

PREVISÃO DO IBOVESPA UTILIZANDO MODELOS HÍBRIDOS

Pedro Constant de Almeida dos Santos Braga

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Aprovada por:

Prof. Luiz Pereira Caloba, Dr. Ing.

Prof. Alexandre Pinto Alves da Silva, Ph. D.

Prof. Marcelo Cunha Medeiros, D. Sc.

Dr. Romeu Ricardo da Silva, D. Sc.

RIO DE JANEIRO, RJ - BRASIL

ABRIL DE 2006

BRAGA, PEDRO CONSTANT DE ALMEIDA DOS
SANTOS

Previsão do IBOVESPA Utilizando Modelos
Híbridos [Rio de Janeiro] 2006

XVII, 194 p. 29,7 cm (COPPE/UFRJ, M. Sc.
Engenharia Elétrica, 2006)

Dissertação - Universidade Federal do Rio de
Janeiro, COPPE

1. Previsão do IBOVESPA
2. Séries Temporais
3. Redes Neurais

I. COPPE/UFRJ II. Título (série)

Àqueles que me incentivam a sempre me superar

AGRADECIMENTOS

Quando cheguei ao término deste estudo, notei quão importante foi o apoio de diversas pessoas durante todo o seu desenrolar. Muitas dessas ocasiões passaram-se despercebidas para mim, porém ao olhar para trás vejo todo o caminho que percorri e que por diversas vezes havia alguém ao meu lado lutando pelos meus sonhos como se fossem seus.

Gostaria de agradecer aos meus pais, Tânia e Roque, por sempre terem me incentivado e apoiado em todos os aspectos da minha vida, investindo em mim tudo que estive ao seu alcance apenas por confiarem cegamente em meu caráter e senso de responsabilidade.

Com não menos importância, devo agradecer ao meu orientador, Professor Caloba, por ter confiado em mim e me ajudado em todos os momentos desde o primeiro dia em que começamos esta pesquisa, sempre com muita boa vontade e dedicação em face ao desafio proposto.

Duas amigas de longa data – Vanessa e Aniela – não poderiam ser esquecidas nestes agradecimentos, pela eficiência e presteza em me auxiliar com dados da área econômica, contribuindo com extrema dedicação na busca por respostas a meus questionamentos e pelo fato de haverem me apresentado a dois amigos experientes neste campo, Daniel e Eduardo.

Ao mais que amigo, Pablo, sou eternamente grato pelo apoio integral dedicado a mim para galgar os resultados obtidos. Apoiando-me incondicionalmente em diversos aspectos de minha vida, torcendo e orgulhando-se de cada vitória minha.

Àquela que mais reclamou de minha ausência nos últimos tempos, Maria, sou imensamente grato por todo o amor expressado desde quando éramos apenas dois adolescentes. Acreditando em mim, por vezes, mais do que nela própria.

A minha irmã, Natascha, que apesar de não ter contribuído diretamente na execução desta pesquisa, me permitiu a tranquilidade necessária para a sua conclusão. A esta devo agradecer também pelo carinho por horas quase maternal – ou paternal – em lidar comigo.

Digo muito obrigado aos meus familiares, próximos ou mais distantes, que desde criança estiveram ao meu lado ajudando a construir o adulto que sou hoje. Sem perda de

significância, sou extremamente grato aos meus amigos, por tudo que essa palavra representa para mim e por sempre terem se mostrado merecedores dessa alcunha.

Encerro, portanto, agradecendo a todos que sempre me incentivaram a me superar, acreditando em meu potencial, compreendendo meus defeitos e construindo cada parte do que sou hoje.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M. Sc.)

PREVISÃO DO IBOVESPA UTILIZANDO MODELOS HÍBRIDOS

Pedro Constant de Almeida dos Santos Braga

Abril/2006

Orientador: Luiz Pereira Caloba

Programa: Engenharia Elétrica

A previsão de indicadores econômicos de mercados financeiros completos mostra-se uma tarefa bastante árdua. Entretanto, alguns mercados emergentes possuem características particulares, tendendo a sofrer influência externa de outros mercados e de alguns grandes investidores. Esta pesquisa consiste em um sistema desenvolvido com o intuito de realizar a previsão da cotação do fechamento do IBOVESPA, analisando a correlação de vinte séries econômicas com a série objetivo e utilizando estudos estatísticos, conceitos de séries temporais e redes neurais.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M. Sc.)

IBOVESPA FORESCANTING USING HYBRID MODELS

Pedro Constant de Almeida dos Santos Braga

April/2006

Advisor: Luiz Pereira Caloba

Department: Electric Engineering

An eventual forecast in complete financial markets may reveal itself to be a remarkably complex task. However, due to rather particular traces, some emerging markets are subject to suffer great external influence either from other markets or investors. The present work consists in the development of a system with the purpose of forecasting the closing price of the IBOVESPA. It is the result of a thorough analysis on the correlation between twenty economic series and the target series, using statistic studies, concepts of temporal series and neural networks.

ÍNDICE

I.	Introdução.....	1
II.	Mercado Financeiro.....	3
II.1.	BOVESPA.....	3
II.1.1.	Histórico.....	3
II.1.2.	IBOVESPA.....	5
II.2.	Previsão de Mercado Financeiro.....	7
II.3.	Indicadores Econômicos.....	8
II.4.	Indicadores Calculados.....	23
III.	Séries Temporais e Redes Neurais.....	26
III.1.	Redes Neurais.....	26
III.2.	Tendência.....	28
III.3.	Sazonalidade.....	28
III.4.	Ciclos Senoidais.....	28
IV.	Pré-Processamento.....	29
IV.1.	Séries de Retornos.....	29
IV.2.	Outliers.....	39
IV.3.	Distribuição dos Indicadores.....	53
IV.4.	Autocorrelação e Correlação Cruzada.....	56
IV.5.	Seleção de Variáveis.....	59
V.	Estudo da Série do IBOVESPA.....	62
V.1.	Rede Neural.....	62
V.2.	Relevância.....	65
V.3.	Resultados.....	67
V.3.1.	Cenário I.....	68
V.3.2.	Cenário II.....	75
V.4.	Aplicação.....	80
V.5.	Métodos Alternativos.....	82
V.5.1.	Critérios de Otimização.....	82
V.5.2.	Módulo e Variância Predita do IBOVESPA como Parâmetros de Entrada da Rede.....	83
V.5.3.	Componentes Principais.....	83

V.5.4. Fator de Correção de Erros de Polaridade do Processo de Treinamento para Grandes Variações.....	84
V.5.5. Rede Especialista.....	85
V.5.6. Votação das Redes Neurais Geradas.....	85
VI. Conclusão.....	87
VII. Referências Bibliográficas.....	88
Apêndice I – Espectro em Frequência.....	92
Apêndice II – Resultados Gráficos dos Parâmetros de Distribuição das Séries de Retornos.....	104
Apêndice III – Resultados Gráficos das Correlações das Séries de Retornos com a Série Objetivo.....	129
Apêndice IV – Modelo GARCH.....	176
Glossário.....	194

ÍNDICE DE FIGURAS

Figura 1: Série de Cotações do Fechamento do IBOVEPA.....	9
Figura 2: Série de Cotações da Abertura do IBOVEPA.....	9
Figura 3: Série de Cotações do Mínimo do IBOVEPA.....	10
Figura 4: Série de Cotações do Máximo do IBOVEPA.....	10
Figura 5: Série de Cotações do Fechamento do Índice NASDAQ.....	11
Figura 6: Série de Cotações do Fechamento do Índice C-Bond Brasil.....	12
Figura 7: Série de Cotações do Fechamento do Índice Dow Jones.....	12
Figura 8: Série de Cotações do Fechamento do Índice CDI.....	13
Figura 9: Série de Cotações do Fechamento do Índice Merval.....	14
Figura 10: Série de Cotações do Fechamento do Índice FTSE.....	15
Figura 11: Série de Cotações do Fechamento do Índice PTAX.....	16
Figura 12: Série de Cotações do Fechamento do Índice S&P.....	17
Figura 13: Série de Cotações do Fechamento do IBX.....	18
Figura 14: Série de Cotações do Fechamento do DIxPre180.....	19
Figura 15: Série de Cotações do Fechamento do DIxPre360.....	20
Figura 16: Série de Cotações do Fechamento do DIxPre540.....	20
Figura 17: Série de Cotações do Fechamento do DIxPre720.....	21
Figura 18: Série de Cotações do Fechamento do Euro.....	21
Figura 19: Série de Cotações do Fechamento do Yen.....	22
Figura 20: Série de Cotações do Fechamento do Dólar.....	22
Figura 21: Série de Retornos da Variação Diária do IBOVESPA.....	23
Figura 22: Série de Retornos da Variação Noturna do IBOVESPA.....	24
Figura 23: Série de Retornos da Variação Máxima do IBOVESPA.....	25
Figura 24: Rede Neural <i>feedforward</i>	26
Figura 25: Série de Retornos do Fechamento IBOVESPA.....	29
Figura 26: Série de Retornos da Abertura IBOVESPA.....	30
Figura 27: Série de Retornos do Mínimo IBOVESPA.....	30
Figura 28: Série de Retornos do Máximo IBOVESPA.....	31
Figura 29: Série de Retornos do Fechamento NASDAQ.....	31
Figura 30: Série de Retornos do Fechamento BRACBOND.....	32
Figura 31: Série de Retornos do Fechamento Dow Jones.....	32

Figura 32: Série de Retornos do Fechamento CDI.....	33
Figura 33: Série de Retornos do Fechamento Merval.....	33
Figura 34: Série de Retornos do Fechamento FTSE100.....	34
Figura 35: Série de Retornos do Fechamento PTAX.....	34
Figura 36: Série de Retornos do Fechamento S&P.....	35
Figura 37: Série de Retornos do Fechamento IBX.....	35
Figura 38: Série de Retornos do Fechamento DIXPre180.....	36
Figura 39: Série de Retornos do Fechamento DIXPre360.....	36
Figura 40: Série de Retornos do Fechamento DIXPre540.....	37
Figura 41: Série de Retornos do Fechamento DIXPre720.....	37
Figura 42: Série de Retornos do Fechamento Euro.....	38
Figura 43: Série de Retornos do Fechamento Yen.....	38
Figura 44: Série de Retornos do Fechamento Dólar.....	39
Figura 45: <i>Atenuação de Outliers</i> Fechamento IBOVESPA.....	42
Figura 46: <i>Atenuação de Outliers</i> Abertura IBOVESPA.....	42
Figura 47: <i>Atenuação de Outliers</i> Mínimo IBOVESPA.....	43
Figura 48: <i>Atenuação de Outliers</i> Máximo IBOVESPA.....	43
Figura 49: <i>Atenuação de Outliers</i> Fechamento NASDAQ.....	44
Figura 50: <i>Atenuação de Outliers</i> Fechamento BRACBOND.....	44
Figura 51: <i>Atenuação de Outliers</i> Fechamento Dow Jones.....	45
Figura 52: <i>Atenuação de Outliers</i> Fechamento CDI.....	45
Figura 53: <i>Atenuação de Outliers</i> Fechamento Merval.....	46
Figura 54: <i>Atenuação de Outliers</i> Fechamento FTSE100.....	46
Figura 55: <i>Atenuação de Outliers</i> Fechamento PTAX.....	47
Figura 56: <i>Atenuação de Outliers</i> Fechamento S&P.....	47
Figura 57: <i>Atenuação de Outliers</i> Fechamento IBX.....	48
Figura 58: <i>Atenuação de Outliers</i> Fechamento DIXPre180.....	48
Figura 59: <i>Atenuação de Outliers</i> Fechamento DIXPre360.....	49
Figura 60: <i>Atenuação de Outliers</i> Fechamento DIXPre540.....	49
Figura 61: <i>Atenuação de Outliers</i> Fechamento DIXPre720.....	50
Figura 62: <i>Atenuação de Outliers</i> Fechamento Euro.....	50
Figura 63: <i>Atenuação de Outliers</i> Fechamento Yen.....	51
Figura 64: <i>Atenuação de Outliers</i> Fechamento Dólar.....	51
Figura 65: <i>Atenuação de Outliers</i> Variação Diária do IBOVESPA.....	52

Figura 66: Atenuação de <i>Outliers</i> Variação Noturna do IBOVESPA.....	52
Figura 67: Atenuação de <i>Outliers</i> Variação Máxima do IBOVESPA.....	53
Figura 68: Correlação Fechamento IBOVESPA em Sentido Direto do Período Completo.....	58
Figura 69: Correlação Fechamento IBOVESPA em Sentido Direto de Três Anos.....	59
Figura 70: Cenário I – Conjunto Geral – % Acerto Sinal por Faixa de Previsão.	72
Figura 71: Cenário I – Conjunto Geral – % Acerto Sinal por Faixa de Real.....	72
Figura 72: Cenário I – Conjunto Aplicação – % Acerto Sinal por Faixa de Previsão....	73
Figura 73: Cenário I – Conjunto Aplicação – % Acerto Sinal por Faixa de Real.	73
Figura 74: Cenário I – Conjunto Geral – Saída Real x Prevista.	74
Figura 75: Cenário I – Conjunto Aplicação – Saída Real x Prevista.....	74
Figura 76: Cenário II – Conjunto Geral – % Acerto Sinal por Faixa de Previsão.....	77
Figura 77: Cenário II – Conjunto Geral – % Acerto Sinal por Faixa de Real.....	78
Figura 78: Cenário II – Conjunto Aplicação – % Acerto Sinal por Faixa de Previsão..	78
Figura 79: Cenário II – Conjunto Aplicação – % Acerto Sinal por Faixa de Real.	79
Figura 80: Cenário II – Conjunto Geral – Saída Real x Prevista.....	79
Figura 81: Cenário II – Conjunto Aplicação – Saída Real x Prevista.	80
Figura 82: Retornos das Aplicações por Taxa de Corretagem.....	82
Figura 83: Componentes em Frequência Fechamento IBOVESPA	92
Figura 84: Componentes em Frequência Abertura IBOVESPA.....	93
Figura 85: Componentes em Frequência Mínimo IBOVESPA	93
Figura 86: Componentes em Frequência Máximo IBOVESPA.....	94
Figura 87: Componentes em Frequência Fechamento NASDAQ	94
Figura 88: Componentes em Frequência Fechamento BRACBOND.....	95
Figura 89: Componentes em Frequência Fechamento Dow Jones	95
Figura 90: Componentes em Frequência Fechamento CDI.....	96
Figura 91: Componentes em Frequência Fechamento MERVAL	96
Figura 92: Componentes em Frequência Fechamento FTSE100.....	97
Figura 93: Componentes em Frequência Fechamento PTAX.....	97
Figura 94: Componentes em Frequência Fechamento S&P.....	98
Figura 95: Componentes em Frequência Fechamento BX.....	98
Figura 96: Componentes em Frequência Fechamento DIXPRE180	99
Figura 97: Componentes em Frequência Fechamento DIXPRE360	99
Figura 98: Componentes em Frequência Fechamento DIXPRE540	100

Figura 99: Componentes em Frequência Fechamento DIXPRE720	100
Figura 100: Componentes em Frequência Fechamento Euro.....	101
Figura 101: Componentes em Frequência Fechamento Yen.....	101
Figura 102: Componentes em Frequência Fechamento Dólar	102
Figura 103: Componentes em Frequência Variação Diária IBOVESPA	102
Figura 104: Componentes em Frequência Variação Noturna IBOVESPA.....	103
Figura 105: Componentes em Frequência Variação Máxima IBOVESPA.....	103
Figura 106: Distribuição Fechamento IBOVESPA	105
Figura 107: Distribuição Abertura IBOVESPA.....	107
Figura 108: Distribuição Mínimo IBOVESPA	108
Figura 109: Distribuição Máximo IBOVESPA.....	109
Figura 110: Distribuição Fechamento NASDAQ	110
Figura 111: Distribuição Fechamento BRACBOND	111
Figura 112: Distribuição Fechamento Dow Jones	112
Figura 113: Distribuição Fechamento CDI	113
Figura 114: Distribuição Fechamento Merval.....	114
Figura 115: Distribuição Fechamento FTSE100.....	115
Figura 116: Distribuição Fechamento PTAX.....	116
Figura 117: Distribuição Fechamento S&P.....	117
Figura 118: Distribuição Fechamento IBX	118
Figura 119: Distribuição Fechamento DIXPRE180	119
Figura 120: Distribuição Fechamento DIXPRE360	120
Figura 121: Distribuição Fechamento DIXPRE540	121
Figura 122: Distribuição Fechamento DIXPRE720	122
Figura 123: Distribuição Fechamento Euro.....	123
Figura 124: Distribuição Fechamento <i>Yen</i>	124
Figura 125: Distribuição Fechamento Dólar	125
Figura 126: Distribuição Variação Diária IBOVESPA	126
Figura 127: Distribuição Variação Noturna IBOVESPA.....	127
Figura 128: Distribuição Variação Máxima IBOVESPA.....	128
Figura 129: Correlação Fechamento IBOVESPA em Sentido Direto.....	130
Figura 130: Correlação Fechamento IBOVESPA em Sentido Inverso.....	131
Figura 131: Correlação Abertura IBOVESPA em Sentido Direto.....	132
Figura 132: Correlação Abertura IBOVESPA em Sentido Inverso.....	133

Figura 135: Correlação Máximo IBOVESPA em Sentido Direto.....	136
Figura 136: Correlação Máximo IBOVESPA em Sentido Inverso.....	137
Figura 137: Correlação Fechamento NASDAQ em Sentido Direto.....	138
Figura 138: Correlação Fechamento NASDAQ em Sentido Inverso.....	139
Figura 139: Correlação Fechamento Bracbond em Sentido Direto.....	140
Figura 140: Correlação Fechamento Bracbond em Sentido Inverso.....	141
Figura 141: Correlação Fechamento Dow Jones em Sentido Direto.....	142
Figura 142: Correlação Fechamento Dow Jones em Sentido Inverso.....	143
Figura 143: Correlação Fechamento CDI em Sentido Direto.....	144
Figura 144: Correlação Fechamento CDI em Sentido Inverso.....	145
Figura 145: Correlação Fechamento Merval em Sentido Direto.....	146
Figura 146: Correlação Fechamento Merval em Sentido Inverso.....	147
Figura 147: Correlação Fechamento FTSE em Sentido Direto.....	148
Figura 148: Correlação Fechamento FTSE em Sentido Inverso.....	149
Figura 149: Correlação Fechamento PTAX em Sentido Direto.....	150
Figura 150: Correlação Fechamento PTAX em Sentido Inverso.....	151
Figura 151: Correlação Fechamento S&P em Sentido Direto.....	152
Figura 152: Correlação Fechamento S&P em Sentido Inverso.....	153
Figura 153: Correlação Fechamento IBX em Sentido Direto.....	154
Figura 154: Correlação Fechamento IBX em Sentido Inverso.....	155
Figura 156: Correlação Fechamento DIxPre180 em Sentido Inverso.....	157
Figura 157: Correlação Fechamento DIxPre360 em Sentido Direto.....	158
Figura 159: Correlação Fechamento DIxPre540 em Sentido Direto.....	160
Figura 160: Correlação Fechamento DIxPre540 em Sentido Inverso.....	161
Figura 161: Correlação Fechamento DIxPre720 em Sentido Direto.....	162
Figura 162: Correlação Fechamento DIxPre720 em Sentido Inverso.....	163
Figura 163: Correlação Fechamento Euro em Sentido Direto.....	164
Figura 164: Correlação Fechamento Euro em Sentido Inverso.....	165
Figura 165: Correlação Fechamento Yen em Sentido Direto.....	166
Figura 166: Correlação Fechamento Yen em Sentido Inverso.....	167
Figura 167: Correlação Fechamento Dólar em Sentido Direto.....	168
Figura 169: Correlação Variação Diária IBOVESPA em Sentido Direto.....	170
Figura 170: Correlação Variação Diária IBOVESPA em Sentido Inverso.....	171
Figura 171: Correlação Variação Noturna IBOVESPA em Sentido Direto.....	172

Figura 172: Correlação Variação Noturna IBOVESPA em Sentido Inverso.....	173
Figura 173: Correlação Variação Máxima IBOVESPA em Sentido Direto.	174
Figura 174: Correlação Variação Máxima IBOVESPA em Sentido Inverso.	175
Figura 175: Autocorrelação Fechamento IBOVESPA	177
Figura 176: Autocorrelação Parcial Fechamento IBOVESPA.....	177
Figura 177: Autocorrelação Quadrado do Fechamento IBOVESPA.....	178
Figura 178: Conjunto de pré-processamento descrito pelo modelo GARCH(1, 1).....	184
Figura 179: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo GACH(1, 1).....	185
Figura 180: Resposta em frequência do conjunto de pós processamento para o modelo GARCH(1, 1)	185
Figura 181: Resposta em frequência do filtro utilizado para filtragem no modelo GARCH(1, 1)	186
Figura 182: Resposta em frequência dos sinais filtrados no modelo GARCH(1, 1)....	186
Figura 183: Conjunto de pós-processamento filtrado predito pelo modelo GARCH(1, 1)	187
Figura 184: Conjunto de pré-processamento descrito pelo modelo GJR(1, 1)	188
Figura 185: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo GJR(1, 1).....	188
Figura 186: Resposta em frequência dos sinais filtrados no modelo GJR(1, 1)	189
Figura 187: Conjunto de pós-processamento filtrado predito pelo modelo GJR(1, 1). 189	
Figura 188: Conjunto de pré-processamento descrito pelo modelo EGARCH(1, 1) ...	190
Figura 189: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo EGARCH(1, 1)	191
Figura 190: Resposta em frequência dos sinais filtrados no modelo EGARCH(1, 1)..	191
Figura 191: Conjunto de pós-processamento filtrado predito pelo modelo EGARCH(1, 1).....	192

