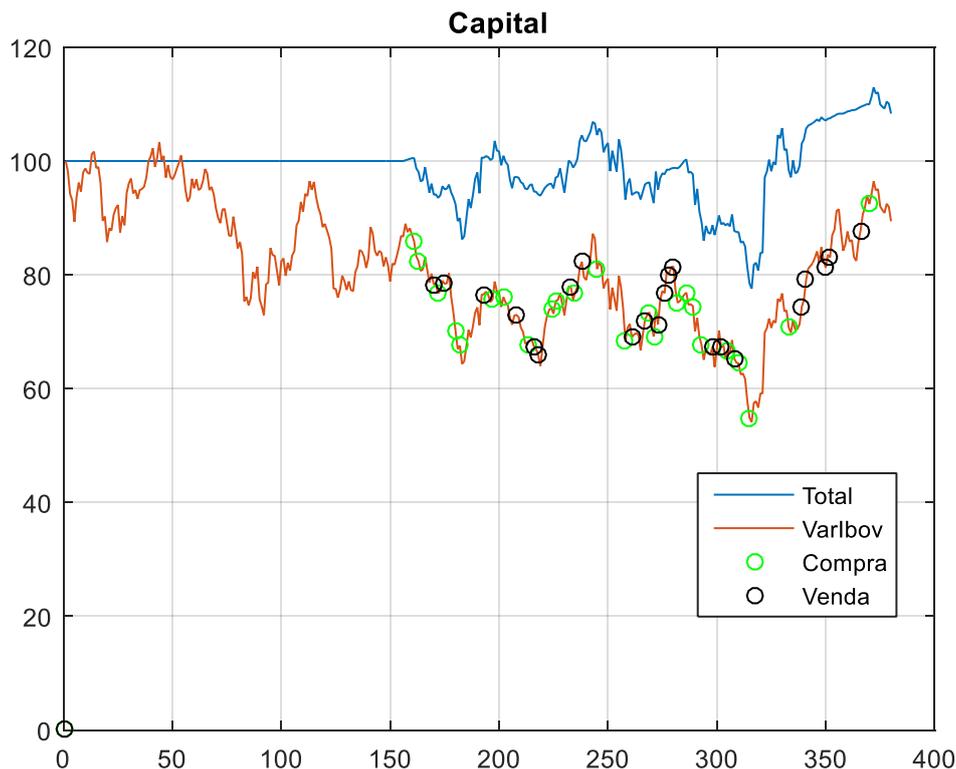


Figura 5.9– Gráfico resumo das operações para o conjunto de redes C-MSE-4

Na figura 5.9, a série “Total” significa a evolução percentual do capital disponível que inicia em 100%, no período um, e pode sofrer a primeira alteração após o período 156, que corresponde ao treinamento, em virtude das operações de compra e venda. A série “VarIbov” é a variação percentual do índice Ibovespa ao longo do tempo, sendo que no período um corresponde a 100%. Por sua vez, as séries “Compra” e “Venda” são os momentos nos quais há a indicação por parte do sistema de realização de operações de compra e venda, respectivamente.

Tabela 5.3 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes C-MSE-4 (%)
2013	-15,5	-2,92
2014	-2,90	-3,12
2015	-13,30	-9,63
2016	38,90	28,63
2017*	4,32	-0,89
2017*-2013	3,07	8,33

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014 e 2015, porém, para os anos de 2016 e 2017 os resultados ficaram inferiores ao *benchmark*. Chama atenção o ano de 2013, em que o índice caiu 15,50% enquanto que as operações caíram apenas 2,92%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 8,33%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 46.

### 5.5. Rede 4 - NAR L-MSE-4

Este conjunto de rede L-MSE-4 foi criado a partir da junção temporal das redes L-MSE-4-1, L-MSE-4-2, L-MSE-4-3, L-MSE-4-4 e L-MSE-4-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 300 pontos, com o mesmo critério de parada, o critério MSE, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. No gráfico da figura 5.10, são mostrados o índice estimado, em vermelho e o índice real, em azul. Em alguns momentos esses índices divergem em tendência. No entanto, o objetivo pretendido, que é calcular o indicador de mínimos e máximos, pôde ser satisfeito.

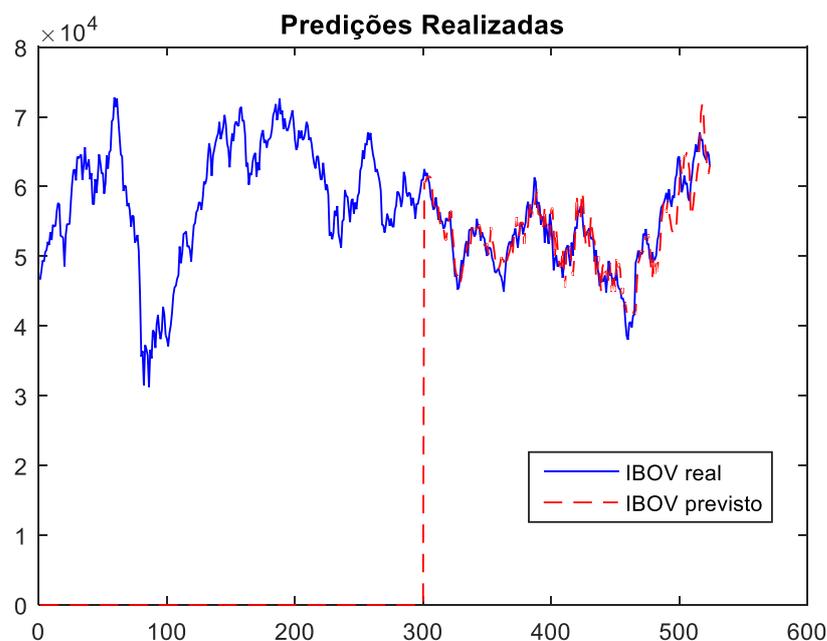


Figura 5.10– Comparação para as predições para o conjunto de redes L-MSE-4

Com as previsões mostradas na figura 5.10 pode-se então proceder ao cálculo do  $IMM_N$ , sendo  $N$  igual a quatro. Pelo método proposto nesse trabalho, de posse do  $IMM_N$ , é possível realizar indicações de compra e venda. Na figura 5.11 plota-se o cálculo do indicador e seu limiar, conforme mostrado no capítulo 4, com a diferença de que, no capítulo 4, os dados utilizados para o cálculo foram os reais e não estes estimados através destas redes NAR's. Pode-se observar nessa figura que o limiar foi atingido diversas vezes, o que demonstra que os dados estimados causarão várias indicações de compra e venda.