ÍNDICE DE TABELAS

Tabela 1: Tratamento de <i>Outliers</i> - Indicadores Econômicos.....	41
Tabela 2: Tratamento de <i>Outliers</i> - Indicadores Calculados.....	41
Tabela 3: Parâmetros de Distribuição - Indicadores Econômicos	55
Tabela 4: Parâmetros de Distribuição - Indicadores Calculados.....	56
Tabela 5: Atrasos Considerados para Indicadores Econômicos.....	60
Tabela 6: Atrasos Considerados para Indicadores Calculados.....	61
Tabela 7: Performance da Rede com Distribuições Equalizadas.....	64
Tabela 8: Performance das Redes por Número de Neurônios Camada Intermediária ...	64
Tabela 9: Análise de Relevância	66
Tabela 10: Séries de Retornos Relevantes.....	67
Tabela 11: Cenário I – Performance das Redes em EMQ.....	68
Tabela 12: Cenário I – Performance das Redes em % Acerto Sinal.....	69
Tabela 13: Cenário I – Performance das Redes em Coeficientes de Regressão	69
Tabela 14: Cenário I – % Acerto Sinal por Faixa de Previsão da Saída Rede.....	70
Tabela 15: Cenário I – % Acerto Sinal por Faixa de Real da Saída Rede.....	70
Tabela 16: Cenário I – % Acerto Sinal por Faixa de Previsão do Modelo Ingênuo	71
Tabela 17: Cenário I – % Acerto Sinal por Faixa de Real do Modelo Ingênuo.....	71
Tabela 18: Cenário II – Performance das Redes em EMQ.....	75
Tabela 19: Cenário II – Performance das Redes em % Acerto Sinal	75
Tabela 20: Cenário II – Performance das Redes em Coeficientes de Regressão.....	76
Tabela 21: Cenário II – % Acerto Sinal por Faixa de Previsão da Saída Rede.....	76
Tabela 22: Cenário II – % Acerto Sinal por Faixa de Real da Saída Rede	77
Tabela 23: Retornos das Aplicações por Taxa de Corretagem	81
Tabela 24: Retornos das Aplicações por Taxa de Corretagem para o Modelo Ingênuo	81
Tabela 25: Resultados Comparativos - Módulo e Variância Predita do IBOVESPA	83
Tabela 26: Resultados Comparativos - Componentes Principais.....	84
Tabela 27: Resultados Comparativos - Rede Especialista.....	85
Tabela 28: Resultados Comparativos - Critério de Votação	86
Tabela 29: Níveis de significância resultantes do teste <i>Ljung-Box</i>	179
Tabela 30: Níveis de significância resultantes do teste ARCH.....	179
Tabela 31: Parâmetros do modelo GARCH(1, 1)	184

Tabela 32: Parâmetros do modelo GJR(1, 1)	187
Tabela 33: Parâmetros do modelo EGARCH(1, 1).....	190
Tabela 34: Erro Médio Quadrático dos modelos de variância condicional.....	192

ÍNDICE DE EQUAÇÕES

Equação 1: Variação Diária do IBOVESPA	23
Equação 2: Variação Noturna do IBOVESPA	24
Equação 3: Variação Máxima do IBOVESPA.....	25
Equação 4: Saída dos Neurônios da Camada Intermediária.....	27
Equação 5: Saída da Rede Neural.....	27
Equação 6: Série de Retornos.....	29
Equação 7: Média.....	53
Equação 8: Variância	53
Equação 9: Desvio Padrão.....	54
Equação 10: Assimetria	54
Equação 11: Curtose	54
Equação 12: Coeficiente de Autocorrelação	56
Equação 13: Coeficiente de Correlação Cruzada.....	57
Equação 14: Limite de Significância da Correlação Cruzada.....	58
Equação 15: Coeficiente de Correlação.....	62
Equação 16: Limite de Significância da Autocorrelação.....	176
Equação 17: Modelo ARMAX.....	180
Equação 18: Inovações	180
Equação 19: Modelo GARCH.....	181
Equação 20: Modelo GJR.....	181
Equação 21: Modelo EGARCH	182
Equação 22: Variância Instantânea	183

I. INTRODUÇÃO

A capacidade de prever acontecimentos futuros tem sido a força motriz de muitas pesquisas desenvolvidas pela humanidade, sobretudo no âmbito econômico, onde se revela de crucial importância, razão pela qual vem sendo cada vez mais utilizada.

No que se refere ao Brasil, a possibilidade de previsão do índice da Bolsa de Valores de São Paulo, IBOVESPA, vem aguçando a curiosidade de muitos economistas e pesquisadores, que vêem nesse fato a oportunidade de angariar capital com uma boa margem de segurança.

Essa é a tônica do presente trabalho, desenvolvido com o intuito de atingir de forma eficiente e eficaz os objetivos mencionados. Com esse propósito, analisou-se a influência de diversos indicadores econômicos na cotação do IBOVESPA, submetendo suas séries temporais a transformações e estudos estatísticos, objetivando a aplicação dessas como entradas de uma rede neural cujo resultado é uma estimativa da variação da cotação da série objetivo em $D+1$ ¹. Até o momento, poucos trabalhos abordando o assunto foram publicados no Brasil e muito ainda pode ser desenvolvido nesta área.

No primeiro capítulo do corpo deste documento, é feita uma breve descrição do mercado financeiro, dando uma visão do panorama econômico e apresentando os indicadores econômicos considerados nesta pesquisa. No capítulo seguinte, aborda-se a relação entre séries temporais e redes neurais, apresentando-se de forma clara e concisa seus conceitos e características que puderam ser explorados no decorrer deste projeto. Já no terceiro capítulo, descrevem-se os mecanismos utilizados no pré-processamento das séries temporais e anunciam-se as variáveis de entrada da rede neural. Na sequência, discute-se o estudo em si, onde são apresentados: as ferramentas utilizadas na previsão, os resultados obtidos, uma simulação de aplicação e alguns métodos alternativos; por último é feita uma conclusão de toda a pesquisa e são apresentados possíveis estudos futuros a serem desenvolvidos.

¹ D+1 representa o dia seguinte de uma análise; D ou D+0 representa o momento em que a análise está transcorrendo;

Compondo este trabalho apresentam-se em apêndices alguns estudos realizados, que não obtiveram resultados significativos, assim como alguns detalhamentos de resultados obtidos que puderam ser retirados do corpo principal sem perda de compreensão.

II. MERCADO FINANCEIRO

II.1. BOVESPA

II.1.1. Histórico

BOVESPA é a denominação da principal bolsa de valores brasileira, localizada em São Paulo capital. Fundada em 23 de agosto de 1890, a Bolsa de Valores de São Paulo tem uma longa história de serviços prestados ao mercado de capitais e à economia brasileira.

Até meados da década de 60, a BOVESPA e as demais bolsas brasileiras eram entidades oficiais corporativas, vinculadas às secretarias de finanças, atuais secretarias da fazenda dos governos estaduais, e compostas por corretores nomeados pelo poder público.

Com as reformas do sistema financeiro nacional e do mercado de capitais vigentes a partir de 1965/66, as bolsas assumiram a característica institucional que mantêm até hoje, transformando-se em associações civis sem fins lucrativos, com autonomia administrativa, financeira e patrimonial.

A antiga figura individual do corretor de fundos públicos foi substituída pela da sociedade corretora, empresa constituída sob a forma de sociedade por ações nominativas ou por cotas de responsabilidade limitada.

A Bolsa de Valores de São Paulo é uma entidade auto-reguladora que opera sob a supervisão da Comissão de Valores Mobiliários (CVM).

Desde a década de 60, tem sido constante o desenvolvimento da BOVESPA, seja no campo tecnológico, no plano da qualidade dos serviços prestados aos investidores, aos intermediários do mercado e às companhias abertas.

Em 1972, a BOVESPA foi a primeira bolsa brasileira a implantar o pregão automatizado com a disseminação de informações *on-line* e em tempo real, através de uma ampla rede de terminais de computador.

No final da década de 70, a BOVESPA foi também pioneira na introdução de operações com opções sobre ações no Brasil; nos anos 80 implantou o Sistema Privado de Operações por Telefone (SPOT).

Na mesma época, a BOVESPA desenvolveu um sistema de custódia fungível de títulos e implantou uma rede de serviços *on-line* para as corretoras.

Em 1990, foram iniciadas as negociações através do Sistema de Negociação Eletrônica - CATS (*Computer Assisted Trading System*) que operava simultaneamente com o sistema tradicional de Pregão Viva Voz.

Em 1997, foi implantado com sucesso o novo sistema de negociação eletrônica da BOVESPA, o Mega Bolsa. Além de utilizar um sistema tecnológico altamente avançado, o Mega Bolsa amplia o volume potencial de processamento de informações e permite que a BOVESPA consolide sua posição como o mais importante centro de negócios do mercado latino-americano.

A ampliação do uso da informática foi a marca das atividades da BOVESPA em 1999, com o lançamento do *Home Broker* e do *After-Market*, ambos meios para facilitar e tornar viável a desejada participação do pequeno e médio investidor no mercado.

O *Home Broker* permite que o investidor, por meio do site das Corretoras na Internet, transmita sua ordem de compra ou de venda diretamente ao Sistema de Negociação da BOVESPA. Neste sentido, o sistema da BOVESPA é único no mundo. Nos Estados Unidos, as ordens são executadas, em sua maioria, fora do âmbito das bolsas de valores e, portanto, nem sempre ao melhor preço.

O *After-Market* é outra inovação da BOVESPA, pioneira em termos mundiais, que oferece a sessão noturna de negociação eletrônica. Além de atender aos profissionais do mercado, este mecanismo também é interessante para os pequenos e médios investidores, pois permite que enviem ordens por meio da Internet também no período noturno.

Atualmente, a BOVESPA é o maior centro de negociação com ações da América Latina, destaque que culminou com um acordo histórico para a integração de todas as bolsas brasileiras em torno de um único mercado de valores - o da BOVESPA.

Em janeiro de 2005 eram negociadas ações de 379 companhias na BOVESPA, dentre elas:

- Acesita
- Ambev
- Aracruz
- Banco do Brasil
- Bradesco
- Bradespar
- Brasil Telecom
- Braskem
- Caemi
- Celesc
- Cemig
- CESP
- Comgas
- Copel
- CRT Celular
- CSN
- Eletrobras
- Eletropaulo
- Embraer
- Embratel
- Gerdau
- Ipiranga Petróleo
- Itaubanco
- Itausa
- Klabin
- Light Serviços Eletricidade
- NET
- Petrobras
- Sabesp
- Siderúrgica Tubarão
- Souza Cruz
- Tele Centro Oeste
- Tele Leste Celular
- Telemar
- Telemig Celular
- Telesp
- Telesp Celular
- TIM Participações
- Tractebel Energia
- Transmissão Paulista
- Vale do Rio Doce
- Votorantim Celulose e Papel

O índice que mede o desempenho das principais ações do BOVESPA é o IBOVESPA, além deste, existem outros índices secundários como IBX50 e IBX100.

II.1.2. IBOVESPA

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

É o valor atual, em moeda corrente, de uma carteira teórica de ações constituída em 02/01/1968, a partir de uma aplicação hipotética¹. Supõe-se não ter sido efetuado nenhum investimento adicional desde então, considerando-se somente os ajustes efetuados em decorrência da distribuição de proventos pelas empresas emissoras (tais como reinversão de dividendos recebidos e do valor apurado com a venda de direitos de subscrição, e manutenção em carteira das ações recebidas em bonificação). Dessa forma, o índice reflete não apenas as variações dos preços das ações, mas também o impacto da distribuição dos proventos, sendo considerado um indicador que avalia o retorno total de suas ações componentes.

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

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

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

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

¹ O Índice sofreu, unicamente para efeito de divulgação e sem prejuízo de sua metodologia de cálculo, as seguintes adequações:

- Divisão por 100, em 03/10/1983;
- Divisão por 10, em 02/12/1985;
- Divisão por 10, em 29/08/1988;
- Divisão por 10, em 14/04/1989;
- Divisão por 10, em 12/01/1990;
- Divisão por 10, em 28/05/1991;
- Divisão por 10, em 21/01/1992;
- Divisão por 10, em 26/01/1993;
- Divisão por 10, em 27/08/1993;
- Divisão por 10, em 10/02/1994;
- Divisão por 10, em 03/03/1997.

A BOVESPA calcula seu índice em tempo real, considerando os preços dos últimos negócios efetuados no mercado à vista com ações componentes de sua carteira.

Sua divulgação é feita pela rede de difusão da BOVESPA e também retransmitida por uma série de *vendors*, sendo possível, dessa forma, acompanhar *on line* seu comportamento em qualquer parte do Brasil ou do mundo.

Uma metodologia de cálculo simples, com seus dados à disposição do público investidor, assegura uma grande confiabilidade ao Índice BOVESPA. Isto pode ser constatado pela chancela do mercado, traduzida pelo fato do IBOVESPA ser o único dos indicadores de performance de ações brasileiras a ter um mercado futuro líquido (um dos maiores mercados de contrato de índice do mundo).

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

II.2. Previsão de Mercado Financeiro

A previsão de mercado financeiro desperta o interesse de muitos pesquisadores e é uma área aonde muito ainda pode ser estudado e explorado. Em parte, devido ao pequeno incentivo que estes trabalhos recebem para serem publicados na área acadêmica, sendo na maior parte dos casos vendidos para os grandes bancos de investimento.

O conjunto de informações utilizado na previsão caracteriza a eficiência do preditor desenvolvido. Esse conjunto pode conter apenas informações passadas e correntes das cotações de mercado, dispor de todas as informações públicas ou ainda ser composto por informações privadas, mais difíceis de mensurar e, possivelmente, mais caras para se adquirir. É fundamental avaliar o conjunto de informações disponíveis em tempo real para o desenvolvimento de um preditor.

Os modelos de preditores devem rapidamente detectar e utilizar quaisquer períodos com indícios de previsibilidade do comportamento do mercado financeiro e esses períodos podem surgir e rapidamente desaparecer devido à exploração desse comportamento por outros investidores ou pelo próprio investidor¹. Portanto, a

¹Notadamente para investidores de grande porte.

implementação de um preditor é um processo contínuo de adequação à volatilidade do mercado e, sendo assim, torna-se difícil estimar um intervalo de tempo em que um modelo apresentará bons retornos e garantir que o risco mantenha-se estável durante todo o período.

Além dos fatores de risco, outros aspectos precisam ser levados em consideração na avaliação de um preditor, dentre eles os custos para operar na bolsa, assim como possíveis restrições de operação.

A previsão pode focar-se em diversos níveis de dinamismo do mercado financeiro, prevendo desde tendências para investimentos de longo prazo até cotações *intra-day* para aplicações que requeiram maior agilidade. Dentro destes dois extremos, há a previsão do fechamento das cotações diárias que é a tônica do presente trabalho.

II.3. Indicadores Econômicos

Neste estudo, foram analisados vinte indicadores econômicos nacionais e estrangeiros, a fim de realizar a previsão da cotação do IBOVESPA em $D+1$. Desta forma, pretende-se avaliar a influência de suas séries temporais atrasadas no comportamento da série objetivo. Nos estudos subseqüentes, será considerada a influência das observações desses indicadores até vinte dias úteis antes ($D-19$) da observação em análise, ou seja, um mês antes.

Inicialmente, para esta análise foi utilizado um conjunto de dados compreendendo o período de 01/02/1999 a 22/11/2004, período este dentro do Plano Real, sendo composto por observações diárias obtidas da base de dados Bloomberg [1]. Sendo que os últimos três meses deste conjunto de dados foram reservados para a realização de uma simulação de aplicação do modelo desenvolvido, portanto este conjunto não fez parte de nenhum estudo estatístico, somente foi submetido às transformações propostas.

Consideraram-se semanas de cinco dias úteis, portanto sábados e domingos foram descartados e em feriados convencionou-se que seria mantida a cotação do último dia útil imediatamente anterior ao feriado. Ou seja, convencionou-se que em um feriado a cotação dos indicadores manter-se-ia constante.

Uma breve descrição e o comportamento destes indicadores econômicos no período proposto são disponibilizados a seguir:

- Fechamento IBOVESPA – valor em que foi cotado o IBOVESPA na última operação realizada no pregão da BOVESPA;




Figura 1: Série de Cotações do Fechamento do IBOVESPA.

- Abertura IBOVESPA – valor em que foi cotado o IBOVESPA na primeira operação realizada no pregão da BOVESPA;

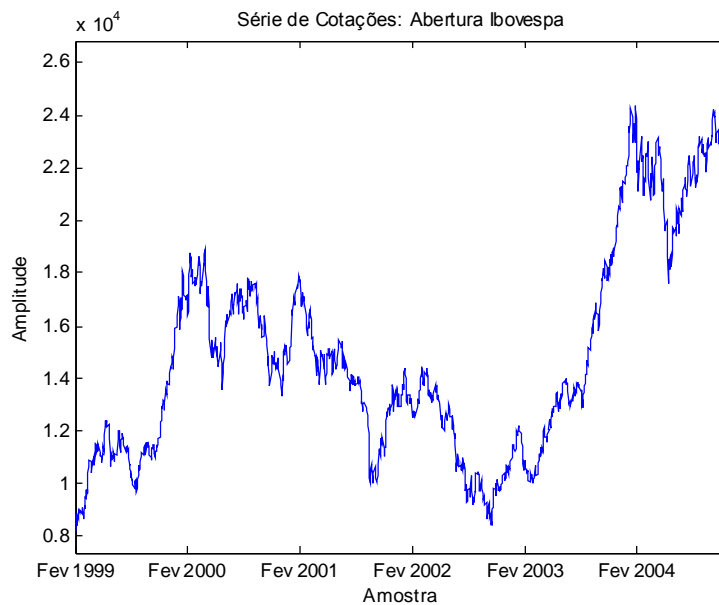


Figura 2: Série de Cotações da Abertura do IBOVESPA.

- Mínimo IBOVESPA – valor mínimo em que foi cotado o IBOVESPA durante as operações realizadas no pregão da BOVESPA;

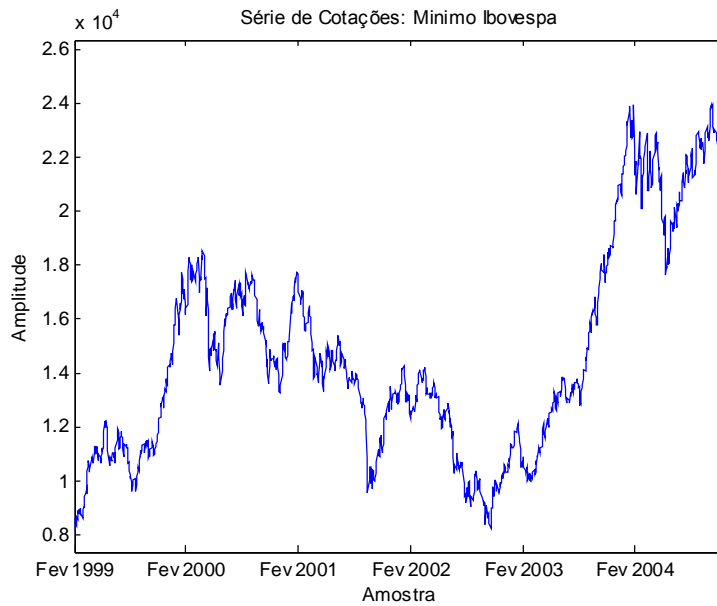


Figura 3: Série de Cotações do Mínimo do IBOVESPA.

- Máximo IBOVESPA – valor máximo em que foi cotado o IBOVESPA durante as operações realizadas no pregão da BOVESPA;




Figura 4: Série de Cotações do Máximo do IBOVESPA.

- Fechamento NASDAQ – Mede todas as ações ordinárias NASDAQ (*National Association of Security Dealers Automated Quotation System*) domésticas e não domésticas listadas na *The Nasdaq Stock Market* em Nova Iorque. O Índice é o valor ponderado de mercado e isto significa que cada título da empresa afeta o Índice na proporção de seu valor de mercado. O valor de mercado, o último preço de venda multiplicado pelo total de ações em circulação, é calculado durante o dia da comercialização e é relacionado ao valor total do Índice. Atualmente inclui mais de 5.000 empresas, mais que a maioria dos outros índices de mercado de ações, sendo amplamente seguido;




Figura 5: Série de Cotações do Fechamento do Índice NASDAQ.