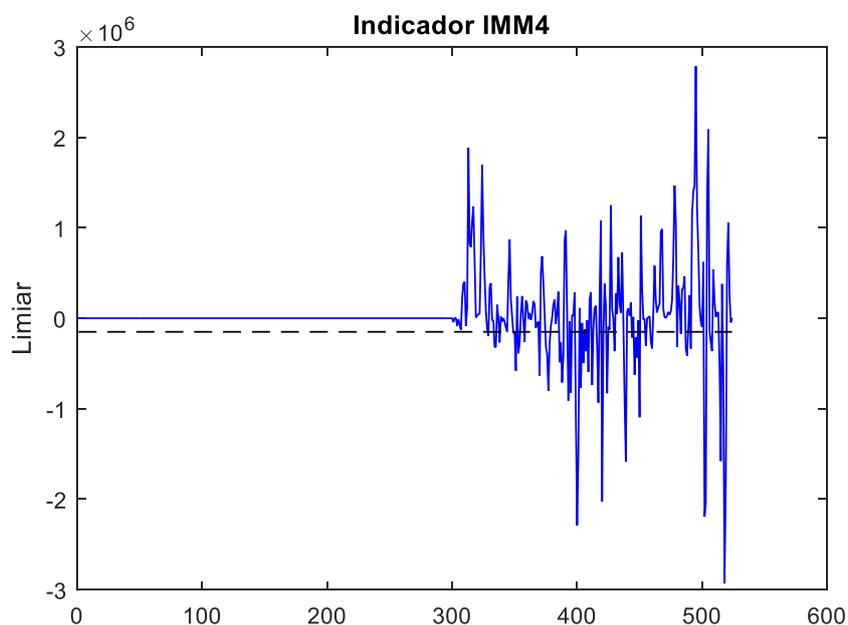


Figura 5.11– Cálculo do indicador  $IMM_N$  para os dados estimados para o conjunto de redes L-MSE-4

Como parte final do processo de negociação, analisemos em seguida o que ocorre no módulo 5, responsável pelas operações de investir ou desinvestir, com a consequente apuração dos resultados dessas operações em termos do retorno alcançado ano a ano. Esse retorno é então comparado ao *benchmark*. As operações de compra e venda podem ser visualizadas através da figura 5.12, enquanto que os retornos alcançados, através da Tabela 5.4.

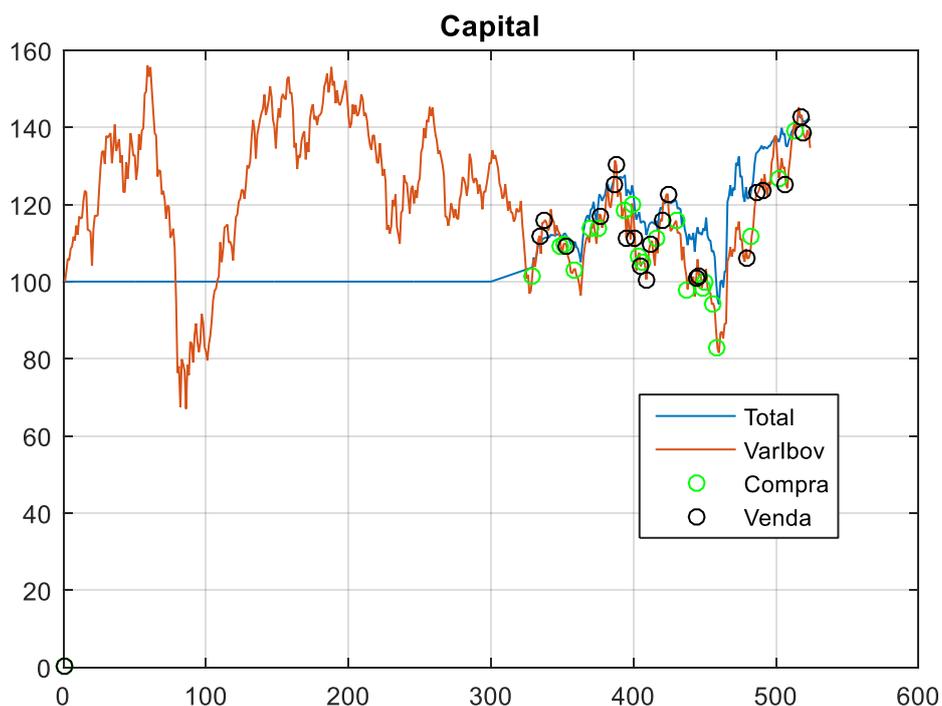


Figura 5.12– Gráfico resumo das operações para o conjunto de redes L-MSE-4

Na figura 5.12, a série “Total” significa a evolução percentual do capital disponível que inicia em 100%, no período um, e pode sofrer a primeira alteração após o período 300, que corresponde ao treinamento, em virtude das operações de compra e venda. A série “VarIbov” é a variação percentual do índice Ibovespa ao longo do tempo, sendo que no período um corresponde a 100%. Por sua vez, as séries “Compra” e “Venda” são os momentos nos quais há a indicação por parte do sistema de realização de operações de compra e venda, respectivamente.

Tabela 5.4 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes L-MSE-4 (%)
<b>2013</b>	-15,5	11,88
<b>2014</b>	-2,90	2,98
<b>2015</b>	-13,30	-7,58
<b>2016</b>	38,90	28,22
<b>2017*</b>	4,32	3,86
<b>2017*-2013</b>	3,07	41,82

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014 e 2015, porém, para os anos de 2016 e 2017 os resultados ficaram inferiores ao *benchmark*. Chama atenção o ano de 2013, em que o índice caiu -15,50% enquanto que as operações renderam um valor positivo de 11,88%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 41,82%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi de 41.

### 5.6. Rede 5 - NAR C-ES-7

Este conjunto de rede C-ES-7 foi criado a partir da junção temporal das redes C-ES-7-1, C-ES-7-2, C-ES-7-3, C-ES-7-4 e C-ES-7-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 156 pontos, com o mesmo critério de parada, o critério ES, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. Os gráficos modelos (Predições Realizadas, Plotagem do Indicador IMM<sub>4</sub> e Capital que mostra o momento das operações e a evolução do capital) apresentados nas outras sessões serão suprimidos aqui, pois eles serão semelhantes em informações. Para não ficar repetitivo, aqui se optou por apresentar somente a tabela de resultados, no caso a tabela 5.5.