- Fechamento C-Bond – do inglês *Capitalization Bond* é o título de dívida externa emitido pelo governo brasileiro em 1994, sendo a base de cálculo do risco país;




Figura 6: Série de Cotações do Fechamento do Índice C-Bond Brasil.

- Fechamento Dow Jones – índice da bolsa de valores de Nova Iorque (NYSE) que representa o setor industrial dos EUA;




Figura 7: Série de Cotações do Fechamento do Índice Dow Jones.

- Fechamento CDI – Criado em meados da década de 1980, os Certificados de Depósito Interbancário são os títulos de emissão das instituições financeiras, que lastreiam as operações do mercado interbancário. O CDI é utilizado para avaliar o custo do dinheiro negociado entre os bancos, no setor privado;




Figura 8: Série de Cotações do Fechamento do Índice CDI.

- Fechamento Merval – Lançado em 30 de junho de 1986, o Índice Merval é uma média do valor de mercado de uma carteira de ações selecionadas de acordo com sua negociação na Bolsa de Comércio de Buenos Aires. A atualização das ações que compõem o índice é feita trimestralmente de acordo com sua participação no mercado nos últimos seis meses;




Figura 9: Série de Cotações do Fechamento do Índice Merval.

- Fechamento FTSE100 – Desenvolvido conjuntamente pelo Financial Times e pela Bolsa de Valores de Londres foi lançado em 3 de janeiro de 1984. O FTSE 100, apelidado de *Footsie*, corresponde a uma carteira de 100 ações de maior capitalização entre as mais de 2.500 ações registradas nessa bolsa. A metodologia adota o sistema de ponderação por valor de mercado das empresas emissoras. Desde seu nascimento tem sido objeto de contratos futuros e de opções de estilo europeu negociados na Bolsa de Valores de Londres;

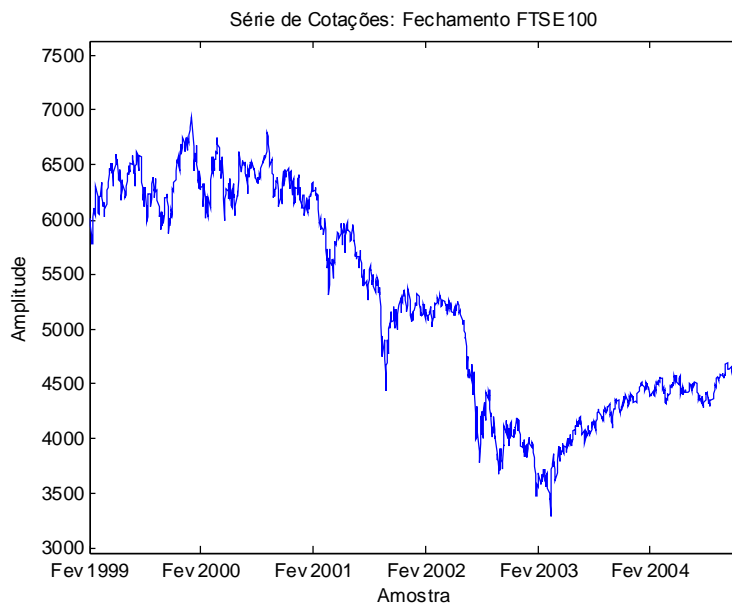


Figura 10: Série de Cotações do Fechamento do Índice FTSE.

- Fechamento PTAX – Taxa de câmbio calculada ao final de cada dia, ou seja, é a taxa média de todos os negócios com dólares realizados naquela data no mercado interbancário de câmbio, com liquidação em $D+2$;




Figura 11: Série de Cotações do Fechamento do Índice PTAX.

- Fechamento S&P – Consiste em 500 ações escolhidas por tamanho de mercado, liquidez e representação de grupo industrial. Ele é um índice ponderado de valor de mercado (preço da ação vezes número de ações em circulação) com o peso de cada ação no Índice proporcional a seu valor de mercado. É uma das marcas mais amplamente usadas do desempenho patrimonial norte-americano;

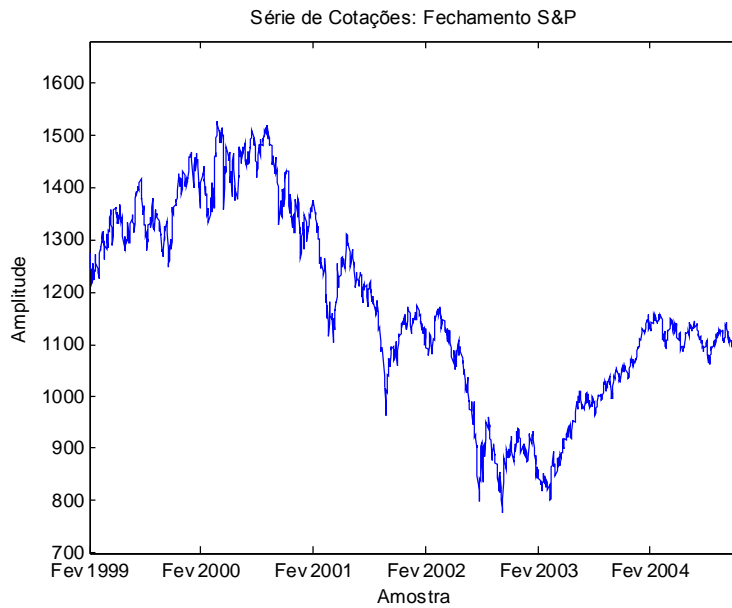


Figura 12: Série de Cotações do Fechamento do Índice S&P.

- Fechamento IBX – Índice Brasil, mede o retorno de uma carteira teórica composta por 100 ações selecionadas dentre as mais negociadas na BOVESPA em termos de número de negócios e volume financeiro e ponderadas pelo seu respectivo número de ações disponíveis à negociação no mercado;




Figura 13: Série de Cotações do Fechamento do IBX.

- Fechamento DIxPre180 – consiste em um indicador que representa a troca de rentabilidade e risco entre indicadores distintos, neste caso DI¹ versus taxa de juros prefixada de 180 dias.




Figura 14: Série de Cotações do Fechamento do DIxPre180.

¹ Carteiras que aplicam em renda fixa, porém, amarram a rentabilidade dos papéis que adquirem à variação dos Depósitos Interfinanceiros, normalmente fazendo operações no mercado futuro. Assim, oscilam diariamente junto aos juros interbancários, mas não oferecem nenhum adicional de rentabilidade.

- Fechamento DlxPre360 – consiste em um indicador que representa a troca de rentabilidade e risco entre indicadores distintos, neste caso DI versus taxa de juros prefixada de 360 dias;




Figura 15: Série de Cotações do Fechamento do DlxPre360.

- Fechamento DlxPre540 – consiste em um indicador que representa a troca de rentabilidade e risco entre indicadores distintos, neste caso DI versus taxa de juros prefixada de 540 dias;




Figura 16: Série de Cotações do Fechamento do DlxPre540.

- Fechamento DlxPre720 – consiste em um indicador que representa a troca de rentabilidade e risco entre indicadores distintos, neste caso DI versus taxa de juros prefixada de 720 dias;




Figura 17: Série de Cotações do Fechamento do DlxPre720.

- Fechamento Euro – cotação em relação ao Dólar Americano da moeda oficial da União Européia;




Figura 18: Série de Cotações do Fechamento do Euro.

- Fechamento Yen – cotação em relação ao Dólar Americano da moeda oficial do Japão;




Figura 19: Série de Cotações do Fechamento do Yen.

- Fechamento Dólar – cotação em relação ao Real da moeda oficial dos Estados Unidos da América;




Figura 20: Série de Cotações do Fechamento do Dólar.

II.4. Indicadores Calculados

Além dos indicadores dispostos na seção anterior, gerou-se um conjunto de indicadores calculados definidos a partir das quatro diferentes cotações do IBOVESPA disponíveis neste estudo. O intuito da geração destes indicadores é de manter em um único indicador características comportamentais do IBOVESPA. São eles:

- Variação Diária do IBOVESPA – definido como o logaritmo do valor da cotação do fechamento do IBOVESPA dividido pelo valor da cotação de abertura em um determinado dia, ou seja:

$$r_t = \log\left(\frac{f_t}{a_t}\right) \quad (1)$$

Onde:

r_t – representa a série retornos na data t ;

f_t – representa a cotação do fechamento IBOVESPA na data t ;

a_t – representa a cotação da abertura IBOVESPA na data t ;

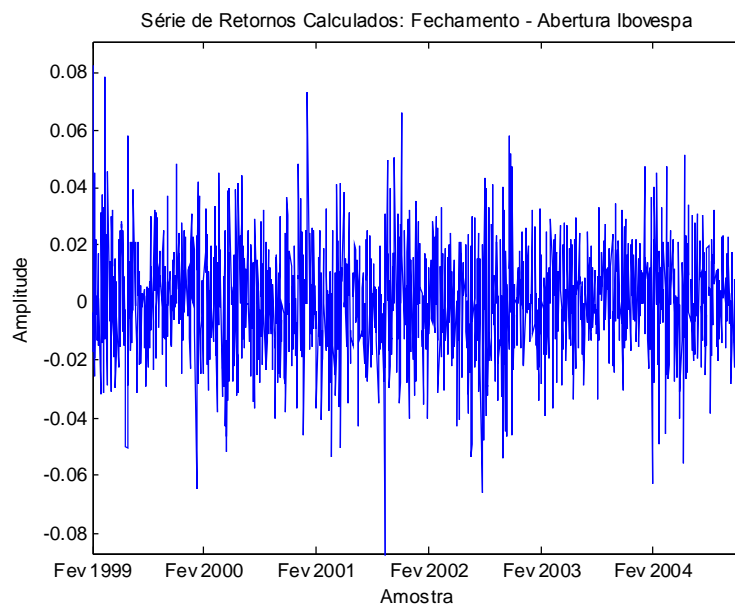


Figura 21: Série de Retornos da Variação Diária do IBOVESPA.

- Variação Noturna IBOVESPA – definido como o logaritmo do valor da cotação de abertura do IBOVESPA em um determinado dia dividido pelo valor da cotação do último fechamento ocorrido:

$$r_t = \log\left(\frac{a_t}{f_{t-n}}\right) \quad (2)$$

Onde:

r_t – representa a série retornos na data t ;

f_{t-n} – representa a cotação do fechamento IBOVESPA no último dia útil anterior à data t ;

a_t – representa a cotação da abertura IBOVESPA na data t ;

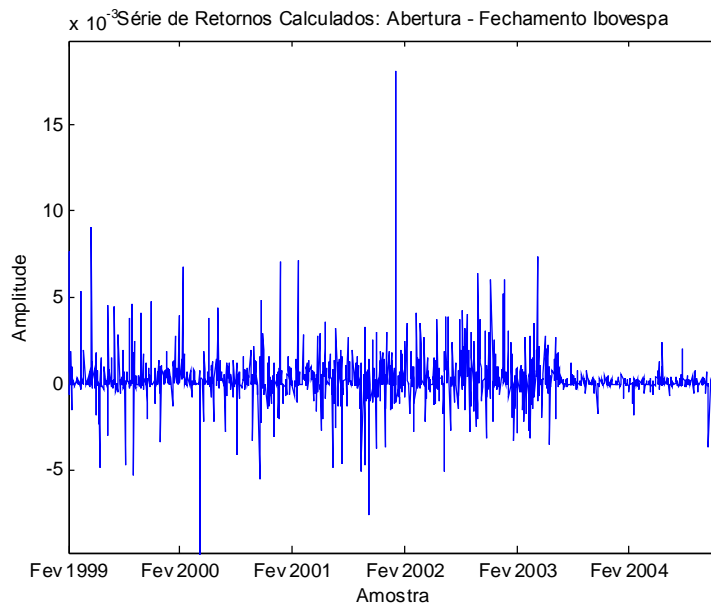


Figura 22: Série de Retornos da Variação Noturna do IBOVESPA.

- Variação Máxima IBOVESPA – definido como o logaritmo do valor máximo da cotação do IBOVESPA dividido pelo valor mínimo da cotação em um determinado dia:

$$r_t = \log\left(\frac{\max_t}{\min_t}\right) \quad (3)$$

Onde:

r_t – representa a série retornos na data t ;

\max_t – representa a máxima cotação do IBOVESPA na data t ;

\min_t – representa a mínima cotação do IBOVESPA na data t ;

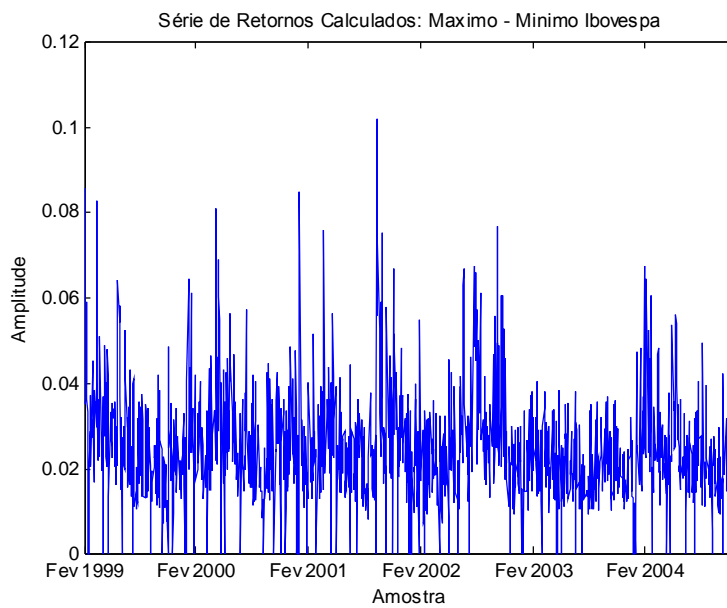


Figura 23: Série de Retornos da Variação Máxima do IBOVESPA.

III. SÉRIES TEMPORAIS E REDES NEURAIAS

III.1. Redes Neurais

As redes neurais utilizadas nesta pesquisa são redes do tipo *feedforward* com duas camadas de neurônios, múltiplas entradas e uma saída, como apresentado na figura a seguir. A camada de neurônios intermediária é composta por neurônios com função de ativação do tipo tangente hiperbólica e a camada de saída composta por um único neurônio com função de ativação linear. Todos os neurônios possuem sinapse de polarização e todas as entradas se comunicam através de sinapses com os neurônios da camada intermediária, cujas saídas comunicam-se através de sinapses com o neurônio da camada de saída.

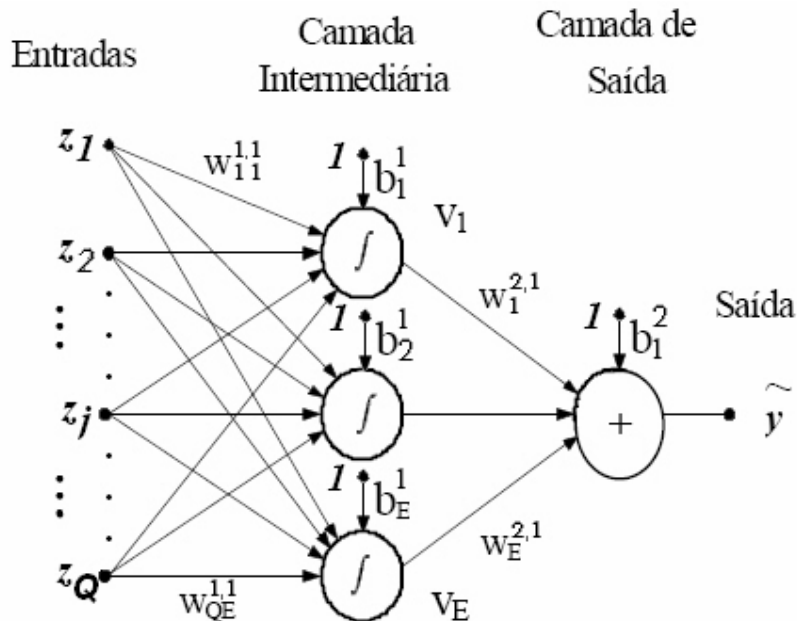


Figura 24: Rede Neural *feedforward*.

Onde:

z_j – representa a entrada j ;

$w_n^{1,1}$ – representa a sinapse entre a entrada n e o neurônio j da camada intermediária;

b_j^k – representa a sinapse de polarização do neurônio j da camada k ;

v_e – representa a saída do neurônio e da camada intermediária;

$w_j^{2,1}$ – representa a sinapse entre o neurônio j da camada intermediária e o neurônio da camada de saída;

\tilde{y} – representa a saída predita da rede;

Sendo:

$$v_j = \text{tgh} \left(\sum_{n=1}^Q w_{n,j}^{1,1} z_n + b_j^1 \right) \forall i = 1, \dots, E \quad (4)$$

$$\tilde{y} = \sum_{j=1}^E w_j^{2,1} v_j + b_1^2 \quad (5)$$

O treinamento da rede foi realizado por épocas com retro propagação do erro e o critério de performance da rede foi estabelecido através do erro médio quadrático (EMQ). O conjunto de dados foi segmentado em quatro subconjuntos: treinamento, validação, teste e um subconjunto adicional de aplicação¹. Os dois primeiros são utilizados no processo de treinamento da rede e os dois últimos utilizados para avaliar a rede gerada.

Neste estudo, as entradas da rede serão compostas pelos indicadores econômicos, pelos indicadores calculados e pelo próprio IBOVESPA atrasados:

$$\tilde{y}(t) = \varphi [z(t-1), \dots, z(t-N), y(t-1), \dots, y(t-M)]$$

Onde:

$z(t-k)$ – representa o conjunto de entradas atrasadas de k dias;

$y(t-k)$ – representa a saída real atrasada de k dias;

N – representa os maiores atrasos utilizados nas entradas;

M – representa o máximo atraso utilizado na saída;

\tilde{y} – representa a saída da rede;

Sendo que os atrasos considerados para cada uma das entradas da rede neural seguiram um critério específico de seleção, que será descritos posteriormente, e que foram analisados atrasos de até 20 dias úteis referentes à data em análise. Parâmetros específicos utilizados na rede projetada também serão descritos em uma seção posterior.

¹ Composto pelos últimos três meses do conjunto de dados, será mantido isolado de todas as análises estatísticas subseqüentes e servirá apenas para ser utilizado no processo de simulação do projeto.

III.2. Tendência

A componente mais fácil de identificar visualmente é a tendência da série, caracterizada por um comportamento que pode ser aproximado por faixas, em geral, por uma função conhecida. As mais comuns são lineares, polinomiais, exponenciais e logarítmicas.

Nas séries de cotações analisadas, pode-se observar claramente a existência de média móvel, ou seja, uma tendência linear, caracterizada por uma variação do valor médio das séries por intervalo de tempo. Portanto, essas foram submetidas a uma transformação para eliminação desta característica, gerando séries de retornos. Maiores informações sobre o processo utilizado serão fornecidas no próximo capítulo.

III.3. Sazonalidade

Normalmente, em série temporais, identificam-se padrões que se repetem em intervalos regulares de tempo, ou períodos. Esta característica é chamada de sazonalidade da série. Os períodos da sazonalidade de uma série podem ser determinados pelo conhecimento da fenomenologia da série. Em se tratando de mercado financeiro, não havia algo esperado e pela análise das séries não foi observada nenhuma sazonalidade.

III.4. Ciclos Senoidais

Um caso particular de sazonalidade é o ciclo senoidal, em que a sazonalidade possui a forma de uma senóide com período determinado. Esta senóide também é caracterizada por uma forma senoidal de mesmo período na autocorrelação da série e por uma raia de frequência com amplitude significativamente acima da média em seu espectrograma.

Os espectros de frequência das séries de retornos foram estimados para analisar esta característica e estão dispostos no Apêndice I. Esses resultados foram suprimidos do corpo deste trabalho, pois não foram encontradas informações relevantes nas séries.

IV. PRÉ-PROCESSAMENTO

IV.1. Séries de Retornos

Como observado no capítulo anterior, analisando-se as séries de cotações dos indicadores econômicos, identifica-se claramente a presença de média móvel no decorrer das mesmas. Para a retirada dessa tendência, optou-se por trabalhar com séries de retornos que refletem as variações diárias dos indicadores em detrimento das séries de cotações. Portanto, as séries foram submetidas a uma transformação não linear, através da aplicação do seguinte procedimento:

$$r_t = \ln \left(\frac{c_t}{c_{t-1}} \right) \quad (6)$$

Onde:

r_t – representa a série retornos na data t ;

c_t – representa a série de cotações na data t ;

Com isso, as séries analisadas passam a ser uma composição da variação da cotação do indicador em $D+0$ em relação à cotação em $D-1$. A essas composições, denominam-se séries de retornos, que serão as séries efetivamente estudadas no decorrer desta pesquisa. Seus comportamentos podem ser observados nas figuras a seguir:




Figura 25: Série de Retornos do Fechamento IBOVESPA.