Tabela 5.5 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes C-ES-7 (%)
<b>2013</b>	-15,5	1,61
<b>2014</b>	-2,90	7,74
<b>2015</b>	-13,30	-8,27
<b>2016</b>	38,90	24,26
<b>2017*</b>	4,32	3,51
<b>2017*-2013</b>	3,07	29,18

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014 e 2015, porém, para os anos de 2016 e 2017 os resultados ficaram inferiores ao *benchmark*. Chama atenção o ano de 2013, em que o índice caiu 15,50% enquanto que as operações renderam um valor positivo de 1,61%. Chama atenção também que, no

acumulado dos anos, a metodologia alcançou um resultado de 29,18%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 40.

### 5.7. Rede 6 - NAR L-ES-7

Este conjunto de rede L-ES-7 foi criado a partir da junção temporal das redes L-ES-7-1, L-ES-7-2, L-ES-7-3, L-ES-7-4 e L-ES-7-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 300 pontos, com o mesmo critério de parada, o critério ES, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. Os gráficos modelos (Predições Realizadas, Plotagem do Indicador IMM<sub>4</sub> e Capital que mostra o momento das operações e a evolução do capital) apresentados nas outras sessões serão suprimidos aqui, pois eles serão semelhantes em informações. Para não ficar repetitivo, aqui se optou por apresentar somente a tabela de resultados, no caso a tabela 5.6.

Tabela 5.6 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes L-ES-7 (%)
<b>2013</b>	-15,5	0,61
<b>2014</b>	-2,90	-0,92
<b>2015</b>	-13,30	-1,49
<b>2016</b>	38,90	42,79
<b>2017*</b>	4,32	2,27
<b>2017*-2013</b>	3,07	43,40

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014, 2015 e 2016, porém, para o ano de 2017 o resultado ficou inferior ao *benchmark*. Chama atenção o ano de 2016, em que o índice cresceu 38,93% enquanto que as operações renderam 42,79%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 43,4%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 36.

### 5.8. Rede 7 - NAR C-ES-4

Este conjunto de rede C-ES-4 foi criado a partir da junção temporal das redes C-ES-4-1, C-ES-4-2, C-ES-4-3, C-ES-4-4 e C-ES-4-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 156 pontos, com o mesmo critério de parada, o critério ES, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. Os gráficos modelos (Predições Realizadas, Plotagem do Indicador IMM<sub>4</sub> e Capital que mostra o momento das operações e a evolução do capital) apresentados nas outras sessões serão suprimidos aqui, pois eles serão semelhantes em informações. Para não ficar repetitivo, aqui se optou por apresentar somente a tabela de resultados, no caso a tabela 5.7.

Tabela 5.7 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

Anos	Ibovespa (%)	Redes C-ES-4 (%)
2013	-15,5	-0,91
2014	-2,90	-6,19
2015	-13,30	-2,70
2016	38,90	11,42
2017*	4,32	6,71
2017*-2013	3,07	21,72

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2015 e 2017, porém, para os anos de 2014 e 2016 os resultados ficaram inferiores ao *benchmark*. Chama atenção o ano de 2017, em que o índice cresceu 4,32% enquanto que as operações renderam 6,71%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 21,72%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 49.

### 5.9. Rede 8 - NAR L-ES-4

Este conjunto de rede L-ES-4 foi criado a partir da junção temporal das redes L-ES-4-1, L-ES-4-2, L-ES-4-3, L-ES-4-4 e L-ES-4-5. Estas redes foram treinadas em seus conjuntos de treinamento, com 300 pontos, com o mesmo critério de parada, o critério

ES, e são constituídas por quatro neurônios na camada interna. Cada uma das redes prevê um total de 50 pontos, conforme descrito no item 4.6, totalizando 250 pontos de predição. Os gráficos modelos (Predições Realizadas, Plotagem do Indicador IMM<sub>4</sub> e Capital que mostra o momento das operações e a evolução do capital) apresentados nas outras sessões serão suprimidos aqui, pois eles serão semelhantes em informações. Para não ficar repetitivo, aqui se optou por apresentar somente a tabela de resultados, no caso a tabela 5.8.

Tabela 5.8 – Desempenho alcançado para 2013, 2014, 2015, 2016 e 2017.

<b>Anos</b>	<b>Ibovespa (%)</b>	<b>Redes L-ES-4 (%)</b>
<b>2013</b>	-15,5	-1,15
<b>2014</b>	-2,90	-3,14
<b>2015</b>	-13,30	0,14
<b>2016</b>	38,90	25,25
<b>2017*</b>	4,32	5,44
<b>2017*-2013</b>	3,07	26,62

Fonte: Sítio da internet da BM&F-Bovespa; \* até 10/04.

Utilizar este conjunto de redes, segundo esta metodologia, foi melhor para os anos de 2013, 2014, 2015 e 2017, porém, para o ano de 2016 o resultado ficou inferior ao *benchmark*. Chama atenção o ano de 2017, em que o índice cresceu 4,32% enquanto que as operações renderam 5,44%. Chama atenção também que, no acumulado dos anos, a metodologia alcançou um resultado de 26,62%, superior ao resultado do índice, que foi de 3,07%. O total de operações de compra e venda foi igual a 40.

## 5.10. Comparações

Segue um quadro comparativo (tabela 5.9) que reúne as informações dispostas nas tabelas de 5.1 a 5.8. Nesta tabela, uma informação adicional foi colocada, qual seja, o PA (Percentual de Acertos) do indicador IMM<sub>N</sub> calculado através das predições em comparação ao IMM<sub>N</sub> calculado através da série real.

Tabela 5.9 – Resumo do desempenho dos oito conjuntos de redes.

	2013	2014	2015	2016	2017*	13-17*	PA (%)	Compra	Venda
IBOV	-15,5	-2,9	-13,3	38,90	4,32	<b>3,07</b>		NA	NA
C-MSE-7	1,91	-4,42	-1,16	10,-90	0,85	7,69	49,1	24	27
<b>L-MSE-7</b>	<b>0,89</b>	<b>-1,33</b>	<b>3,92</b>	<b>28,25</b>	<b>-0,95</b>	<b>31,40</b>	<b>60,0</b>	<b>21</b>	<b>24</b>
C-MSE-4	-2,92	-3,12	-9,63	28,63	-0,89	8,33	55,9	24	22
<b>L-MSE-4</b>	<b>11,88</b>	<b>2,98</b>	<b>-7,58</b>	<b>28,22</b>	<b>3,86</b>	<b>41,82</b>	<b>59,5</b>	<b>20</b>	<b>21</b>
<b>C-ES-7</b>	<b>1,61</b>	<b>7,74</b>	<b>-8,27</b>	<b>24,26</b>	<b>3,51</b>	<b>29,18</b>	<b>54,1</b>	<b>20</b>	<b>20</b>
<b>L-ES-7</b>	<b>0,61</b>	<b>-0,92</b>	<b>-1,49</b>	<b>42,79</b>	<b>2,27</b>	<b>43,40</b>	<b>61,8</b>	<b>24</b>	<b>12</b>
C-ES-4	-0,91	-6,19	-2,7	11,42	6,71	21,72	52,7	26	23
L-ES-4	-1,15	-3,14	0,14	25,25	5,44	26,62	63,2	23	17

Fonte: Sítio da internet da BM&F-Bovespa; \*até 10/04.

Vale ressaltar que o ano de 2017 foi simulado até o dia dez de abril, pois estas eram as informações disponíveis quando da transferência delas da internet para se poder dar início a concepção e elaboração da metodologia e simulações deste trabalho.

O conjunto de redes que obteve o melhor PA (Percentual de Acertos), sendo de 63,2%, foi a L-ES-4. A pesar disso, ela não se configura entre os quatro melhores em termos de retorno. Dos oito conjuntos de redes testados segue abaixo a relação dos quatro melhores resultados com o sistema de negociação, comparando o rendimento em todo o período simulado, de 2013 até abril de 2017.

**1º L-ES-7** com 43,4 % de retorno no acumulado contra 3,07 % do *benchmark*

**2º L-MSE-4** com 41,8 % de retorno no acumulado contra 3,07 % do *benchmark*

**3º L-MSE-7** com 31,4 % de retorno no acumulado contra 3,07 % do *benchmark*

**4º C-ES-7** com 29,2 % de retorno no acumulado contra 3,07 % do *benchmark*

Pode-se perceber que, diante dos resultados, possuir um período maior de treinamento resultou em rentabilidades maiores. Além disso, uma rede mais complexa,

com 7 neurônios na camada interna, também se mostrou mais vantajosa. Já o critério de treinamento não foi impactante já que houve um empate se considerarmos que cada um apareceu em metade das vezes entre os 4 melhores resultados de rentabilidade obtidos através do uso do sistema de negociação e mostrados anteriormente.

Os retornos foram apurados trimestre a trimestre e o teste não-paramétrico de Wilcoxon<sup>4</sup> foi aplicado para os conjuntos das redes L-ES-7 e L-MSE-4 em comparação ao *benchmark*. No primeiro se conclui que é possível rejeitar a hipótese nula ( $Z = -1,82$ ;  $\rho = 0,034$ ), ou seja, houve de fato uma melhora do retorno em termos trimestrais. No segundo, o resultado indica que não é possível rejeitar a hipótese nula ( $Z = -0,74$ ;  $\rho = 0,2327$ ) pelo fato de  $\rho$  ficar superior a 5%.

---

<sup>4</sup> Disponível em: <https://www.socscistatistics.com/tests/signedranks/Default2.aspx> Acesso em: 03/01/2019.

## 6. Conclusões

Observa-se, através da tabela 5.9, que nenhum dos oito conjuntos de redes obteve resultado inferior ao do índice Ibovespa no acumulado do período. Esse fato sugere que, apesar de em alguns casos não se obter ganhos expressivos, a utilização de um método avançado, como as redes neurais, se mostrou mais vantajoso do que não utilizar nenhuma técnica. O crescimento médio dos 8 conjuntos de rede ficou em 26,3%, o melhor deles em 43,4%, bastante superior ao índice Ibovespa, que cresceu apenas 3,1% no período observado.

Em Santos (2014), para os anos de 2011 a 2013, um outro sistema operando simuladamente sobre um conjunto de ações que compõe o índice, os métodos KNN e SVM, obteve crescimentos médios anuais do capital de 2,6% e 3,7% respectivamente, de outro lado, os crescimentos anuais médios obtidos pelo sistema sob o conjunto de rede **L-MSE-4** e **L-ES-7** no período de observação do presente trabalho, de 2011 a 2016 – excluído 2017, pois não operou até a finalização deste ano – foram de **8,1%** e **8,8%** respectivamente. Apesar da diferença, considera-se o resultado obtido por Santos (2014) bastante positivo, pois o índice teve um decréscimo anual médio de -9,42% no período de observação, de 2011 a 2013, de outro lado, no período de observação do presente trabalho o índice apresentou um decréscimo anual médio de -1,2%. Já em Pommerenzenbaum (2014) a aplicação de seu sistema ocorreu de 2011 a agosto de 2012 e foi mostrado que uma das estratégias apresentou crescimento da carteira de 22,8% no período todo, superior a um ano, em compensação, a pior estratégia apresentada levou a perdas de 80% do capital.

Em Chang *et al* (2014) foi obtido retorno médio de 14,27% para a modalidade de análise técnica e retorno de 22,23% quando utilizada a modalidade de análise técnica em combinação com análise sentimental das notícias da internet sobre um grupo selecionado de ações negociadas na bolsa de valores em Taiwan.

Tendo em vista o conhecimento adquirido ao longo do desenvolvimento do tema, algumas propostas de melhorias para trabalhos posteriores poderiam incorporar as seguintes ideias: criar uma rede para predições do indicador  $IMM_N$  em vez de prever a série do índice para posterior cálculo do indicador e aplicação; variar o tamanho do vetor de entrada da rede que foi mantido fixo; criar uma validação pós-treinamento em dados não utilizados no treinamento nem na validação convencional; aplicação em “real time” através de sistemas de compra e venda de corretoras de valores para operações em curtíssimo prazo, operando em uma amostragem de minuto ou dezenas de minuto; considerar o efeito da distribuição de lucros e dividendos, mas essa proposta pressupõe que o sistema opere simuladamente sobre as ações e não do índice; utilizar um comitê de redes para sugerir operações de compra e venda através de um sistema de votação; combinar o método desenvolvido aqui com análise de informações da internet, conforme apresentado em Souza (2017).