Figura 26: Série de Retornos da Abertura IBOVESPA.

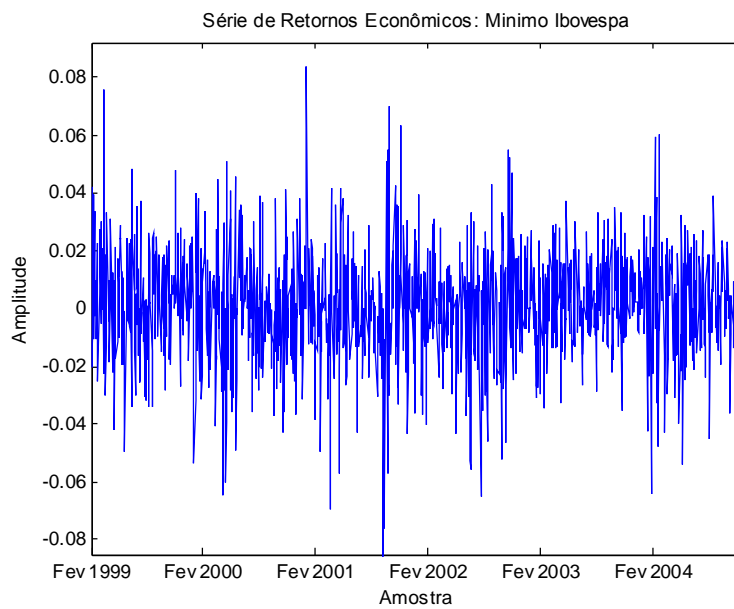


Figura 27: Série de Retornos do Mínimo IBOVESPA.




Figura 28: Série de Retornos do Máximo IBOVESPA.




Figura 29: Série de Retornos do Fechamento NASDAQ.




Figura 30: Série de Retornos do Fechamento BRACBOND.

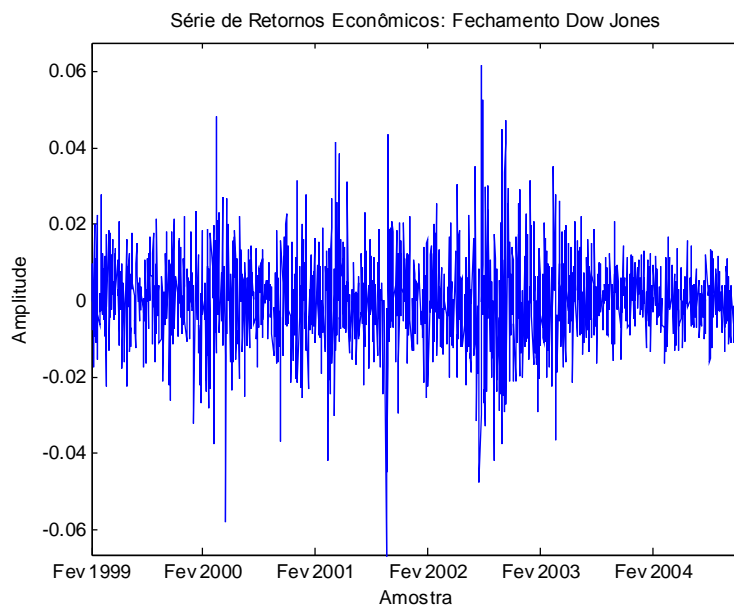


Figura 31: Série de Retornos do Fechamento Dow Jones.




Figura 32: Série de Retornos do Fechamento CDI.




Figura 33: Série de Retornos do Fechamento Merval.




Figura 34: Série de Retornos do Fechamento FTSE100.




Figura 35: Série de Retornos do Fechamento PTAX.




Figura 36: Série de Retornos do Fechamento S&P.




Figura 37: Série de Retornos do Fechamento IBX.




Figura 38: Série de Retornos do Fechamento DlxPre180.




Figura 39: Série de Retornos do Fechamento DlxPre360.




Figura 40: Série de Retornos do Fechamento DlxPre540.




Figura 41: Série de Retornos do Fechamento DlxPre720.




Figura 42: Série de Retornos do Fechamento Euro.




Figura 43: Série de Retornos do Fechamento Yen.




Figura 44: Série de Retornos do Fechamento Dólar.

Como observado no capítulo anterior, pela análise visual dos resultados acima não se verificou a presença de qualquer sazonalidade nas séries.

IV.2. Outliers

Para garantir uma maior generalidade da rede neural e realizar a retirada de dados espúrios, os indicadores econômicos e calculados foram submetidos a uma rotina específica de tratamento e atenuação de *outliers*. Desta forma garante-se que o treinamento das redes neurais envolvidas não será influenciado em demasia pelas grandes variações atípicas no período.

Em função, da presença de *clusters* de volatilidade, períodos de alta e baixa volatilidade (*heteroscedasticity*), nas séries de retornos econômicas, a caracterização de um *outlier* foi realizada por *clusters* seqüenciais e não na série como um todo.

O processo utilizado para este tratamento é descrito a seguir:

- Define-se a data da série onde a análise deverá ser realizada;
- Seleciona-se o período de duas semanas (dez dias úteis) imediatamente anteriores à data em análise;
- Estima-se média e desvio padrão deste conjunto de onze dias;
- São definidos limiares superiores e inferiores estimados através da média acrescida e decrescida de dois desvios padrões respectivamente;

- Caso o valor da série de retornos na data especificada ultrapasse um dos limiares estabelecidos, seu valor é *clampado* ao valor definido pelo limiar ultrapassado, isto é, fixado nesse limiar;
- A rotina é repetida até que a varredura de toda a série seja realizada;

É clara a deficiência da rotina no que tange o início da série de retornos devido à falta de dados para compor o *cluster* anterior à data em análise. Porém, posteriormente, esses primeiros dias da série serão desconsiderados.

A aplicação desta rotina é unidirecional e baseia-se apenas em valores passados, ou seja, em seu algoritmo não se utilizam valores futuros à data em análise, pois, estes valores não serão de conhecimento prévio na fase de execução do sistema.

Supondo uma distribuição normal, o limiar dado pela média acrescida e decrescida de dois desvios padrões prevê que 95,5 % dos dados serão mantidos com seus valores originais. Ilustrando o suposto, os percentuais de tratamento de *outlier* por indicador podem ser observados nas tabelas a seguir:

Tabela 1: Tratamento de *Outliers* - Indicadores Econômicos

Indicador	% Rejeição de <i>Outliers</i>
Fechamento IBOVESPA	3,10 %
Abertura IBOVESPA	3,10 %
Mínimo IBOVESPA	3,43 %
Máximo IBOVESPA	3,23 %
Fechamento NASDAQ	1,85 %
Fechamento BRACBOND	3,70 %
Fechamento Dow Jones	2,38 %
Fechamento CDI	7,79 %
Fechamento Merval	3,96 %
Fechamento FTSE100	2,51 %
Fechamento PTAX	3,50 %
Fechamento S&P	2,77 %
Fechamento IBX	2,71 %
Fechamento DlxPRE180	4,88 %
Fechamento DlxPRE360	4,42 %
Fechamento DlxPRE540	3,89 %
Fechamento DlxPRE720	3,76 %
Fechamento Euro	3,23 %
Fechamento Yen	3,17 %
Fechamento Dólar	3,89 %

Tabela 2: Tratamento de *Outliers* - Indicadores Calculados

Indicador	% Rejeição de <i>Outliers</i>
Δ Diária IBOVESPA	3,10 %
Δ Noturna IBOVESPA	7,13 %
Δ Máxima IBOVESPA	4,82 %

Após serem submetidas ao processo de tratamento de *outliers*, as séries de retornos são exibidas a seguir:




Figura 45: *Atenuação de Outliers* Fechamento IBOVESPA.




Figura 46: *Atenuação de Outliers* Abertura IBOVESPA.




Figura 47: Atenuação de *Outliers* Mínimo IBOVESPA.




Figura 48: Atenuação de *Outliers* Máximo IBOVESPA.




Figura 49: Atenuação de *Outliers* Fechamento NASDAQ.




Figura 50: Atenuação de *Outliers* Fechamento BRACBOND.




Figura 51: Atenuação de *Outliers* Fechamento Dow Jones.




Figura 52: Atenuação de *Outliers* Fechamento CDI.




Figura 53: Atenuação de *Outliers* Fechamento Merval.




Figura 54: Atenuação de *Outliers* Fechamento FTSE100.




Figura 55: Atenuação de *Outliers* Fechamento PTAX.




Figura 56: Atenuação de *Outliers* Fechamento S&P.




Figura 57: Atenuação de *Outliers* Fechamento IBX.




Figura 58: Atenuação de *Outliers* Fechamento DlxPre180.




Figura 59: Atenuação de *Outliers* Fechamento DlxPre360.




Figura 60: Atenuação de *Outliers* Fechamento DlxPre540.




Figura 61: Atenuação de *Outliers* Fechamento DlxPre720.




Figura 62: Atenuação de *Outliers* Fechamento Euro.




Figura 63: Atenuação de *Outliers* Fechamento Yen.




Figura 64: Atenuação de *Outliers* Fechamento Dólar.




Figura 65: Atenuação de *Outliers* Variação Diária do IBOVESPA.




Figura 66: Atenuação de *Outliers* Variação Noturna do IBOVESPA.




Figura 67: Atenuação de *Outliers* Variação Máxima do IBOVESPA.

IV.3. Distribuição dos Indicadores

Fez-se um estudo sobre as características de alguns parâmetros estatísticos dos indicadores referentes à distribuição dos mesmos. Os parâmetros estimados foram:

- Média – valor médio de uma população usualmente utilizado como valor da tendência central de um conjunto de dados, para valores reais de variáveis aleatórias a média representa o valor esperado destas variáveis;

$$\mu = \hat{E}(x) = \frac{1}{N} \sum_{k=1}^N x_k \quad (7)$$

- Mediana – também conhecido como percentil de 50 %, é o valor que separa uma população onde metade das amostras é superior e metade é inferior ao valor estimado;
- Variância – em estatística é uma medida da dispersão de uma variável aleatória, indicando quão distante as variáveis estão do valor esperado de uma distribuição;

$$\sigma^2 = \hat{E}((x - \mu)^2) = \frac{1}{N-1} \sum_{k=1}^N (x_k - \mu)^2 \quad (8)$$

- Desvio Padrão – é a medida mais utilizada para indicar como os dados estão dispersos em um conjunto e é definido como a raiz quadrada da variância;

$$\sigma = \left[\frac{1}{N-1} \sum_{k=1}^N (x_k - \mu)^2 \right]^{1/2} \quad (9)$$

- Assimetria – é uma medida da assimetria da distribuição de valores reais de uma variável aleatória, mais precisamente seu valor será positivo quando a cauda superior for mais longa e negativo no caso contrário;

$$s = \frac{E((x - \mu)^3)}{\sigma^3} \quad (10)$$

- Curtose – é uma medida de dispersão que caracteriza o “achatamento” de uma distribuição. Um alto coeficiente indica que boa parte da variância é devido a desvios pouco freqüentes, ou seja, um pico suave e caudas mais “gordas”. Uma curtose de 3 indica uma distribuição normal;

$$k = \frac{E((x - \mu)^4)}{\sigma^4} \quad (11)$$

As estimativas destes parâmetros para os indicadores econômicos podem ser visualizadas na tabela 3. Na tabela 4, os mesmos resultados são apresentados para os indicadores calculados. A análise gráfica das distribuições destas séries foi suprimida do corpo deste documento e encontra-se disponível no Apêndice II.

Tabela 3: Parâmetros de Distribuição - Indicadores Econômicos

Indicador	Média	Mediana	Variância	Desvio Padrão	Assimetria	Curto se
Fechamento IBOVESPA	$7,28 \times 10^{-4}$	$1,10 \times 10^{-3}$	$3,64 \times 10^{-4}$	$1,91 \times 10^{-2}$	$-8,96 \times 10^{-2}$	3,52
Abertura IBOVESPA	$7,10 \times 10^{-4}$	$6,63 \times 10^{-4}$	$3,60 \times 10^{-4}$	$1,90 \times 10^{-2}$	$-1,03 \times 10^{-1}$	3,53
Mínimo IBOVESPA	$7,60 \times 10^{-4}$	$1,85 \times 10^{-3}$	$3,25 \times 10^{-4}$	$1,80 \times 10^{-2}$	$-2,02 \times 10^{-1}$	4,17
Máximo IBOVESPA	$7,30 \times 10^{-4}$	$9,87 \times 10^{-4}$	$2,60 \times 10^{-4}$	$1,61 \times 10^{-2}$	$-1,17 \times 10^{-1}$	3,87
Fechamento NASDAQ	$-1,82 \times 10^{-4}$	$7,23 \times 10^{-4}$	$6,67 \times 10^{-4}$	$2,58 \times 10^{-2}$	$1,74 \times 10^{-1}$	4,91
Fechamento BRACBOND	$3,84 \times 10^{-4}$	$7,12 \times 10^{-4}$	$1,35 \times 10^{-4}$	$1,16 \times 10^{-2}$	$-5,80 \times 10^{-1}$	14,33
Fechamento Dow Jones	$9,51 \times 10^{-5}$	$1,47 \times 10^{-4}$	$1,41 \times 10^{-4}$	$1,19 \times 10^{-2}$	$4,36 \times 10^{-2}$	4,79
Fechamento CDI	$-4,37 \times 10^{-4}$	0	$1,13 \times 10^{-4}$	$1,06 \times 10^{-2}$	$-3,73 \times 10^{-1}$	108,82
Fechamento Merval	$7,78 \times 10^{-4}$	$2,54 \times 10^{-4}$	$5,54 \times 10^{-4}$	$2,35 \times 10^{-2}$	$2,51 \times 10^{-1}$	6,68
Fechamento FTSE100	$-1,54 \times 10^{-4}$	$2,04 \times 10^{-4}$	$1,56 \times 10^{-4}$	$1,25 \times 10^{-2}$	$-1,40 \times 10^{-1}$	4,97
Fechamento PTAX	$2,91 \times 10^{-4}$	$2,89 \times 10^{-4}$	$9,55 \times 10^{-5}$	$9,77 \times 10^{-3}$	$-3,11 \times 10^{-1}$	9,19
Fechamento S&P	$-2,67 \times 10^{-5}$	$2,64 \times 10^{-5}$	$1,53 \times 10^{-4}$	$1,24 \times 10^{-2}$	$1,37 \times 10^{-1}$	4,17
Fechamento IBX	$1,05 \times 10^{-3}$	$1,24 \times 10^{-3}$	$2,47 \times 10^{-4}$	$1,57 \times 10^{-2}$	$-1,33 \times 10^{-1}$	3,86
Fechamento DIXPRE180	$-7,04 \times 10^{-4}$	$-1,28 \times 10^{-3}$	$4,41 \times 10^{-4}$	$2,10 \times 10^{-2}$	$-7,18 \times 10^{-2}$	11,84
Fechamento DIXPRE360	$-6,38 \times 10^{-4}$	$-1,01 \times 10^{-3}$	$5,42 \times 10^{-4}$	$2,33 \times 10^{-2}$	$6,25 \times 10^{-2}$	10,36
Fechamento DIXPRE540	$-6,94 \times 10^{-4}$	$-8,89 \times 10^{-4}$	$3,83 \times 10^{-4}$	$1,96 \times 10^{-2}$	$8,26 \times 10^{-2}$	7,57
Fechamento DIXPRE720	$-6,87 \times 10^{-4}$	$-8,62 \times 10^{-4}$	$4,18 \times 10^{-4}$	$2,05 \times 10^{-2}$	$7,85 \times 10^{-2}$	6,91
Fechamento Euro	$8,98 \times 10^{-5}$	0	$4,07 \times 10^{-5}$	$6,38 \times 10^{-3}$	$-1,00 \times 10^{-1}$	3,39
Fechamento Yen	$-6,74 \times 10^{-5}$	$-8,58 \times 10^{-5}$	$3,91 \times 10^{-5}$	$6,25 \times 10^{-3}$	$-7,85 \times 10^{-2}$	3,92
Fechamento Dólar	$2,56 \times 10^{-4}$	$1,96 \times 10^{-4}$	$1,02 \times 10^{-4}$	$1,01 \times 10^{-2}$	$-1,46 \times 10^{-1}$	7,86

Tabela 4: Parâmetros de Distribuição - Indicadores Calculados

Indicador	Média	Mediana	Variância	Desvio Padrão	Assimetria	Curto se
Δ Diária IBOVESPA	$4,34 \times 10^{-4}$	$6,09 \times 10^{-4}$	$3,57 \times 10^{-4}$	$1,89 \times 10^{-2}$	$-1,03 \times 10^{-1}$	3,51
Δ Noturna IBOVESPA	$3,16 \times 10^{-4}$	$1,79 \times 10^{-4}$	$1,49 \times 10^{-6}$	$1,22 \times 10^{-3}$	$9,81 \times 10^{-1}$	16,05
Δ Máxima IBOVESPA	$2,49 \times 10^{-2}$	$2,30 \times 10^{-2}$	$1,31 \times 10^{-4}$	$1,16 \times 10^{-2}$	1,16	5,43

Pode-se observar que a maior parte dos indicadores analisados possui comportamento próximo a uma distribuição normal, demais conclusões podem ser obtidas através dos resultados gráficos.

IV.4. Autocorrelação e Correlação Cruzada

A autocorrelação direta de uma série temporal nada mais é do que a correlação entre o valor atual da série $y(t)$ e o valor atrasado de k unidades de tempo, $y(t-k)$. Caso disponham-se de N valores de uma série estacionária no tempo, $i = 1, \dots, N$, podem-se montar $N - k$ pares $[y(t), y(t+k)]$, $t = 1, \dots, N - k$. E o coeficiente de correlação é dado por:

$$r(k) = \frac{1}{\sigma_y^2} \frac{1}{N - k} \sum_{t=1}^{N-k} (y(t) - \mu_y)(y(t+k) - \mu_y) \quad (12)$$

Onde:

$r(k)$ – coeficiente de correlação para o atraso k ;

$y(t)$ – valor da série no instante t ;

σ_y – desvio padrão da série y ;

N – quantidade de valores em uma série estacionária;

k – quantidade de unidades de tempo referente ao atraso;

μ_y – valor médio da série y ;

Analogamente, a correlação cruzada entre duas séries temporais $x(t)$ e $y(t)$ estacionárias no tempo mede a correlação entre a variável y tomada no instante atual, $y(t)$, e a variável x tomada com um atraso de k unidades de tempo, $x(t-k)$. Desta forma:

$$r(k) = \frac{1}{\sigma_x \sigma_y} \frac{1}{N-k} \sum_{t=1}^{N-k} (x(t) - \mu_x)(y(t+k) - \mu_y) \quad (13)$$

Onde:

$r(k)$ – coeficiente de correlação para o atraso k ;

$y(t)$ – valor da série y no instante t ;

$x(t)$ – valor da série x no instante t ;

σ_y – desvio padrão da série y ;

σ_x – desvio padrão da série x ;

N – quantidade de valores em uma série estacionária;

k – quantidade de unidades de tempo referente ao atraso;

μ_x – valor médio da série x ;

μ_y – valor médio da série y ;

Várias análises foram realizadas a fim de encontrar um meio eficiente de identificar as correlações significativas presentes entre as séries estudadas. Entretanto, em função das fracas correlações existentes, das mesmas serem variantes no tempo e do tamanho do período em que as correlações são estatisticamente significativas, muitas das análises obtiveram resultados insatisfatórios¹.

Dentre os métodos estudados, o critério eleito para esta pesquisa baseou-se na geração de séries atrasadas de k dias ($k \leq 20$) para cada um dos indicadores disponíveis, sendo cada uma dessas séries atrasadas utilizada para estimar a correlação com a série objetivo. Essa correlação era estimada de forma seqüencial, cumulativa e bidirecional, ou seja, percorriam-se as séries sequencialmente em ambos os sentidos e, a cada nova amostra incluída na análise, era realizada uma nova estimativa da correlação.

¹ Dentre as análises pode-se citar:

- Estudo da correlação cruzada e da autocorrelação compreendendo o período completo de análise;
- Estudo da correlação cruzada e da autocorrelação do cubo das séries compreendendo o período completo de análise, a fim de ressaltar as grandes variações;
- Estudo da correlação cruzada e da autocorrelação compreendendo faixas de amplitude da série objetivo, a fim de verificar se há alguma relação entre a amplitude da variação e as entradas envolvidas;
- Estudo da correlação cruzada e da autocorrelação compreendendo faixas de tempo da série objetivo, a fim de verificar a volatilidade das correlações;

A fim de serem analisadas as volatilidades destas correlações, dividiram-se as séries em cinco segmentos de um ano¹, 08/2000, 08/2001, 08/2003, 08/2002 e 08/2004. Desta forma, a análise foi realizada para o período completo em cada sentido e ao término dessa análise o processo era repetido retirando-se o primeiro ano considerado (08/2000 no sentido direto e 08/2004 no sentido inverso). O processo repetia-se até que apenas um ano restasse no conjunto de análise. Sendo assim, pode-se avaliar a influência do ano retirado na correlação residual que porventura houvesse ocorrido nos demais anos estudados.