## 7. Bibliografia

AGHABOZORGI, Saeed; THE, Ying Wah. **Stock market co-movement assessment using a three-phase clustering method**. *Expert Systems with Applications*, v. 41, 2014, 1301-1314. Disponível em: < <https://doi.org/10.1016/j.eswa.2013.08.028>>. Acesso: 28/06/2017.

BAO, Yukun *et al.* **A Comparative Study of Multi-step-ahead Prediction for Crude Oil Price with Support Vector Regression**. In: *International Joint Conference on Computational Sciences and Optimization (CSO)*, 2011, Yunnan.

CAO, L. J.; TAY, Francis E. H. **Support vector machine with adaptive parameters in financial time series forecasting**. *IEEE Transactions on Neural Networks*, v. 14, 2003, 1506–1518. Disponível em: < <http://dl.acm.org/citation.cfm?id=2327202>>. Acesso: 28/06/2017.

CAVALCANTE Rodolfo C.; OLIVEIRA, Adriano L. I. **An approach to handle concept drift in financial time series based on Extreme Learning Machines and explicit Drift Detection**. In: *International Joint Conference on Neural Networks (IJCNN)*, 2015. Killarney.

CAVALCANTE, Rodolfo C. *et al.* **Computational Intelligence and Financial Markets: A Survey and Future Directions**. *Expert Systems With Applications*, v. 55, 2016, 194-211. Disponível em: < <http://dx.doi.org/10.1016/j.eswa.2016.02.006>>. Acesso: 28/06/2017.

CHEN, Pin-An; CHANG, Li-Chiu; CHANG, Fi-Jhon. **Reinforced recurrent neural networks for multi-step-ahead flood forecasts**. *Journal of Hydrology*, v. 497, 2013, 71-79. Disponível em: < <https://doi.org/10.1016/j.jhydrol.2013.05.038>>. Acesso: 11/09/2017.

CLAUMANN, Carlos A.; ROQUEIRO, Nestor; MACHADO, Ricardo A. F.; BOLZAN, Arioaldo. **Implementação de um controlador preditivo utilizando redes neurais recorrentes e algoritmos genéticos**. In: V Congresso Brasileiro de Redes Neurais, 2001, Rio de Janeiro.

COELHO, Fábio Ulhoa. **Manual de Direito Comercial**. 22. ed. São Paulo: Saraiva. 2010. 501p.

COSTA, Alexandre Fructuoso. **Previsão de Séries Temporais Financeiras por Meio de Redes Neurais Dinâmicas e Processos de Transformação de Dados: uma Abordagem Empírico-comparativa**. 2012. 94f. Dissertação (Mestrado em Engenharia

de Produção) - Faculdade de Engenharia de Bauru, Universidade Estadual Paulista Júlio de Mesquita Filho, Bauru.

DING, X. et al. *Deep Learning for Event-Driven Stock Prediction*. *Conference on Artificial Intelligence, n. Ijcai, p. 2327-2333, 2015*. Disponível em: < <https://www.ijcai.org/Proceedings/15/Papers/329.pdf> >. Acesso: 03/01/2019.

EVANS, Cain; PAPPAS, Konstantinos; XHAFA, Fatos. *Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation*. *Mathematical and Computer Modelling*, v. 58, 2013, 1249-1266. Disponível em: < <https://doi.org/10.1016/j.mcm.2013.02.002> >. Acesso: 28/06/2017.

GAMBOGI, Jarbas Aquiles. **Aplicação de Redes Neurais na Tomada de Decisão no Mercado de Ações**. 2013. 66f. Dissertação (Mestrado em Engenharia Elétrica) – Departamento de Telecomunicações e Controle, Universidade de São Paulo, São Paulo.

GUYON, I. *Neural Network and Applications Tutorial*. *Physics Reports*, v. 3-4, 1991, 215-259, North Holland.

HAGAN, Martin T.; DEMUTH, Howard B.; BEALE, Mark H. **Neural Network Toolbox User's Guide**. Disponível em: < [www.image.ece.ntua.gr/courses\\_static/nn/matlab](http://www.image.ece.ntua.gr/courses_static/nn/matlab) >. Acesso em: 28/06/2017.

HAGAN, Martin T.; DEMUTH, Howard B.; BEALE, Mark H.; JÉSUS, Orlando de. *Neural Network Design*. 2. ed. *Virtual Book*. 2014. 1012p. Disponível em: < <http://hagan.okstate.edu/nnd.html> >. Acesso em: 28/06/2017.

HAYKIN, Simon. *Neural Networks: A comprehensive Foundation*. 2. ed. Ontario: Person Education, 1999. 823p.

HUANG, Chien-Feng. *A hybrid stock selection model using genetic algorithms and support vector regression*. *Applied Soft Computing*, v. 12, 2012, 807-818. Disponível em: < <https://doi.org/10.1016/j.asoc.2011.10.009> >. Acesso: 28/06/2017.

JÚNIOR, José Maria Pires de Menezes. **Redes Neurais Dinâmicas para Predição e Modelagem Não-linear de Séries Temporais**. 2006, 113f. Dissertação (Mestrado em Engenharia de Teleinformática) – Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza.

KERR, Roberto Borges. **Mercado Financeiro e de Capitais**, 1. ed. São Paulo: Pearson. 2011. 230p.

LARSEN, Jan Ivar. *Predicting Stock Prices Using Technical Analysis and Machine Learning*. 2010. 81f. Dissertação (*Master of Science in Computer Science*) – Department of Computer and Information Science, Norwegian University of Science and Technology, Trondheim.

LEONDES, Cornelius T. *Algorithms and Architectures: Neural Network Systems Techniques and Applications*. Volume 1. 1. ed. California: Academic Press.1998. 457p.

LIANG, Xun *et al.* *Associating stock prices with web financial information time series based on support vector regression*. *Neurocomputing*, v. 115, 2013, 142-149.  
Disponível em: < <https://doi.org/10.1016/j.neucom.2013.01.011>>. Acesso: 28/06/2017.

MCNELIS, Paul D. *Neural Network in Finance: Gaining predictive edge in the Market*. 1. ed. California: Elsevier Academic Press. 2005. 243p.

Mohammad Talebi Motlagh, Hamid Khaloozadeh. *A new architecture for modeling and prediction of dynamic systems using neural networks: Application in Tehran stock exchange*. In: *International Conference on Control, Instrumentation, and Automation (ICCA)*, 2016, Qazvin.

OLIVEIRA, Fagner A.; NOBRE, Cristiane N.; ZÁRATE Luis E. *Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index: Case study of PETR4, Petrobras, Brazil*. *Expert Systems with Applications*, v. 40, 2013, 7596-7606. Disponível em: < <https://doi.org/10.1016/j.eswa.2013.06.071>>. Acesso: 28/06/2017.

OLIVEIRA, Fagner Andrade de *et al.* *The use of artificial neural networks in the analysis and prediction of stock prices*. In: *IEEE International Conference on Systems, Man, and Cybernetics*, 2011, Anchorage.

PALIT, Ajoy K.; POPOVIC, Dobrivoje. *Computacional Intelligence in Time Series Forecasting: Theory and Engineering Applications*. 1. ed. London: Springer. 2005. 372p.

PASQUOTTO, Jorge Luis Durgante. **Previsão de Séries Temporais no Varejo Brasileiro: Uma Investigação Comparativa da Aplicação de Redes Neurais Recorrentes de Elman**. 2010. 191f. Dissertação (Mestre em Administração) – Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

POMMERANZENBAUM, Igor Ramalho. **Redes Neurais Artificiais na Predição das Principais Séries do índice Ibovespa e suas Aplicações em Sistemas Automatizados de Negociação**. 2014. 114f. Dissertação (Mestrado em Engenharia Elétrica) – Instituto Luiz Coimbra de Pós-graduação e Pesquisa de Engenharia (COPPE), Universidade Federal do Rio de Janeiro, Rio de Janeiro.

RAO, A. *et al.* *Survey: Stock Market Prediction Using Statistical Computational Methodologies and Artificial Neural Networks*. In: *International Research Journal of Engineering and Technology (IRJET)*, 2015, India.

RODRIGUES, Márcio de Menezes. **Otimizando a Previsão de Cheias Sazonais para o Rio Negro Utilizando Redes Neurais de Propagação Direta**. 2015. 74f. Dissertação

(Mestrado em Engenharia Elétrica) – Faculdade de Tecnologia, Universidade Federal do Amazonas, Manaus.

RODRIGUES, Marcio de Menezes; FILHO, Cícero F. Costa; COSTA, Marly G. F. ***Comparing Neural Networks and Pseudo-Inverse Matrix to Flood Forecasting of the Amazon River***. In: *European Simulation and Modelling Conference*, 29, 2015, Leicester.

RUGGIERO, Márcia A. Gomes; LOPES, Vera Lúcia da Rocha. **Cálculo Numérico: Aspectos Teóricos e Computacionais**. 2. ed. São Paulo: Pearson. 1996. 422p.

SANTOS, Daiane Sampaio. **Predição de Mínimos e Máximos Locais para Investimento em Bolsa de Valores Utilizando Aprendizado de Máquina**. 2014. 78f. Dissertação (Mestrado em Ciência da Computação) – Faculdade de Computação, Universidade Federal de Mato Grosso do Sul, Campo Grande.

SOUZA, Beatriz. **As dez maiores bolsas do mundo em capitalização de mercado, 2016**. Disponível em: < <http://exame.abril.com.br/mercados/as-10-maiores-bolsas-do-mundo-em-capitalizacao-de-mercado/> >. Acesso em: 21/06/2017.

SOUZA, Diego Falcão de. **Modelos Composicionais: Análise e Aplicação em Previsões no Mercado de Ações**. 2017. 44f. Dissertação (Mestrado em Informática) – Universidade Federal do Amazonas, Manaus.

TERMUTAS, F.; GUNTURKUN, R.; YUMUSAK, N.; TERMUTAS, H. **Harmonic detection using feed forward and recurrent neural networks for active filters**. *Electric Power Systems Research*. v. 72, 2004, 33-40. Disponível em: < <https://doi.org/10.1016/j.epsr.2004.02.005> >. Acesso: 11/09/2017.

XIONG, Tao; BAO, Yukun; HU, Zhongyi. **Beyond one-step-ahead forecasting: Evaluating of alternative multi-step-ahead forecasting models for crude oil prices**. *Energy Economic*, v. 40, 2013, 305-415. Disponível em: < <https://doi.org/10.1016/j.eneco.2013.07.028> >. Acesso: 28/06/2017.

CHANG, Pei-Chann; WU, Jheng-Long; YU, Liang-Chih. **An intelligent stock trading system using comprehensive features**. *Applied Soft Computing*, v. 23, 2014, 39-50. Disponível em: < <http://dx.doi.org/10.1016/j.asoc.2014.06.010> >. Acesso: 03/01/2019.

YOO, Paul D.; KIM, Maria H.; JAN, Tony. **Machine learning techniques and use of event information for stock market prediction: A survey and evaluation**. In: *Computational intelligence for modelling, control and automation and international conference on intelligent agents, web technologies and internet commerce*, 2005, 835–841.

ZHU, Bangzhu; WEI, Yiming. **Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology**. *Omega*. v. 41, 2013, 517-524. Disponível em: < <https://doi.org/10.1016/j.omega.2012.06.005> >. Acesso: 28/06/2017.