Para facilitar a análise desses resultados apenas eram consideradas correlações que estivessem acima dos níveis de confiança estabelecidos em:

$$\pm 2\sigma = \pm \frac{2}{\sqrt{N}} \quad (14)$$

Onde:

σ – desvio padrão;

N – número de pares analisados;

Portanto, supondo a distribuição normal era garantido um limiar de confiança de 95,5 %, valor tipicamente utilizado. Para ilustrar o procedimento descrito acima, podemos observar as figuras exibidas a seguir:




Figura 68: Correlação Fechamento IBOVESPA em Sentido Direto do Período Completo.

¹ Optou-se por períodos de um ano completo para manter o *trigger* de início e fim do período em análise sempre nos mesmos meses.

Na figura anterior, a correlação é avaliada em relação à própria série de retornos do fechamento do IBOVESPA em sentido direto, dispondo dos cinco anos para análise. Observa-se a presença de correlação para os seguintes atrasos: 0, -9, -10, -15 e -16 dias. Para verificar se as correlações observadas sofrem um efeito residual de alguma correlação presente apenas no primeiro ano, faz-se a análise novamente desconsiderando o ano em questão e o resultado pode ser visto na figura a seguir:




Figura 69: Correlação Fechamento IBOVESPA em Sentido Direto de Três Anos.

Neste caso, há duas conclusões que podem ser feitas: a correlação devia-se unicamente ao ano retirado ou o período em análise não era extenso o suficiente para que o coeficiente de correlação superasse o limiar de confiança.

Esse procedimento foi repetido de forma sucessiva e em seguida foi realizada a análise em sentido inverso. Maiores explicações do processo e os resultados gráficos obtidos podem ser acompanhados no Apêndice III.

A partir desses resultados observou-se que o período de análise deveria ser reduzido em função de haver correlações variantes no tempo. Portanto, foi arbitrado que o período utilizado para o desenvolvimento do preditor compreenderia apenas o último ano em análise.

IV.5. Seleção de Variáveis

Através da análise dos resultados gráficos dispostos no Apêndice III, foi feita a seleção dos indicadores atrasados que passariam a compor o conjunto das entradas do sistema. Como o período de análise foi restringido apenas ao último ano do conjunto de dados, de 22/08/2003 a 22/08/2004, a escolha das variáveis de entrada da rede foi

baseada principalmente na análise dos resultados quando, em sentido direto, apenas o último ano era exibido e quando, em sentido inverso, os cinco anos eram exibidos. Assim sendo, os resultados em análise estavam isentos da interferência dos demais anos do conjunto inicial nos coeficientes de correlação, os demais gráficos foram utilizados para uma análise minuciosa em casos onde a escolha não estivesse clara.

Selecionaram-se somente os indicadores atrasados cujas correlações mantiveram-se estatisticamente significativas por boa parte do período e cujas correlações indicaram uma tendência a influenciar a série objetivo em períodos futuros. Assim, o conjunto de variáveis de entrada determinado pode ser visto nas tabelas 5 e 6.

Tabela 5: Atrasos Considerados para Indicadores Econômicos

Indicador	Atraso (dias)
Fechamento IBOVESPA	10
Abertura IBOVESPA	9
Mínimo IBOVESPA	12
Máximo IBOVESPA	9 e 10
Fechamento NASDAQ	18
Fechamento Merval	1 e 6
Fechamento PTAX	9 e 11
Fechamento S&P	1
Fechamento IBX	10
Fechamento DIxPRE180	11
Fechamento DIxPRE360	11
Fechamento Yen	20
Fechamento Dólar	11

Tabela 6: Atrasos Considerados para Indicadores Calculados

Indicador	Atraso (dias)
Δ Diária IBOVESPA	10
Δ Noturna IBOVESPA	9 e 19

Vale ressaltar, que, inicialmente, foram realizados estudos a fim de descorrelacionar as variáveis de entrada, mas estes estudos não se mostraram tão eficientes quanto a análise de relevância das mesmas após o treinamento da rede.

V. ESTUDO DA SÉRIE DO IBOVESPA

V.1. Rede Neural

Utilizando-se as variáveis de entrada definidas no capítulo anterior, foi projetada uma rede neural de duas camadas com neurônios do tipo tangente hiperbólica na camada intermediária e um único neurônio linear na camada de saída. Adotou-se o método do gradiente descendente cuja função de otimização foi definida como o EMQ e cujo passo de treinamento foi definido em 0,01.

O conjunto de dados de 08/2003 a 08/2004 foi dividido em três subconjuntos distintos, treinamento, validação e teste. A definição desses subconjuntos foi realizada de forma aleatória através da validação cruzada do conjunto de dados inicial. Onde, cinco subconjuntos¹, com 20 % das amostras cada um, foram combinados em dois conjuntos com 20 % cada (validação e teste) e um conjunto com 60 % das amostras (treinamento).

Dessa forma, vinte possíveis combinações foram definidas para serem utilizadas como diferentes cenários dos parâmetros de entrada da rede neural, sendo selecionadas as cinco melhores através da análise simultânea dos coeficientes de regressão entre as saídas prevista e real para os conjuntos de validação e teste². O coeficiente de regressão é definido como:

$$r = \frac{1}{N-1} \frac{\sum_{t=1}^N (y(t) - \mu_y)(\tilde{y}(t) - \mu_{\tilde{y}})}{\sigma_y \sigma_{\tilde{y}}} \quad (15)$$

Onde:

r – coeficiente de regressão: assume valores entre $[-1, 1]$;

N – total de amostras contidas em y ;

y – saída esperada;

¹ A distribuição dos dados nestes cinco subconjuntos foi realizada de forma aleatória, entretanto os dados foram sendo subdivididos por faixas de valores a fim de se obter distribuições similares em cada um dos subconjuntos.

² Este processo de otimização foi utilizado em todos os casos necessários no desenvolvimento deste sistema. A opção por não se realizar o processo de otimização através do EMQ, se baseia no fato deste processo não ter apresentado grande ênfase ao acerto de polaridade.

- \tilde{y} – saída prevista pela rede;
- μ_y – valor médio da saída esperada;
- $\mu_{\tilde{y}}$ – valor médio da saída prevista;
- σ_y – desvio padrão da saída esperada;
- $\sigma_{\tilde{y}}$ – desvio padrão da saída prevista;

O valor médio das saídas das cinco redes selecionadas foi utilizado como o valor de saída do sistema de previsão. Desta forma, obtém-se um resultado menos suscetível a falhas na previsão de polaridade.

Os conjuntos de dados de entrada antes de serem apresentados à rede neural foram submetidos a um processo de normalização, no qual era feita a retirada do valor médio e a normalização pelo desvio padrão de cada uma das séries¹.

Além dessa normalização dos dados, no pré-processamento os subconjuntos de treinamento e validação² tiveram suas distribuições equalizadas através da reamostragem aleatória dos intervalos de baixas concentrações. Desta forma garante-se um treinamento igualitário sem que regiões mais concentradas sejam mais bem treinadas em detrimento das demais.

Foi analisada a equalização das distribuições subdividindo-se os conjuntos por duas faixas de valores, 0,5 e 1 desvio padrão, e os resultados podem ser observados a seguir:

¹ Outro processo de normalização pelo valor máximo e mínimo também foi experimentado, mas o processo adotado obteve melhores resultados.

² Somente foi aplicado o procedimento aos conjuntos de treinamento e validação em função de ambos fazerem parte do treinamento da rede.

Tabela 7: Performance da Rede com Distribuições Equalizadas

Faixas (Desvio Padrão)	Coeficiente de Regressão	
	Validação	Teste
0	0,38	0,32
0,5	0,40	0,35
1	0,39	0,33

Pela análise dos resultados obtidos optou-se por realizar a equalização da distribuição a cada 0,5 desvio padrão.

A quantidade de neurônios a serem dispostos na camada intermediária foi definida de forma empírica através do treinamento e simulação das redes para quantidades pré-estabelecidas (tabela 8).

Tabela 8: Performance das Redes por Número de Neurônios na Camada Intermediária

Neurônio(s)	Coeficiente de Regressão	
	Validação	Teste
1	0,40	0,35
2	0,42	0,36
3	0,40	0,35
4	0,39	0,34
5	0,39	0,33
10	0,38	0,32
15	0,35	0,32
20	0,38	0,31
50	0,37	0,29

Pelos resultados obtidos, pode-se observar que a relação das variáveis de entrada com a série objetivo aproxima-se de um mapeamento linear e que com apenas um neurônio na camada intermediária obtém-se uma boa resposta do sistema. Isto se deve em parte ao fato das variáveis de entrada e da série objetivo terem sido convenientemente submetidas a uma transformação não linear no processo de geração

das séries de retornos. Para manter uma certa capacidade não linear à rede optou-se em utilizar dois neurônios na camada intermediária.

V.2. Relevância

Para avaliar a relevância das entradas da rede neural definidas no processo de seleção de variáveis é adotado o seguinte procedimento:

- Treinam-se as redes com todas as variáveis de entrada disponíveis;
- Simula-se a saída da mesma para os conjuntos de validação e teste;
- Treinam-se novas redes retirando-se, alternadamente, cada uma das entradas;
- Obtêm-se o coeficiente para aferir a eficiência da variável ausente dado através do EMQ entre a saída obtida com todas as variáveis e a saída obtida com a ausência da variável em análise. Para variáveis relevantes esta diferença deve ser grande;
- Ao término da varredura, elimina-se a variável menos relevante observada na análise;
- Reinicia-se o processo até que todas as variáveis de entrada tenham sido eliminadas;

Para cada uma das variáveis eliminadas foram armazenados os coeficientes de desempenho das redes neurais e os resultados dos primeiros doze passos podem ser vistos na tabela a seguir:

Tabela 9: Análise de Relevância

Passo	Coeficiente de Regressão	
	Validação	Teste
1	0,43	0,36
2	0,42	0,36
3	0,42	0,37
4	0,44	0,39
5	0,45	0,39
6	0,46	0,39
7	0,45	0,38
8	0,45	0,41
9	0,44	0,42
10	0,45	0,40
11	0,45	0,39
12	0,43	0,39

Pela análise dos resultados acima e pela análise concomitante dos demais conjuntos de dados e indicadores de performance, optou-se por finalizar a análise de relevância no quinto passo e, portanto, as variáveis de entrada da rede foram redefinidas, sendo apresentadas na tabela 10.

:

Tabela 10: Séries de Retornos Relevantes

Indicador	Atraso (dias)
Fechamento IBOVESPA	10
Mínimo IBOVESPA	12
Máximo IBOVESPA	10
Fechamento NASDAQ	18
Fechamento Merval	1 e 6
Fechamento PTAX	9 e 11
Fechamento S&P	1
Fechamento IBX	10
Fechamento DlxPRE180	11
Fechamento Dólar	11
Δ Notuma IBOVESPA	9 e 19

Pode-se constatar que apenas dois indicadores selecionados são atrasados por apenas um dia (Merval e S&P) e que, caso a previsão seja realizada descartando-se os mesmos, essa poderia ser feita com seis dias de antecedência. Portanto, ambos os cenários foram considerados nos resultados descritos na seção seguinte e com esse objetivo foram implementados dois preditores distintos.

V.3. Resultados

Nesta seção, serão expostos os principais resultados obtidos pelo sistema. Como visto anteriormente, apesar do foco inicial da pesquisa ser prever o valor da cotação do Fechamento do IBOVESPA de $D+1$, este foco foi sendo alterado no decorrer da pesquisa e as análises do desempenho do preditor estão voltadas para a correta previsão da variação em relação à cotação em $D+0$, sendo a polaridade desta variação o principal foco de estudo¹.

¹ Ignorando-se os custos de corretagem, ao garantir o acerto na polaridade da variação, garante-se que capital não será perdido, independentemente da amplitude desta variação.

V.3.1. Cenário I

Neste cenário, são considerados os indicadores atrasados de apenas um dia na geração do preditor, sendo que as performances das cinco melhores redes consideradas no processo de validação cruzada, utilizadas para compor a resposta final do sistema, são exibidas na tabela 11, 12 e 13. Para essas cinco redes, a performance foi avaliada em relação ao EMQ, ao percentual de acerto de sinal e ao coeficiente de regressão nos conjuntos de validação, teste e aplicação (composto pelos três meses subsequentes ao período em análise). Esses resultados foram analisados em subconjuntos de pequenas e grandes variações em relação ao valor predito, cujos limiares foram compostos a partir dos percentis de 25, 50 e 75 %.

Tabela 11: Cenário I – Performance das Redes em EMQ

Rede	EMQ (x 10 ⁻⁴)								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Teste	Aplic.
1	2,56	2,11	2,20	0,65	0,56	0,72	4,40	3,61	3,81
2	2,65	2,53	2,09	0,62	0,75	0,55	4,61	4,25	3,77
3	2,81	2,58	2,02	7,98 [‡]	1,28	0,62	4,74	4,12	3,53
4	2,25	3,01	2,31	1,25	1,96	1,33	3,22	4,26	3,37
5	2,38	2,63	2,13	0,79	0,86	0,66	4,27	4,34	3,72
Média¹	2,53	2,57	2,15	0,82	1,08	0,78	4,25	4,12	3,64
D. P.	0,22	0,32	0,11	0,25	0,56	0,32	0,60	0,30	0,18

¹ Estimado através do valor médio dos resultados das cinco redes separadamente, portanto é um indicativo do comportamento médio das redes escolhidas. Nada tem a ver com a saída final do preditor proposta, composta pelo valor médio da saída das cinco redes.

Tabela 12: Cenário I – Performance das Redes em % Acerto Sinal

Rede	% Acerto Sinal								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Teste	Aplic.
1	64,7 %	64,7 %	64,6 %	60,0 %	64,0 %	60,0 %	69,2 %	65,4 %	69,6 %
2	60,8 %	60,8 %	64,6 %	52,0 %	52,0 %	56,0 %	69,2 %	69,2 %	73,9 %
3	68,6 %	71,9 %	68,8 %	60,0 %	74,2 %	64,0 %	76,9 %	69,2 %	73,9 %
4	66,7 %	63,2 %	64,6 %	68,0 %	58,1 %	60,0 %	65,4 %	69,2 %	69,6 %
5	71,9 %	54,9 %	64,6 %	71,0 %	44,0 %	56,0 %	73,1 %	65,4 %	73,9 %
Média	66,5 %	63,1 %	65,4 %	62,2 %	58,5 %	59,2 %	70,8 %	67,7 %	72,2 %
D. P.	4,2 %	6,2 %	1,9 %	7,5 %	11,5 %	3,4 %	4,4 %	2,1 %	2,4 %

Tabela 13: Cenário I – Performance das Redes em Coeficientes de Regressão

Rede	Coeficientes de Regressão								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Aplic.	Prev.
1	0,53	0,59	0,29	0,15	0,27	0,15	0,69	0,66	0,39
2	0,42	0,43	0,34	0,04	-0,14	0,09	0,55	0,61	0,46
3	0,42	0,36	0,38	0,20	0,19	0,12	0,60	0,55	0,47
4	0,53	0,35	0,31	0,23	0,09	-0,09	0,66	0,50	0,50
5	0,39	0,41	0,32	0,31	-0,13	0,05	0,56	0,55	0,42
Média	0,46	0,43	0,33	0,19	0,06	0,07	0,61	0,57	0,45
D. P.	0,07	0,10	0,03	0,10	0,19	0,09	0,06	0,06	0,05

Esses resultados mostram de maneira clara a dispersão da performance de cada uma das redes utilizadas no processo. Desta forma, pode-se inferir que o processo mostra-se muito mais estável para as predições nas faixas de altas variações e que se analisando o conjunto de dados como um todo, o sistema apresenta bons resultados.

Como visto anteriormente, a saída do sistema é determinada pelo valor médio das cinco redes expostas acima, porém, como os subconjuntos de treinamento, validação e teste de cada uma das redes são compostos por um sorteio aleatório da

mesma massa de dados, cada um deles em cada rede possuem dados distintos e não podem ser analisados como um único subconjunto. Em consequência, a análise destes subconjuntos foi agrupada em um conjunto geral, que continha todos os dados disponíveis a exceção dos dados do conjunto de aplicação.

O desempenho da saída média das redes em relação ao acerto de sinal pode ser observado nas tabelas a seguir:

Tabela 14: Cenário I – % Acerto Sinal por Faixa de Previsão da Saída Rede

Faixa	% Acerto Sinal	
	Geral	Aplicação
Grandes Δ Negativas	72 %	80 %
Pequenas Δ Negativas	70 %	25 %
Pequenas Δ Positivas	61 %	69 %
Grandes Δ Positivas	82 %	71 %

Tabela 15: Cenário I – % Acerto Sinal por Faixa de Real da Saída Rede

Faixa	% Acerto Sinal	
	Geral	Aplicação
Grandes Δ Negativas	61 %	73 %
Pequenas Δ Negativas	46 %	25 %
Pequenas Δ Positivas	75 %	63 %
Grandes Δ Positivas	91 %	85 %

Comparativamente foi feita a mesma análise de acerto de sinal considerando um modelo ingênuo, onde a melhor previsão para a data de amanhã seria a que ocorreu hoje e os resultados podem ser vistos nas tabelas a seguir:

Tabela 16: Cenário I – % Acerto Sinal por Faixa de Previsão do Modelo Ingênuo

Faixa	% Acerto Sinal	
	Genal	Aplicação
Grandes Δ Negativas	41 %	60 %
Pequenas Δ Negativas	51 %	40 %
Pequenas Δ Positivas	55 %	60 %
Grandes Δ Positivas	56 %	30 %

Tabela 17: Cenário I – % Acerto Sinal por Faixa de Real do Modelo Ingênuo

Faixa	% Acerto Sinal	
	Genal	Aplicação
Grandes Δ Negativas	58 %	50 %
Pequenas Δ Negativas	30 %	22 %
Pequenas Δ Positivas	58 %	68 %
Grandes Δ Positivas	52 %	38 %

Pela comparação dos resultados obtidos para o modelo ingênuo pode-se verificar a eficiência do predito desenvolvido. Em forma analítica, analisou-se o percentual de acerto de sinal em relação aos valores previstos e reais. Essa análise foi realizada de forma cumulativa e por polaridade, percorrendo-se as faixas de valores em sentido do módulo decrescente. Os resultados são apresentados abaixo:




Figura 70: Cenário I – Conjunto Geral – % Acerto Sinal por Faixa de Previsão.




Figura 71: Cenário I – Conjunto Geral – % Acerto Sinal por Faixa de Real.




Figura 72: Cenário I – Conjunto Aplicação – % Acerto Sinal por Faixa de Previsão.




Figura 73: Cenário I – Conjunto Aplicação – % Acerto Sinal por Faixa de Real.

Pode-se verificar uma boa performance da mesma nas faixas de grandes variações, que são as faixas de maior interesse na previsão. Verifica-se também que para o conjunto de aplicação a performance não é tão boa para as grandes variações negativas, mas que mantém-se boa parte do tempo bem acima de 50 %. Esse fato deve-se em parte por este período se caracterizar por um período de alta do índice e, portanto,

as quedas do IBOVESPA não estão bem representadas no subconjunto, aproximadamente 40 % dos casos. A relação entre a saída prevista e a saída real para os dois conjuntos pode ser observada nas figuras a seguir:




Figura 74: Cenário I – Conjunto Geral – Saída Real x Prevista.




Figura 75: Cenário I – Conjunto Aplicação – Saída Real x Prevista.

V.3.2. Cenário II

No segundo cenário, descartaram-se os indicadores atrasados de apenas um dia e, portanto, as variações da bolsa poderiam ser previstas com seis dias de antecedência. Os resultados obtidos das cinco melhores redes consideradas no processo de validação cruzada são exibidos nas tabelas 16, 17 e 18.

Tabela 18: Cenário II – Performance das Redes em EMQ

Rede	EMQ ($\times 10^{-4}$)								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Teste	Aplic.
1	2,75	2,58	2,16	0,47	0,90	0,69	4,94	4,20	3,77
2	2,61	2,85	2,28	0,76	0,52	0,72	4,40	5,10	3,98
3	2,86	2,67	2,25	0,50	0,74	0,69	5,12	4,52	3,96
4	2,85	2,95	2,24	0,67	0,58	0,64	4,95	5,23	3,97
5	3,03	2,56	2,01	0,11	0,46	0,56	4,89	5,06	3,59
Média	2,82	2,72	2,19	0,70	0,64	0,66	4,86	4,82	3,85
D. P.	0,15	0,17	0,11	0,25	0,18	0,06	0,27	0,44	0,17

Tabela 19: Cenário II – Performance das Redes em % Acerto Sinal

Rede	% Acerto Sinal								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Teste	Aplic.
1	70,6 %	56,9 %	56,3 %	64,0 %	36,0 %	52,0 %	76,9 %	76,9 %	60,9 %
2	58,8 %	64,7 %	54,2 %	36,0 %	60,0 %	44,0 %	80,8 %	69,2 %	65,2 %
3	64,7 %	64,7 %	56,3 %	56,0 %	48,0 %	48,0 %	73,1 %	80,8 %	65,2 %
4	62,7 %	60,8 %	60,4 %	60,0 %	64,0 %	52,0 %	65,4 %	57,7 %	69,6 %
5	68,6 %	68,4 %	64,6 %	68,0 %	71,0 %	60,0 %	69,2 %	65,4 %	69,6 %
Média	65,1 %	63,1 %	58,3 %	56,8 %	55,8 %	51,2 %	73,1 %	70,0 %	66,1 %
D. P.	4,7 %	4,4 %	4,2 %	12,5 %	13,9 %	5,9 %	6,1 %	9,2 %	3,6 %

Tabela 20: Cenário II – Performance das Redes em Coeficientes de Regressão

Rede	Coeficientes de Regressão								
	Completo			Pequenas Δ			Grandes Δ		
	Val.	Teste	Aplic.	Val.	Teste	Aplic.	Val.	Aplic.	Piev.
1	0,42	0,45	0,30	0,40	-0,08	-0,03	0,49	0,64	0,40
2	0,47	0,36	0,23	-0,07	0,09	-0,11	0,73	0,44	0,33
3	0,37	0,44	0,24	0,10	-0,06	-0,06	0,45	0,66	0,35
4	0,38	0,30	0,25	0,23	-0,03	-0,10	0,46	0,38	0,33
5	0,32	0,31	0,38	0,17	0,39	0,13	0,51	0,36	0,49
Média	0,39	0,37	0,28	0,17	0,06	-0,03	0,53	0,50	0,38
D. P.	0,06	0,07	0,06	0,17	0,19	0,09	0,12	0,14	0,07

Pela análise dos resultados deste cenário, pode-se concluir que não há uma perda significativa na performance de acerto de sinal, entretanto ao analisar o EMQ e o coeficiente de regressão o mesmo não pode ser afirmado, indicando uma piora representativa na previsão do módulo da série. Pode-se inferir que o processo ainda se mostra mais estável para as previsões nas faixas de altas variações.

O desempenho em acerto de sinal determinado pelo valor médio da saída das cinco redes pode ser observado nas tabelas a seguir:

Tabela 21: Cenário II – % Acerto Sinal por Faixa de Previsão da Saída Rede

Faixa	% Acerto Sinal	
	Genl	Aplicação
Grandes Δ Negativas	71 %	57 %
Pequenas Δ Negativas	46 %	33 %
Pequenas Δ Positivas	64 %	44 %
Grandes Δ Positivas	72 %	85 %

Tabela 22: Cenário II – % Acerto Sinal por Faixa de Real da Saída Rede

Faixa	% Acerto Sinal	
	Genal	Aplicação
Grandes Δ Negativas	62 %	45 %
Pequenas Δ Negativas	52 %	38 %
Pequenas Δ Positivas	68 %	50 %
Grandes Δ Positivas	75 %	77 %

Em forma analítica e cumulativa tem-se:




Figura 76: Cenário II – Conjunto Geral – % Acerto Sinal por Faixa de Previsão.




Figura 77: Cenário II – Conjunto Geral – % Acerto Sinal por Faixa de Real.




Figura 78: Cenário II – Conjunto Aplicação – % Acerto Sinal por Faixa de Previsão.




Figura 79: Cenário II – Conjunto Aplicação – % Acerto Sinal por Faixa de Real.

Verifica-se uma piora na performance da rede neste cenário, incluindo períodos onde o percentual de acerto de sinal encontra-se abaixo de 50 %. A relação entre a saída prevista e a saída real para os dois conjuntos pode ser observada nas figuras a seguir:




Figura 80: Cenário II – Conjunto Geral – Saída Real x Prevista.




Figura 81: Cenário II – Conjunto Aplicação – Saída Real x Prevista.

V.4. Aplicação

Para validar os resultados exibidos na seção anterior, foi realizada uma simulação de uma aplicação, supondo a existência de papéis na bolsa que possuíssem resultados semelhantes ao IBOVESPA¹. Essa simulação foi realizada utilizando-se os três últimos meses do conjunto em análise e considerando-se uma taxa de emolumentos em 0,035 %.

Para tal, consideraram-se somente as previsões de grandes variações, movimentando-se todo o montante sempre em que fosse prevista uma queda ou alta do índice pela correspondente venda ou compra de papéis. Obviamente, assumiu-se que sempre se conseguiria realizar as operações desejadas. Devido à grande variedade de taxas de corretagens cobradas no mercado, optou-se por realizar a simulação para quatro possíveis valores, 0,05 %, 0,30 %, 0,50 % e 1,00 %, sendo o primeiro e o último considerados casos extremos, cujo montante envolvido é muito alto ou muito baixo, respectivamente.

¹ Para o IBx 50, por exemplo, há os PIBBs que visam buscar resultados semelhantes à performance do índice e são admitidos para negociação na Bovespa do mesmo modo que qualquer outro valor mobiliário nela negociado.

Considerou-se ainda que o volume do montante aplicado não fosse capaz de alterar os resultados do índice. Os resultados obtidos podem ser vistos de forma numérica na tabela 21 ou em forma gráfica na figura 82.

Tabela 23: Retornos das Aplicações por Taxa de Corretagem

Taxa de Corretagem	Retornos ao Final do Período	
	Absoluto	Sobre o IBOVESPA
0,05 %	27,55 %	12,13 %
0,30 %	22,86 %	8,01 %
0,50 %	19,25 %	4,83 %
1,00 %	10,70 %	-2,69 %

Comparativamente, os resultados para o modelo ingênuo aplicando-se somente nas grandes previsões podem ser vistos na tabela a seguir:

Tabela 24: Retornos das Aplicações por Taxa de Corretagem para o Modelo Ingênuo

Taxa de Corretagem	Retornos ao Final do Período	
	Absoluto	Sobre o IBOVESPA
0,05 %	1,86 %	-10,45 %
0,30 %	-1,63 %	-13,52 %
0,50 %	-4,34 %	-15,90 %
1,00 %	-10,76 %	-21,54 %




Figura 82: Retornos das Aplicações por Taxa de Corretagem.

Para taxas de corretagem menores que 1,00 %, os resultados apresentam retornos significativamente superiores ao crescimento do índice, caracterizando a aplicabilidade do sistema. Vale acrescentar que para este período foram realizadas compras em 16,7 % e vendas em 14,6 % dos casos.

V.5. Métodos Alternativos

Alguns processos alternativos foram testados, mas não obtiveram resultados significantes que justificassem seu detalhamento neste projeto de pesquisa, mas os mesmos são dispostos a seguir, pois podem vir a ser utilizados em outros períodos analisados.

V.5.1. Critérios de Otimização

Alguns outros critérios de otimização foram propostos, como otimização pelo erro médio quadrático e pelo percentual de acerto de sinal, mas optou-se por utilizar o coeficiente de regressão, como sendo um critério que considera com igual importância o acerto de polaridade e o acerto em módulo.

V.5.2. Módulo e Variância Predita do IBOVESPA como Parâmetros de Entrada da Rede

Dois outros estudos foram realizados adicionando-se duas novas variáveis às entradas da rede: o módulo obtido através do valor absoluto da série objetivo e a variância predita pelo modelo GARCH. Considerou-se o módulo da série neste estudo para simular a existência de um preditor de valor absoluto e justificar um futuro desenvolvimento.

Os resultados obtidos após o treinamento das redes com a inclusão desses parâmetros adicionais podem ser vistos na tabela 22.

Tabela 25: Resultados Comparativos - Módulo e Variância Predita do IBOVESPA

Entradas Adicionais	Coeficiente de Regressão	
	Validação	Teste
Nenhuma	0,42	0,37
Módulo	0,50	0,44
Variância	0,41	0,37
Módulo e Variância	0,50	0,42

Através dos resultados acima, pode-se constatar um melhora significativa ao acrescentar o módulo do IBOVESPA como um dos parâmetros de entrada da rede. Entretanto, a utilização da variância prevista pelo modelo GARCH não demonstrou ganho no desempenho do preditor. Em função disso, o estudo realizado e seus resultados detalhados foram suprimidos do corpo deste texto e encontram-se no Apêndice IV.

V.5.3. Componentes Principais

A idéia deste estudo era investigar as correlações entre as variáveis de entrada da rede e tentar transformar o conjunto de variáveis originais em um novo conjunto de variáveis não-correlacionadas. Essas novas variáveis seriam combinações lineares das variáveis originais e derivadas em ordem decrescente de importância na explicação da variabilidade total do sistema. Desta forma, poder-se-ia tentar reduzir o número de variáveis de entrada da rede mantendo praticamente a mesma quantidade de

informações relevantes. Entretanto, o mesmo não se mostrou eficaz e seus resultados podem ser vistos a seguir:

Tabela 26: Resultados Comparativos - Componentes Principais

% Mínimo de Informação Contida	Nº de Componentes	Coeficiente de Regressão	
		Validação	Teste
10 %	2	0,26	0,21
5 %	9	0,32	0,28
2 %	12	0,37	0,32
1 %	13	0,39	0,35
0,5 %	13	0,40	0,35
0 %	14	0,43	0,37

V.5.4. Fator de Correção de Erros de Polaridade do Processo de Treinamento para Grandes Variações

Foi proposta e testada a utilização de um fator de correção de erros de polaridade aplicado no cálculo da função de EMQ. Para cada um dos pares de entrada dessa função, que atendesse aos critérios estipulados de grandes variações definidos a seguir, era verificada a existência de erro de polaridade na previsão e, em caso afirmativo, procedia-se na aplicação de um fator incremental ao erro do par em questão.

Os critérios de definição de grandes variações foram estipulados de quatro formas distintas:

- Pares cujo valor real estivesse acima do percentil de 75 % ou abaixo do percentil de 25 %;
- Pares cujo valor estimado estivesse acima do percentil de 75 % ou abaixo do percentil de 25 %;
- Pares cujo valor real ou o estimado estivessem acima do percentil de 75 % ou abaixo do percentil de 25 %;
- Pares cuja diferença entre o valor real e o estimado estivesse acima do percentil de 75 % ou abaixo do percentil de 25 %.

O fator de correção poderia ser definido como um parâmetro do sistema ou de forma automática. Neste modo, o fator igualava o peso do EMQ de um único par ao total de pares onde o acerto havia sido alcançado.

Devido aos resultados não terem sido significativos, às diversas combinações das possibilidades descritas no processo e de terem sido testados diversos fatores de otimização os resultados foram muito extensos e, portanto, suprimidos deste documento.

V.5.5. Rede Especialista

Outro método tentado foi o treinamento de uma rede especialista que atuaria apenas nas grandes variações previstas pela rede principal, entretanto os resultados obtidos demonstraram que não há aumento justificável na eficiência do processo e podem ser vistos abaixo:

Tabela 27: Resultados Comparativos - Rede Especialista

Rede	% Aceito de Sinal	
	Geral	Previsão
Principal (Grandes Δ)	76 %	74 %
Especialista	78 %	74 %

V.5.6. Votação das Redes Neurais Geradas

Este processo consiste em, ao invés de se utilizar o valor médio das saídas das cinco redes propostas a partir da validação cruzada dos dados, se utilizar o critério de votação de sinal das cinco redes. Desta forma assume-se que os cinco valores previstos possuem o mesmo peso, independentemente, de suas amplitudes. Entretanto o resultado da rede passa a ser apenas a polaridade da série objetivo e esta não é a proposta deste estudo.

Os resultados obtidos podem ser vistos a seguir:

Tabela 28: Resultados Comparativos - Critério de Votação

Intervalos	% Acerto Sinal	
	Média	Votação
Grandes Variações Negativas	61 %	59 %
Pequenas Variações Negativas	46 %	46 %
Pequenas Variações Positivas	75 %	76 %
Grandes Variações Positivas	91 %	91 %

VI. CONCLUSÃO

Analisando as perspectivas existentes inicialmente, o panorama de mercado e todas as dificuldades previstas no início deste estudo, os resultados mostram-se bastante interessantes e motivadores, indicando a possibilidade de se utilizar o sistema na previsão de grandes variações com uma margem de acerto de polaridade em torno de 70 % dos casos.

Estes resultados foram ratificados na simulação de uma aplicação suposta no capítulo anterior, onde se conseguiu retornos absolutos de até 27 % (12 % superior ao retorno do IBOVESPA no mesmo período).

Alguns métodos adicionais podem e devem ser contemplados em estudos futuros, a fim de aumentar a robustez do processo de previsão e melhorar a performance do modelo desenvolvido. Dentre eles, podem-se destacar:

- Utilização de outras variáveis de mercado – além dos indicadores propostos neste trabalho, outros indicadores poderiam ser adicionados ao conjunto em análise, podendo desta forma melhorar a performance da rede. Nesta linha, poder-se-ia citar indicadores privados e tendências.
- Previsão do módulo do IBOVESPA – neste caso a série auto-contida mostra-se bastante correlata, indicado, portanto, a viabilidade de implementação deste sistema. Com esse preditor, poder-se-ia inferir com precisão os momentos em que o custo de operação do capital seriam inferiores ao valor arrecadado, além de melhorar significativamente a performance de previsão de sinal, conforme observado nos resultados deste estudo.
- Previsão de cotações *intra-day* do IBOVESPA – poder-se-ia realizar a previsão utilizando dados *intra-day* e, desta forma, realizar a previsão a um prazo ainda menor e indicando os melhores momentos para efetuar uma operação ao longo do dia;

VII. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] BLOOMBERG. Bloomberg Professional Software for Windows, 2006. Disponível em: <<http://www.bloomberg.com>>. Acesso em: dezembro 2004.
- [2] BOVESPA. Índice Bovespa - IBOVESPA. São Paulo, 2002. Disponível em: <<http://www.bovespa.com.br>>. Acesso em: novembro 2005.
- [3] SHENG, L., “A Fuzzy Neural Network Model for Forecasting Stock Price”. In: *The Forty-Sixth Meeting of the International Society for the Systems Sciences (ISSS)*, 2002-016, Shanghai, China, 2002.
- [4] HUI, S. C., YAP, M. T., PRAKASH, P. “A Hybrid Time Lagged Network for Predicting Stock Prices”, *International Journal of the Computer, the Internet and Management*, v. 8, n. 3, 2000.
- [5] ANÔNIMO, “A strategy for stock trading based on multiple models and trading rules”, Subramanian Ramamoorthy CS 395T, 5 de dezembro de 2003.
- [6] DIGGS, D. H., POVINELLI, R. J. “A Temporal Pattern Approach for Predicting Weekly Financial Time Series”. In: *Artificial Neural Networks in Engineering*, pp.707-712, St. Louis, Missouri, 2003.
- [7] SAAD, E.W., PROKHOROV, D.V., WUNSCH, D.C. “Advanced Neural Network Training Methods for Low False Alarm Stock Trend Prediction”, *Neural Networks, IEEE International Conference* v 4, pp. 2021-2026, 1996.
- [8] MIZUNO, H., KOSAKA, M., YAJIMA, H., et al., “Application of Neural Network to Technical Analysis of Stock Market Prediction”, *Studies in Informatics and Control*, v. 7, n. 3, pp.111-120, 1998.
- [9] KULKARNI, A. S., *Application of Neural Networks to Stock Market Prediction*, 1996.
- [10] TIMMERMANN A., GRANGER, C. W. J., “Efficient market hypothesis and forecasting”, *International Journal of Forecasting* v. 20, n. 1, pp. 15-27, 2004.
- [11] ATIYA, A. “Bankruptcy prediction for credit risk using neural networks: A survey and new results”, *IEEE Transactions on Neural Networks*, v. 12, n. 4, pp. 929-936, 2001.
- [12] WAH, B. W., QIAN, M., “Constrained formulations and algorithms for stock-price predictions using recurrent FIR neural networks”, *Eighteenth national conference on Artificial intelligence*, Edmonton, Alberta, Canadá, pp. 211-216, 2002.

- [13] MCCLUSKEY, P.C., *Feedforward and Recurrent Neural Networks and Genetic Programs for Stock Market and Time Series Forecasting*. M. Sc., Brown University, Department of Computer Science, Providence, Rhode Island, USA, 1993.
- [14] WONG, C. C., CHAN, M. C., LAM, C., *Financial Time Series Forecasting By Neural Network Using Conjugate Gradient Learning Algorithm And Multiple Linear Regression Weight Initialization*, Department of Computing, The Hong Kong Polytechnic University, Kowloon Hong Kong, 2000.
- [15] PANTAZOPOULOS, K. N., TSOUKALAS, L. H., BOURBAKIS, N. G., et al. "Financial prediction and trading strategies using neurofuzzy approaches", *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, v. 28, n. 4, pp. 520-531, 1998.
- [16] KUTSURELIS, J. E., *Forecasting financial markets using neural networks: an analysis of methods and accuracy*. M. Sc., US Naval Postgraduate School, Monterey, California, USA, 1998.
- [17] YAO, J. T., TAN, C. L., "Guidelines for financial forecasting with neural networks". *Proc. International Conference on Neural Information Processing*, Shanghai, China, pp. 757-761, 2001.
- [18] POVINELLI, R. J., "Identifying temporal patterns for characterization and prediction of financial time series events". In: *Proc. of the International Workshop on Temporal, Spatial and Spatio-Temporal Data Mining (TSDM'00)*, pp. 46-61, Lyon, France, 2000.
- [19] LENDASSE A., LEE, J., DE BODT, E., et al., "Input data reduction for the prediction of financial time series". In: *Proc. ESANN 2001, European Symposium on Artificial Neural Networks*, pp. 237-244, Bruges, Bélgica, Abril de 2001.
- [20] ABRAHAM, A., PHILIP, N. S., SARATCHANDRAN, P., "Modeling Chaotic Behavior of Stock Indices Using Intelligent Paradigms", *International Journal of Neural, Parallel & Scientific Computations*, v. 11, n. 1-2, pp. 143-160, 2003.
- [21] DUNIS, C. L., JALILOV, J. "Neural Network Regression and Alternative Forecasting Techniques for Predicting Financial Variables", *Neural Network World*, v. 12, n. 2, pp. 113-139, 2002.
- [22] SHAPIRO, A., "Capital Market Applications of Neural Networks, Fuzzy Logic and Genetic Algorithms", *Proceedings of the 13th International AFIR Colloquium*, v. 1, pp. 493-514, 2003.

- [23] GILES, C. L., LAWRENCE, S., TSOI, A. C., “Noisy Time Series Prediction using a Recurrent Neural Network and Grammatical Inference”, *Machine Learning*, v. 44, n. 1-2, pp. 161–183, 2001.
- [24] AMIN, T., GUAN, L., “Prediction of Financial Time Series Using Independent Component Analysis”, *Proceedings of 2nd. International Conference for Upcoming Engineers*, Toronto, 2003.
- [25] TAKAHO, H., ARAI, T., OTAKE, T., et al., “Prediction of the next stock price using neural network for data mining”, *Proc. of the International Symposium on Nonlinear Theory and its Applications (NOLTA)* pp. 411-414, Xi'an, 2002.
- [26] EGELI, B., ÖZTURAN, M., BADUR, B., “Stock Market Prediction Using Artificial Neural Networks”, *3rd Hawaii International Conference on Business Proceedings, Hawaii*, EUA, 2003.
- [27] NYGREN, K., *Stock prediction - a neural network approach*. M. Sc., Royal Institute of Technology, KTH, 2004.
- [28] Zorin, A., “Stock price prediction: Kohonen versus backpropagation”. *Proceedings of the International Conference “Modeling and Simulation of Business Systems”*, pp. 115-119, Vilnius, Lithuania, 2003.
- [29] Lawrence, R., *Using Neural Networks to Forecast Stock Market Prices*. Department of Computer Science, University of Manitoba, Canadá, 1997.
- [30] LEMOS, L., SOUZA, J., RAW, M., et al. “Aprendizagem Autônoma para Gerenciamento de uma Bolsa de Valores Simplificada”. In: *SBAI2001 - V Simpósio Brasileiro de Automação Inteligente*, Canela, Brasil, 2001.
- [31] CALOBA, L. P. “Introdução ao uso de Redes Neurais na Modelagem de Sistemas Dinâmicos e Séries Temporais”. In: *Aldayr Dantas. (Org.). Livro de Mini Cursos do XIV Congresso Brasileiro de Automática.*, 2002, Brasil.
- [32] Yim, J., *A comparison of neural networks with time series models for forecasting returns on a stock market*, RMIT Business Working Paper Series, WP 2002/07, 2002.
- [33] MORAIS, I. A. C., PORTUGAL, M. S., “Modelagem e Previsão de Volatilidade Determinística e Estocástica para a Série do Ibovespa”. *Estudos Econômicos (IPE/USP)*, Brasil, v. 29, n. 3, pp. 303-341, 1999.
- [34] BOLLERSLEV, T., ENGLE, R. F., NELSON, D. B., “ARCH Models”, *Handbook of Econometrics*, v. IV, capítulo 49, pp. 2959-3038, Elsevier Science B.V., 1994.