## 8. Anexos

### 8.1. Código para avaliação e escolha dos parâmetros $N$ do $IMM_N$ , o limiar $\epsilon$ , o grau de alocação por operação $\theta$ e o período $\tau$

```

close all
clear all
clc
clear

% Este código visa calcular e plotar o indicador a performance do
% sistema de negociação ainda sem a rede neural.
% A performance é realizada com a seguinte variação:
% IMMN=4,8,12;
% Theta = 30, 60, 90;
% eps = -0,15e6;
% eps = -0,20e6.

load dados1
lim=220; % quantidade de dados para plotagem

IBOVn=IBOVn(1:lim);
t=1:lim;

%parâmetros
N = [4 8 12];
iN=length(N);
eps = [-0.2*10^6 -0.15*10^6];
ieps=length(eps);
theta = [0.3 0.6 0.9 1];
itheta=length(theta);
dorm=2;
rf=0.5/100;
cont=1;

perf = zeros(10,iN*ieps*itheta);
% guarda os parâmetros de performance
% 1 - N; 2 - eps; 3 - theta; 4 - cres total; 5 - cresc 2012 dias;
% 6 - cresc 2011 dias; 7 - cres 2010 dias; 8 - n venda; 9 - n compra;

for jN=1:iN

    indicador=zeros(3,lim);

    for n=N(jN):lim+1-N(jN)

        aux1=polyfit(t(n+1-N(jN):n),IBOVn(n+1-N(jN):n)',1);
        indicador(1,n)=aux1(1);
    
```

```

aux2=polyfit(t(n:n-1+N(jN)),IBOVn(n:n-1+N(jN))',1)
indicador(2,n)=aux2(1);
end
indicador(3,:)=indicador(1,:).*indicador(2,:);

for jeps=1:ieps

    for jtheta=1:itheta
        CapRF=zeros(1,lim);
        CapRFc=zeros(1,lim);
        CapRV=zeros(1,lim);
        CapT=zeros(1,lim);
        Qa=zeros(1,lim);

        CapRF(1:N(jN))=100*ones(1,N(jN));
        CapRFc(1:N(jN))=100*ones(1,N(jN));
        CapT=CapRF+CapRV;
        oper=0;
        iC=0;
        iV=0;
        compra=[0 0];
        venda=[0 0];

        for n=N(jN):lim+1-N(jN)

            CapRFc(n)=CapRFc(n-1)*(1+rf/4);
            Qa(n)=Qa(n-1);
            CapRV(n)=Qa(n)*IBOVn(n);
            CapRF(n)=CapRF(n-1)*(1+rf/4);

            if oper>0
                oper=oper-1;
            end

            % compra
            if indicador(1,n) < 0 && indicador(3,n) < eps(jeps) && oper==0 &&
~(CapRV(n)/(CapRV(n)+CapRF(n)) > 0.99)
                oper=dorm;
                Qa(n)=Qa(n)+(CapRF(n)*theta(jtheta)*0.998-1/100)/IBOVn(n);
                CapRV(n)=Qa(n)*IBOVn(n);
                iC=iC+1;
                CapRF(n)=CapRF(n)-CapRF(n)*theta(jtheta);
                compra=[compra ; n IBOVn(n)*100/IBOVn(1)];
            end

            % venda
            if indicador(1,n) > 0 && indicador(3,n) < eps(jeps) && oper==0 &&
~(CapRV(n)/(CapRV(n)+CapRF(n)) < 0.01)
                oper=dorm;
                Qa(n)=Qa(n)-CapRV(n)*theta(jtheta)/IBOVn(n);
                CapRF(n)=CapRF(n)+CapRV(n)*theta(jtheta)*0.998-1/100;
                CapRV(n)=Qa(n)*IBOVn(n);
                iV=iV+1;
                venda=[venda ; n IBOVn(n)*100/IBOVn(1)];
            end

            CapT(n)=CapRF(n)+CapRV(n);
        end
    end
end

```

```

end
perf (1,cont) = N (jN);
perf (2,cont) = eps(jeps);
perf (3,cont) = theta(jtheta);
perf (4,cont) = iC;
perf (5,cont) = iV;
perf (6,cont) = (CapT(52)/CapT(1)-1)*100; %2010
perf (7,cont) = (CapT(104)/CapT(52)-1)*100; %2011
perf (8,cont) = (CapT(156)/CapT(104)-1)*100; %2012
perf (9,cont) = (CapT(209)/CapT(156)-1)*100; %2013
perf (10,cont) = (CapT(lim+1-N(jN))/100-1)*100;% total
cont=cont+1;

if jN==1 && jeps==2 && jtheta==4
    CapTg=CapT;
    CapRVg=CapRV;
    CapRFg=CapRF;
    CapRFcg=CapRFc;
    comprag=compra;
    vendag=venda;
    jNg=jN;
end
end
end
end

figure(1)
plot(t, CapTg, t, CapRVg, t, CapRFg, t, CapRFcg, t,
IBOVn*100/IBOVn(1),comprag(:,1),comprag(:,2),'go',vendag(:,1),vendag(:,2),'ko');
Title('Capital');
Legend('Total','RV','RF','RFc','RVc','compra','venda');
grid on

figure(2)
plot(t, CapTg, t, CapRVg, t, CapRFg,t,
IBOVn*100/IBOVn(1),comprag(:,1),comprag(:,2),'go',vendag(:,1),vendag(:,2),'ko');
Title('Capital');
Legend('Total','Risco','Renda Fixa','VarIbov','Compra','Venda');
grid on

figure(3)
plot(t, CapTg,t,
IBOVn*100/IBOVn(1),comprag(:,1),comprag(:,2),'go',vendag(:,1),vendag(:,2),'ko');
Title('Capital');
Legend('Total','VarIbov','Compra','Venda');
grid on

figure(4)
plot(1:cont-1, perf (4,:),'*');
Legend('performance');
grid on

```

## 8.2. Código do sistema de negociação com as RNA's embutidas

```

close all
clear all
clc
clear

% Este código visa calcular e plotar o indicador a performance do
% sistema de negociação com a rede neural.
% CUIDADO ----> A performance é realizada: REDES Y.2.1 (7, SME, 300 pontos)
N=4;
theta = 0.60;
epsi = -0.15e6;

load netibovY21
% netibov121 % 1 (02/04/2007) até 300 (26/12/2012) aplicação 301 ao 352
% netibov221 % 53 (31/03/2008) até 352 (23/12/2013) aplicação 353 ao 404
% netibov321 % 105 (30/03/2009) até 404 (22/12/2014) aplicação 405 ao 456
% netibov421 % 157x1 (29/03/2010) até 456x2 (21/12/2015) aplicação 457 ao 508
% netibov521 % 209x3 (28/03/2011) até 508x4 (19/12/2016) aplicação 509 ao 524(final)
load dados2 % contém a série do IBOV
intervalosT=[1 53 105 157 209;300 352 404 456 508];
intervalosA=[301 353 405 457 509;352 404 456 508 524];
indicador=zeros(3,length(BOVn));
tempo=1:length(BOVn);
BOVnp=zeros(length(BOVn),1);

%% Aplicação de estimativas e cálculo do indicador
for intervalo=1:5

    % escolhendo as redes por intervalo
    switch intervalo
        case 1
            netibov=netibov121;
        case 2
            netibov=netibov221;
        case 3
            netibov=netibov221;
        case 4
            netibov=netibov421;
        case 5
            netibov=netibov521;
    end
    % variáveis utilizadas
    t=(intervalosA(1,intervalo)-40):intervalosA(2,intervalo);
    BOVr=BOVn(t);
    % regularização de -1 a 1
    BOVnr=2*(BOVr-ones(length(BOVr),1)*min(BOVr))/(max(BOVr)-min(BOVr))-
    ones(length(BOVr),1);
    for n=1:length(t)-40

        % calculando os multisteps para 4 pontos futuros
        Yp=0;
        for j=1:4