[35] CORREIA, M. M., *Memória Longa, Agrupamento de Valores Extremos e Assimetrias em Séries Financeiras*, Dissertação de Mestrado em Economia, FEA-USP, São Paulo, Brasil, Fevereiro de 1998.

[36] CALOBA, L. O. M., *Previsão de Volatilidade Implícita usando Redes Neurais*. Dissertação de M. Sc., COPPEAD/UFRJ, 2000.

APÊNDICE I – ESPECTRO EM FREQUÊNCIA

A análise do espectro em frequência das séries de retornos está disposta neste apêndice por ter resultados muito extensos e que não foram utilizados no processo. Estes resultados possibilitam a verificação de componentes senoidais e sazonalidade no conjunto de dados estudados. Foram estimadas as FFTs das séries de retornos e os resultados obtidos de fase e módulo, suprimida a componente DC das séries, podem ser vistos nos gráficos a seguir.

Não se notam frequências dominantes, mas sim um espectro “ruidoso” e quase uniforme. Um aspecto interessante é que algumas séries, e.g. a de Fechamento do IBOVESPA, parecem apresentar uma componente constante e significativa no atraso de grupo, $-d\theta/d\omega$. Estas duas características sugerem uma componente de atraso puro.




Figura 83: Componentes em Frequência Fechamento IBOVESPA




Figura 84: Componentes em Frequência Abertura IBOVESPA




Figura 85: Componentes em Frequência Mínimo IBOVESPA




Figura 86: Componentes em Frequência Máximo IBOVESPA




Figura 87: Componentes em Frequência Fechamento NASDAQ




Figura 88: Componentes em Frequência Fechamento BRACBOND




Figura 89: Componentes em Frequência Fechamento Dow Jones




Figura 90: Componentes em Freqüência Fechamento CDI




Figura 91: Componentes em Freqüência Fechamento Merval




Figura 92: Componentes em Freqüência Fechamento FTSE100




Figura 93: Componentes em Freqüência Fechamento PTAX




Figura 94: Componentes em Freqüência Fechamento S&P




Figura 95: Componentes em Freqüência Fechamento BX




Figura 96: Componentes em Frequência Fechamento DlxPRE180




Figura 97: Componentes em Frequência Fechamento DlxPRE360




Figura 98: Componentes em Frequência Fechamento DlxPRE540




Figura 99: Componentes em Frequência Fechamento DlxPRE720




Figura 100: Componentes em Frequência Fechamento Euro




Figura 101: Componentes em Frequência Fechamento Yen

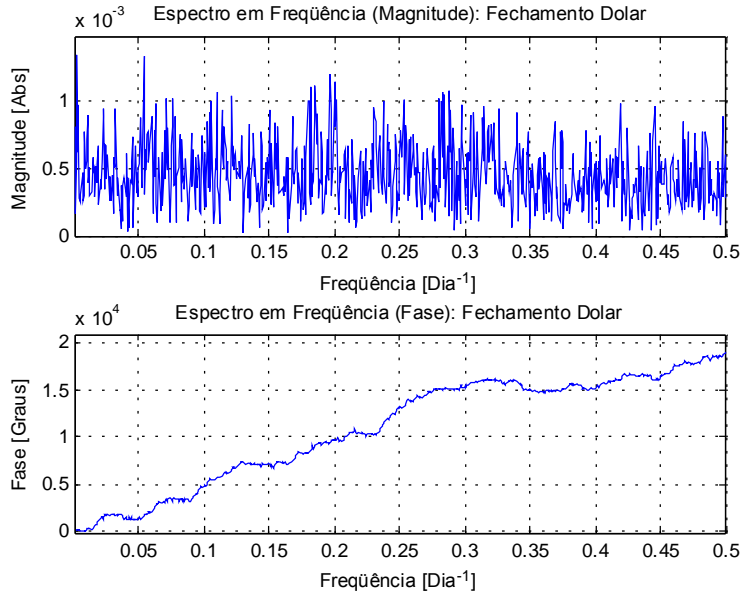


Figura 102: Componentes em Frequência Fechamento Dólar




Figura 103: Componentes em Frequência Variação Diária IBOVESPA




Figura 104: Componentes em Frequência Variação Noturna IBOVESPA




Figura 105: Componentes em Frequência Variação Máxima IBOVESPA

APÊNDICE II – RESULTADOS GRÁFICOS DOS PARÂMETROS DE DISTRIBUIÇÃO DAS SÉRIES DE RETORNOS

Para não poluir o corpo da tese, optou-se por disponibilizar os resultados gráficos dos parâmetros de distribuição das séries neste apêndice, sendo mantidos apenas os resultados numéricos no corpo principal do texto.

Quatro resultados gráficos foram gerados:

- *Boxplot* – representa os limites do quartil inferior, da mediana e do quartil superior, além de representar *outliers* caracterizados por valores superiores a três desvios padrões;
- Histograma – representa a distribuição dos dados, através da estimativa da quantidade de ocorrências de cada dado no conjunto em análise;
- Probabilidade de Distribuição Normal – representa a similaridade da distribuição com uma distribuição normal, através dos valores de cada percentil dos dados. Distribuições normais são caracterizadas por um comportamento linear;
- Função de Densidade Cumulativa – representa a proporção de valores de um conjunto X menores ou iguais a x ;

Os resultados estimados podem ser visualizados a seguir:







Figura 106: Distribuição Fechamento IBOVESPA

A análise dos resultados do Fechamento do IBOVESPA mostra uma distribuição bastante similar à distribuição normal, confirmada pelo coeficiente de curtose. O coeficiente ligeiramente negativo de assimetria indica que a distribuição possui sua cauda esquerda mais alongada que a direita, o que pode ser confirmado na figura 106. Pode-se ainda constatar que o valor médio e a mediana encontram-se ligeiramente positivos, indicativo de uma alta no período como um todo.

As demais séries não serão comentadas minuciosamente, mas foram analisadas e possuem seus resultados apresentados neste projeto de pesquisa.







Figura 107: Distribuição Abertura IBOVESPA







Figura 108: Distribuição Mínimo IBOVESPA







Figura 109: Distribuição Máximo IBOVESPA







Figura 110: Distribuição Fechamento NASDAQ







Figura 111: Distribuição Fechamento BRACBOND







Figura 112: Distribuição Fechamento Dow Jones







Figura 113: Distribuição Fechamento CDI







Figura 114: Distribuição Fechamento Merval







Figura 115: Distribuição Fechamento FTSE100







Figura 116: Distribuição Fechamento PTAX







Figura 117: Distribuição Fechamento S&P







Figura 118: Distribuição Fechamento IBX







Figura 119: Distribuição Fechamento DIXPRE180







Figura 120: Distribuição Fechamento DIXPRE360







Figura 121: Distribuição Fechamento DIXPRE540




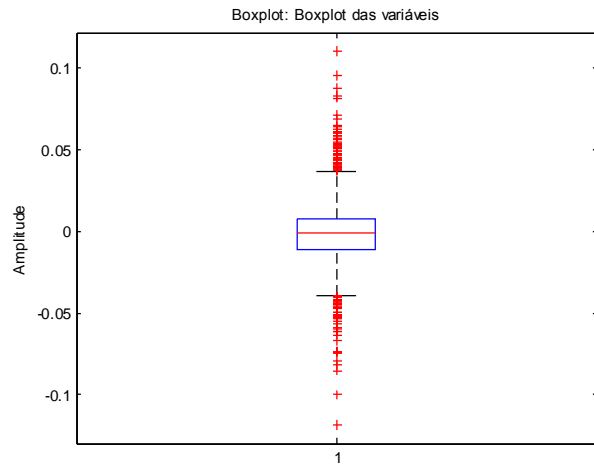


Figura 122: Distribuição Fechamento DIXPRE720







Figura 123: Distribuição Fechamento Euro







Figura 124: Distribuição Fechamento *Yen*







Figura 125: Distribuição Fechamento Dólar







Figura 126: Distribuição Variação Diária IBOVESPA







Figura 127: Distribuição Variação Noturna IBOVESPA







Figura 128: Distribuição Variação Máxima IBOVESPA

APÊNDICE III – RESULTADOS GRÁFICOS DAS CORRELAÇÕES DAS SÉRIES DE RETORNOS COMA SÉRIE OBJETIVO

A seguir são dispostos alguns resultados gráficos obtidos no processo de análise da correlação das séries de retorno com a série objetivo. Estas correlações foram estimadas de forma seqüencial e cumulativa a fim de verificar o período em que determinadas correlações mostraram-se significativas. Esta aproximação foi realizada em ambos os sentidos e o período analisado neste caso foi reduzido a cinco anos. A fim de verificar se algumas correlações deviam-se unicamente a um efeito residual de um ano específico, a mesma estimativa foi realizada sucessivamente com a retirada de cada ano em ambos os sentidos.

Além da análise das séries completas, outros estudos, como a análise da correlação apenas para subidas/descidas do IBOVESPA, a análise por grandes/pequenas variações e ainda a combinação das duas anteriores, foram realizados e seus resultados não são apresentados em função de não se ter observado uma melhora substancial com a sua utilização no processo.

Os resultados podem ser observados nas figuras a seguir:







Figura 129: Correlação Fechamento IBOVESPA em Sentido Direto.

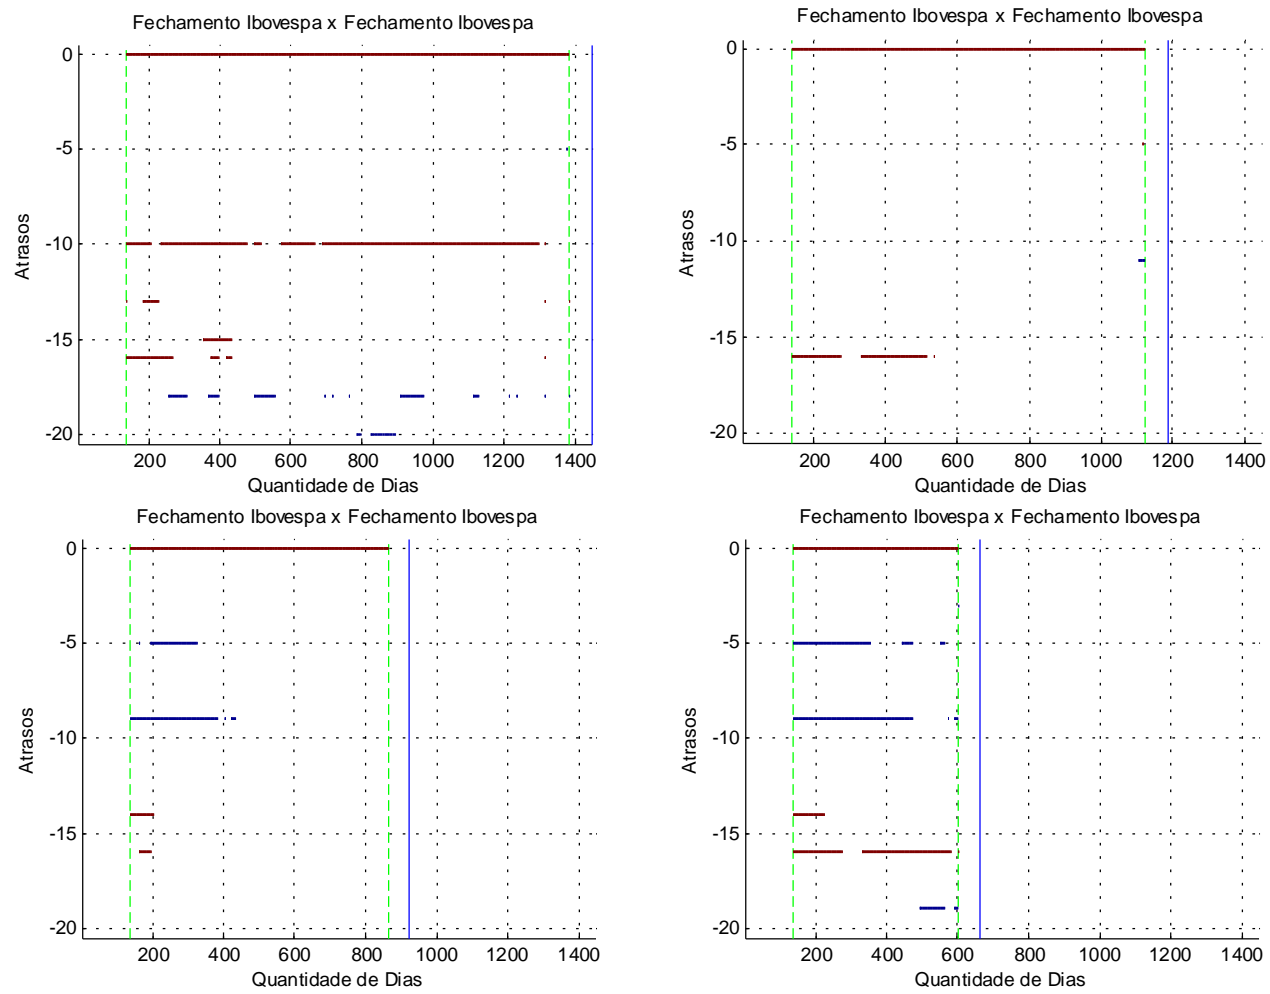


Figura 130: Correlação Fechamento IBOVESPA em Sentido Inverso.







Figura 131: Correlação Abertura IBOVESPA em Sentido Direto.







Figura 132: Correlação Abertura IBOVESPA em Sentido Inverso.







Figura 133: Correlação Mínimo IBOVESPA em Sentido Direto.

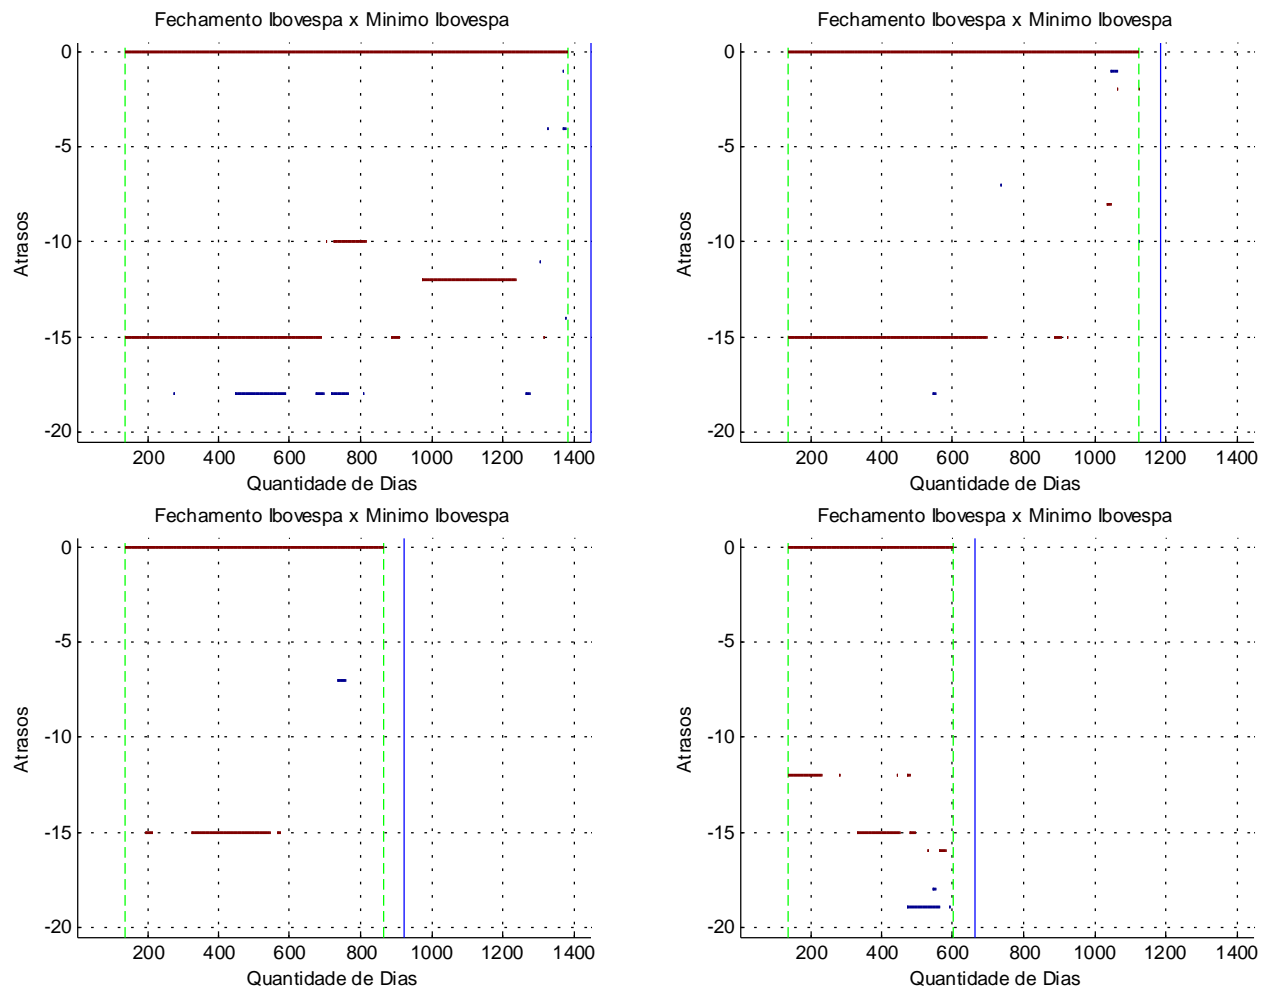


Figura 134: Correlação Mínimo IBOVESPA em Sentido Inverso.







Figura 135: Correlação Máximo IBOVESPA em Sentido Direto.







Figura 136: Correlação Máximo IBOVESPA em Sentido Inverso.







Figura 137: Correlação Fechamento NASDAQ em Sentido Direto.

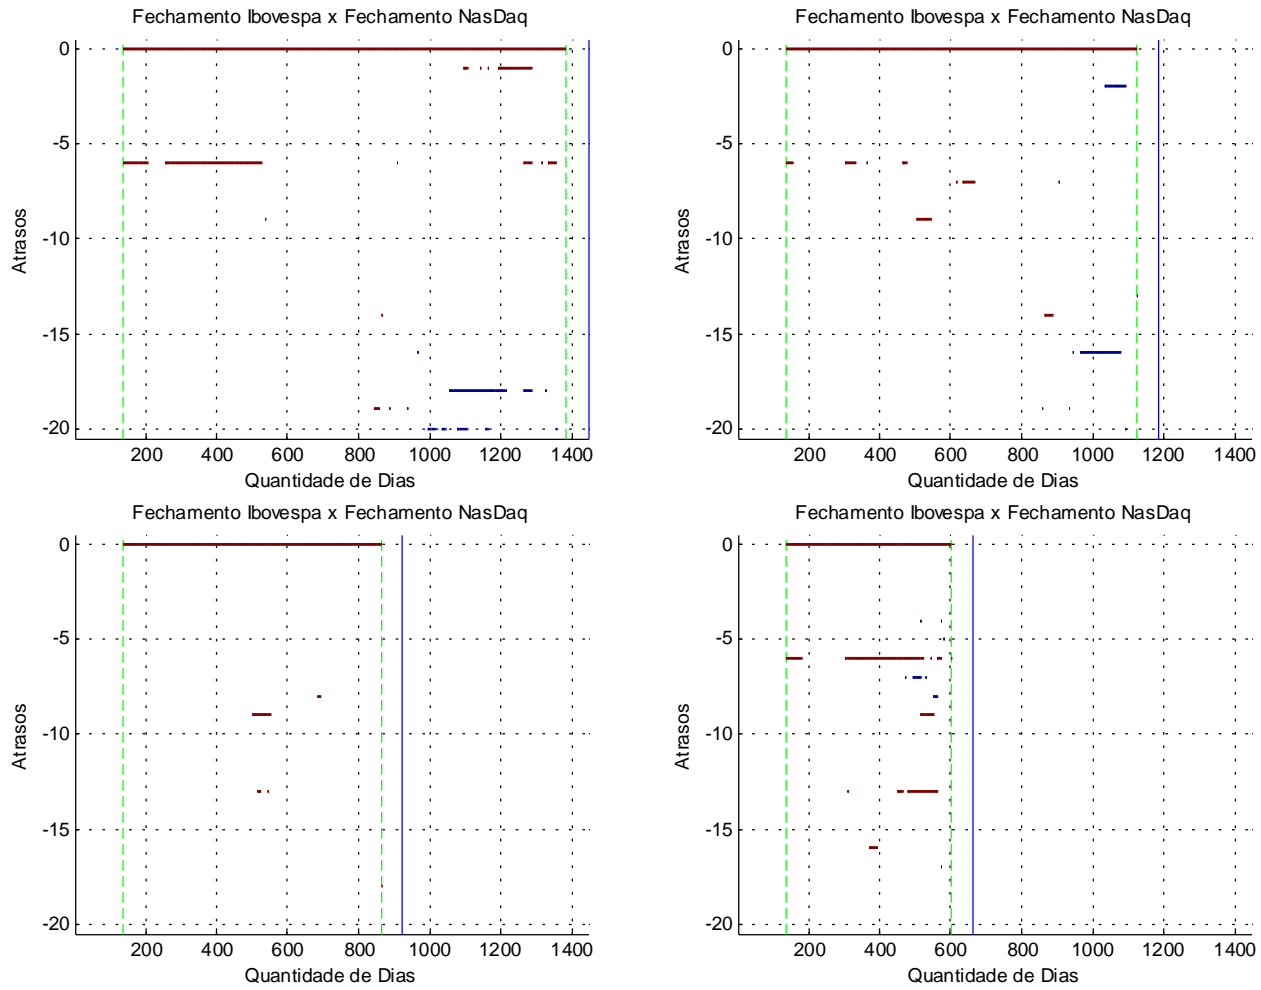


Figura 138: Correlação Fechamento NASDAQ em Sentido Inverso.