```

```

    if j==1
        yini = con2seq(IBOVnr(n:n+39));
        yv = con2seq(0); %IBOVnr(n+40)
    else
        yini = con2seq([IBOVnr(n+j-1:n+39); Yp]);
        yv = con2seq(0); %IBOVnr(n+40)
    end
    [Xs,Xi,Ai] = preparets(netibov,{},{},[yini yv]); %% CUIDADO AQUI DEFINE A
REDE DO INTERVALO
    predict = netibov(Xs,Xi,Ai); %% CUIDADO AQUI DEFINE A REDE DO
INTERVALO
    Yp(j) = cell2mat(predict);
end
% Desregulariza predições
Y = (ones(1,N)+Yp)*(max(IBOVr)-min(IBOVr))/2+min(IBOVr)*ones(1,N);
IBOVnp(intervalosA(1,intervalo)+n-1)=Y(1);

% Cálculo do indicador em cima do IBOV e suas predições não regularizadas
aux1=polyfit(1:4,[IBOVn(intervalosA(1,intervalo)-N+1+n-1:intervalosA(1,intervalo)-
1+n-1)' Y(1)],1);
indicador(1,intervalosA(1,intervalo)+n-1)=aux1(1);
aux2=polyfit(4:7,Y,1);
indicador(2,intervalosA(1,intervalo)+n-1)=aux2(1);
indicador(3,intervalosA(1,intervalo)+n-1)=aux1(1)*aux2(1);

end
end

figure(1)
plot(tempo,IBOVn,'-b',tempo,IBOVnp,'--r');
title('Predições Realizadas');
legend('IBOV real','IBOV previsto');

figure(2)
plot(tempo,indicador(3,:),'b',tempo,epsi*ones(1,length(tempo)),'--k');
title('Indicador IMM4');
ylabel('Limiar');

%% Aplicação de compra e venda

% parâmetros

dorm=2;
rf=0.5/100;
cont=1;

perf = zeros(10,1);
% guarda os parâmetros de performance
% 1 - N; 2 - eps; 3 - theta; 4 - cres total; 5 - cresc 2012 dias;
% 6 - cresc 2011 dias; 7 - cres 2010 dias; 8 - n venda; 9 - n compra;

CapRF=zeros(1,length(tempo));
CapRFc=zeros(1,length(tempo));

```

```

CapRV=zeros(1,length(tempo));
CapT=zeros(1,length(tempo));
Qa=zeros(1,length(tempo));
CapRF(1:intervalosA(1,1)-1)=100*ones(1,intervalosA(1,1)-1);
CapRFc(1:intervalosA(1,1)-1)=100*ones(1,intervalosA(1,1)-1);
CapT=CapRF+CapRV;
oper=0;
iC=0;
iV=0;
compra=[0 0];
venda=[0 0];

for n=intervalosA(1,1):intervalosA(2,5)

    CapRFc(n)=CapRFc(n-1)*(1+rf/4);
    Qa(n)=Qa(n-1);
    CapRV(n)=Qa(n)*IBOVn(n);
    CapRF(n)=CapRF(n-1)*(1+rf/4);

    if oper>0
        oper=oper-1;
    end
    %compra
    if indicador(1,n) < 0 && indicador(3,n)< epsi && oper==0 &&
~(CapRV(n)/(CapRV(n)+CapRF(n)) > 0.99)
        oper=dorm;
        Qa(n)=Qa(n)+(CapRF(n)*theta*0.998-1/100)/IBOVn(n);
        CapRV(n)=Qa(n)*IBOVn(n);
        iC=iC+1;
        CapRF(n)=CapRF(n)-CapRF(n)*theta;
        compra=[compra ; n IBOVn(n)*100/IBOVn(1)];
    end
    %venda
    if indicador(1,n) > 0 && indicador(3,n) < epsi && oper==0 &&
~(CapRV(n)/(CapRV(n)+CapRF(n)) < 0.01)
        oper=dorm;
        Qa(n)=Qa(n)-CapRV(n)*theta/IBOVn(n);
        CapRF(n)=CapRF(n)+CapRV(n)*theta*0.998-1/100;
        CapRV(n)=Qa(n)*IBOVn(n);
        iV=iV+1;
        venda=[venda ; n IBOVn(n)*100/IBOVn(1)];
    end
    CapT(n)=CapRF(n)+CapRV(n);
end

perf (1) = N;
perf (2) = epsi;
perf (3) = theta;
perf (4) = iC;
perf (5) = iV;
perf (6) = (CapT(353)/CapT(300)-1)*100; %2013
perf (7) = (CapT(405)/CapT(353)-1)*100; %2014
perf (8) = (CapT(457)/CapT(405)-1)*100; %2015
perf (9) = (CapT(509)/CapT(457)-1)*100; %2016
perf (10) = (CapT(524)/CapT(509)-1)*100; %2017** até 10/04

```

```

perf (11) = (CapT(length(tempo))/100-1)*100;% total

% figure(1)
% plot(t, CapTg, t, CapRVg, t, CapRFg, t, CapRFcg, t,
IBOVn*100/IBOVn(1),comprag(:,1),comprag(:,2),'go',vendag(:,1),vendag(:,2),'ko');
% Title('Capital');
% Legend('Total','RV','RF','RFc','RVc','compra','venda');
% grid on
%
% figure(2)
% plot(t, CapTg, t, CapRVg, t, CapRFg,t,
IBOVn*100/IBOVn(1),comprag(:,1),comprag(:,2),'go',vendag(:,1),vendag(:,2),'ko');
% Title('Capital');
% Legend('Total','Risco','Renda Fixa','VarIbov','Compra','Venda');
% grid on
%

figure(3)
plot(tempo, CapT,tempo,
IBOVn*100/IBOVn(1),compra(:,1),compra(:,2),'go',venda(:,1),venda(:,2),'ko');
title('Capital');
legend('Total','VarIbov','Compra','Venda');
grid on

% figure(4)
% plot(1:cont-1, perf (4,:),'*');
% Legend('performance');
% grid on

```