Figura 139: Correlação Fechamento Bracbond em Sentido Direto.







Figura 140: Correlação Fechamento Bracbond em Sentido Inverso.



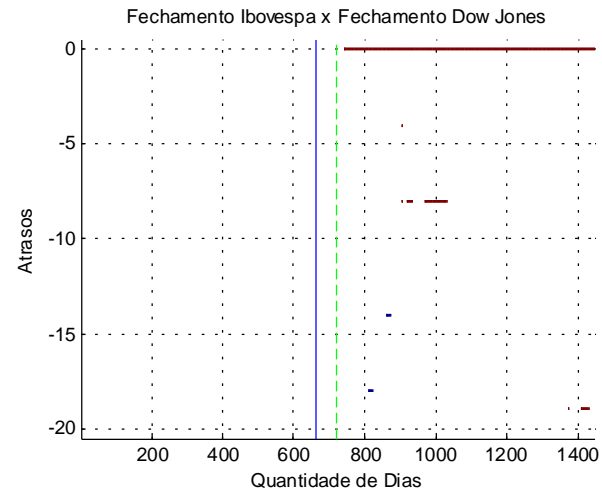



Figura 141: Correlação Fechamento Dow Jones em Sentido Direto.







Figura 142: Correlação Fechamento Dow Jones em Sentido Inverso.







Figura 143: Correlação Fechamento CDI em Sentido Direto.







Figura 144: Correlação Fechamento CDI em Sentido Inverso.







Figura 145: Correlação Fechamento Merval em Sentido Direto.







Figura 146: Correlação Fechamento Merval em Sentido Inverso.







Figura 147: Correlação Fechamento FTSE em Sentido Direto.







Figura 148: Correlação Fechamento FTSE em Sentido Inverso.







Figura 149: Correlação Fechamento PTAX em Sentido Direto.

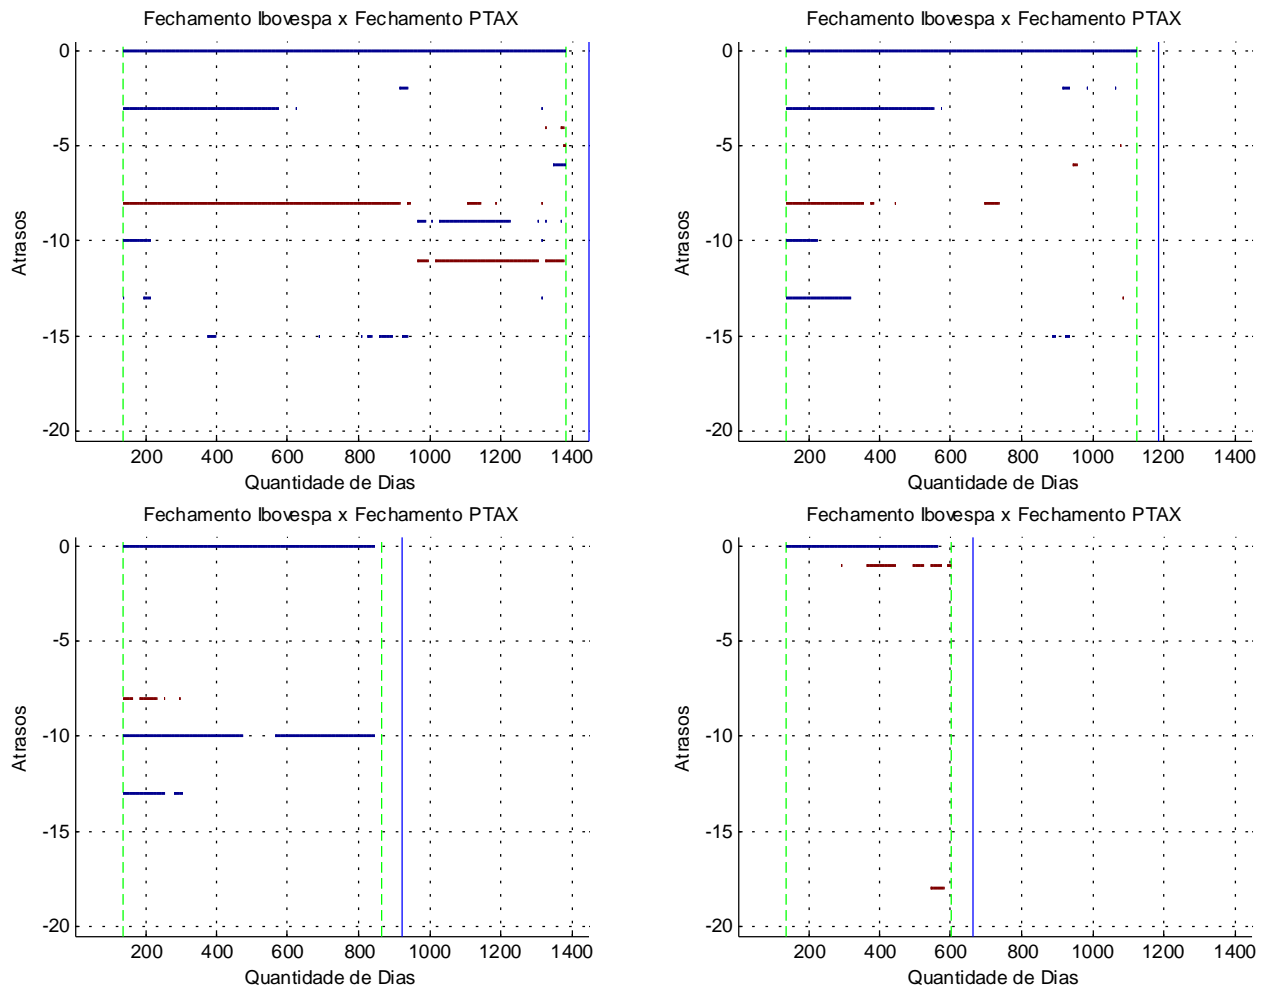


Figura 150: Correlação Fechamento PTAX em Sentido Inverso.







Figura 151: Correlação Fechamento S&P em Sentido Direto.







Figura 152: Correlação Fechamento S&P em Sentido Inverso.







Figura 153: Correlação Fechamento IBX em Sentido Direto.







Figura 154: Correlação Fechamento IBX em Sentido Inverso.







Figura 155: Correlação Fechamento DlxPre180 em Sentido Direto.







Figura 156: Correlação Fechamento DlxPre180 em Sentido Inverso.







Figura 157: Correlação Fechamento DlxPre360 em Sentido Direto.







Figura 158: Correlação Fechamento DlxPre360 em Sentido Inverso.







Figura 159: Correlação Fechamento DlxPre540 em Sentido Direto.







Figura 160: Correlação Fechamento DlxPre540 em Sentido Inverso.







Figura 161: Correlação Fechamento DlxPre720 em Sentido Direto.







Figura 162: Correlação Fechamento DlxPre720 em Sentido Inverso.

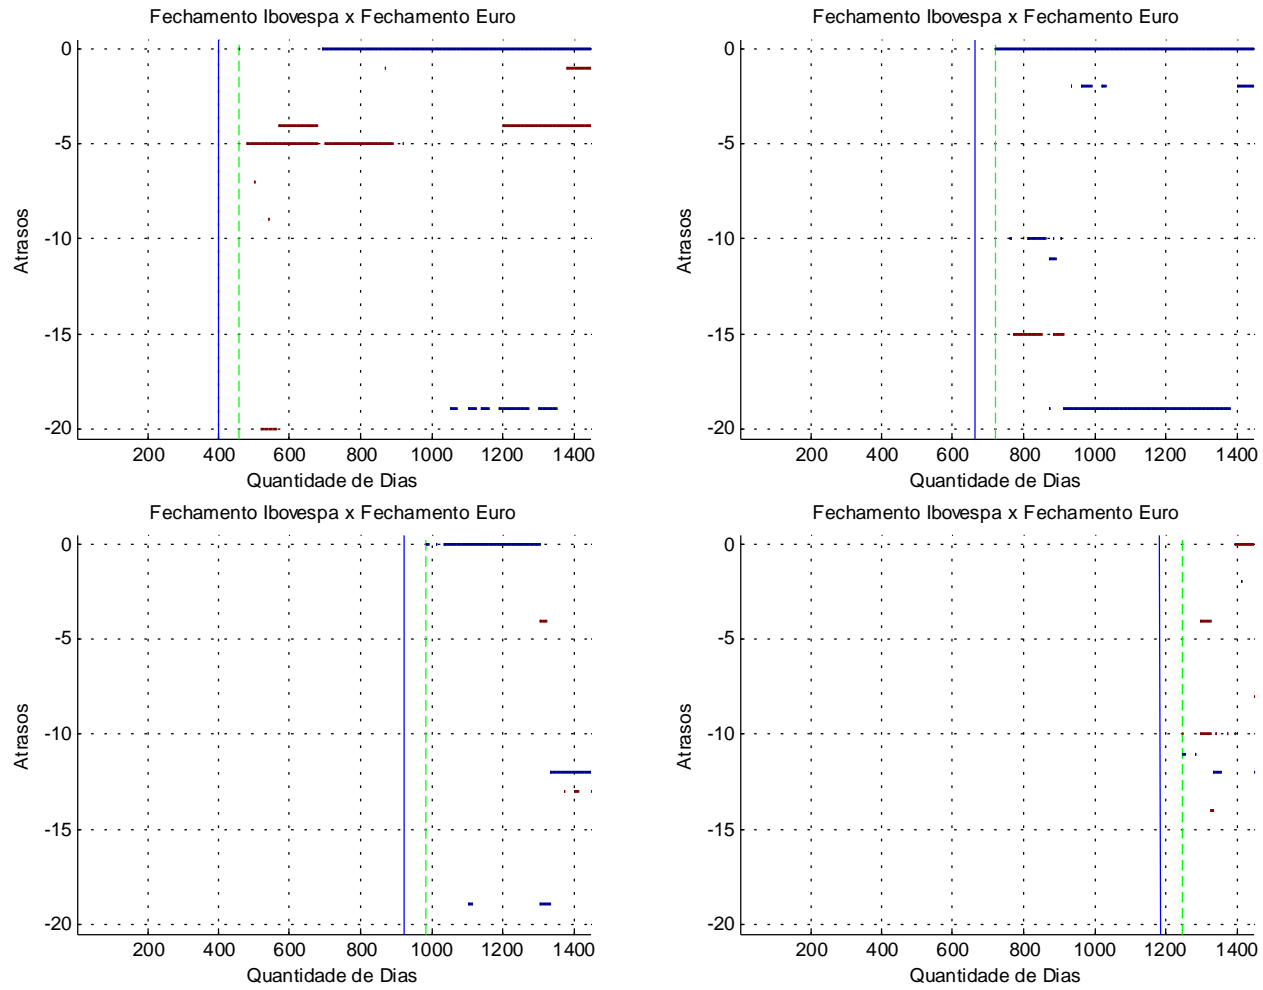


Figura 163: Correlação Fechamento Euro em Sentido Direto.

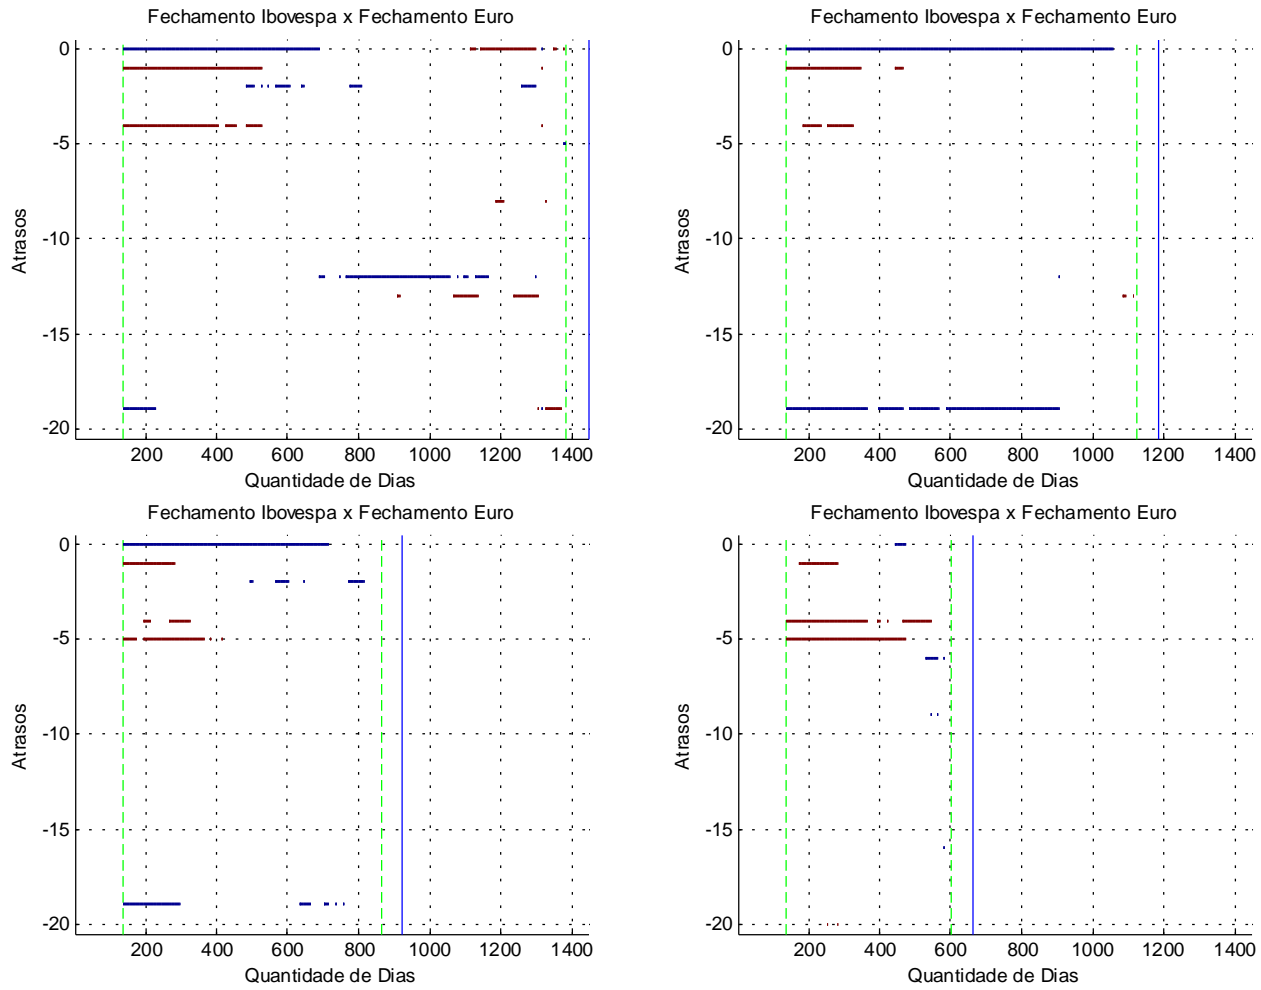


Figura 164: Correlação Fechamento Euro em Sentido Inverso.







Figura 165: Correlação Fechamento Yen em Sentido Direto.







Figura 166: Correlação Fechamento Yen em Sentido Inverso.







Figura 167: Correlação Fechamento Dólar em Sentido Direto.







Figura 168: Correlação Fechamento Dólar em Sentido Inverso.







Figura 169: Correlação Variação Diária IBOVESPA em Sentido Direto.







Figura 170: Correlação Variação Diária IBOVESPA em Sentido Inverso.







Figura 171: Correlação Variação Noturna IBOVESPA em Sentido Direto.







Figura 172: Correlação Variação Noturna IBOVESPA em Sentido Inverso.

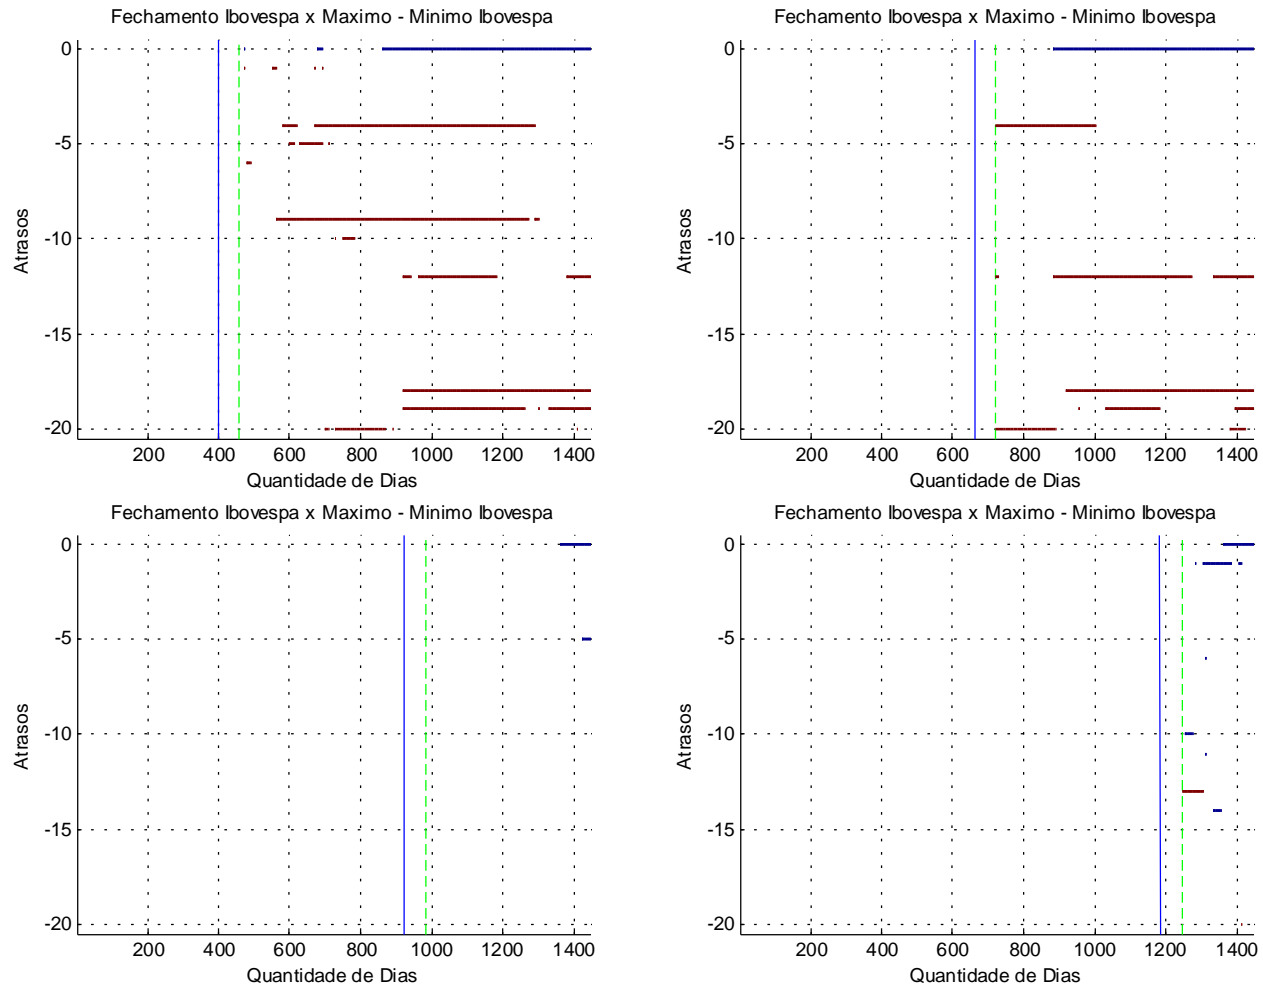


Figura 173: Correlação Variação Máxima IBOVESPA em Sentido Direto.

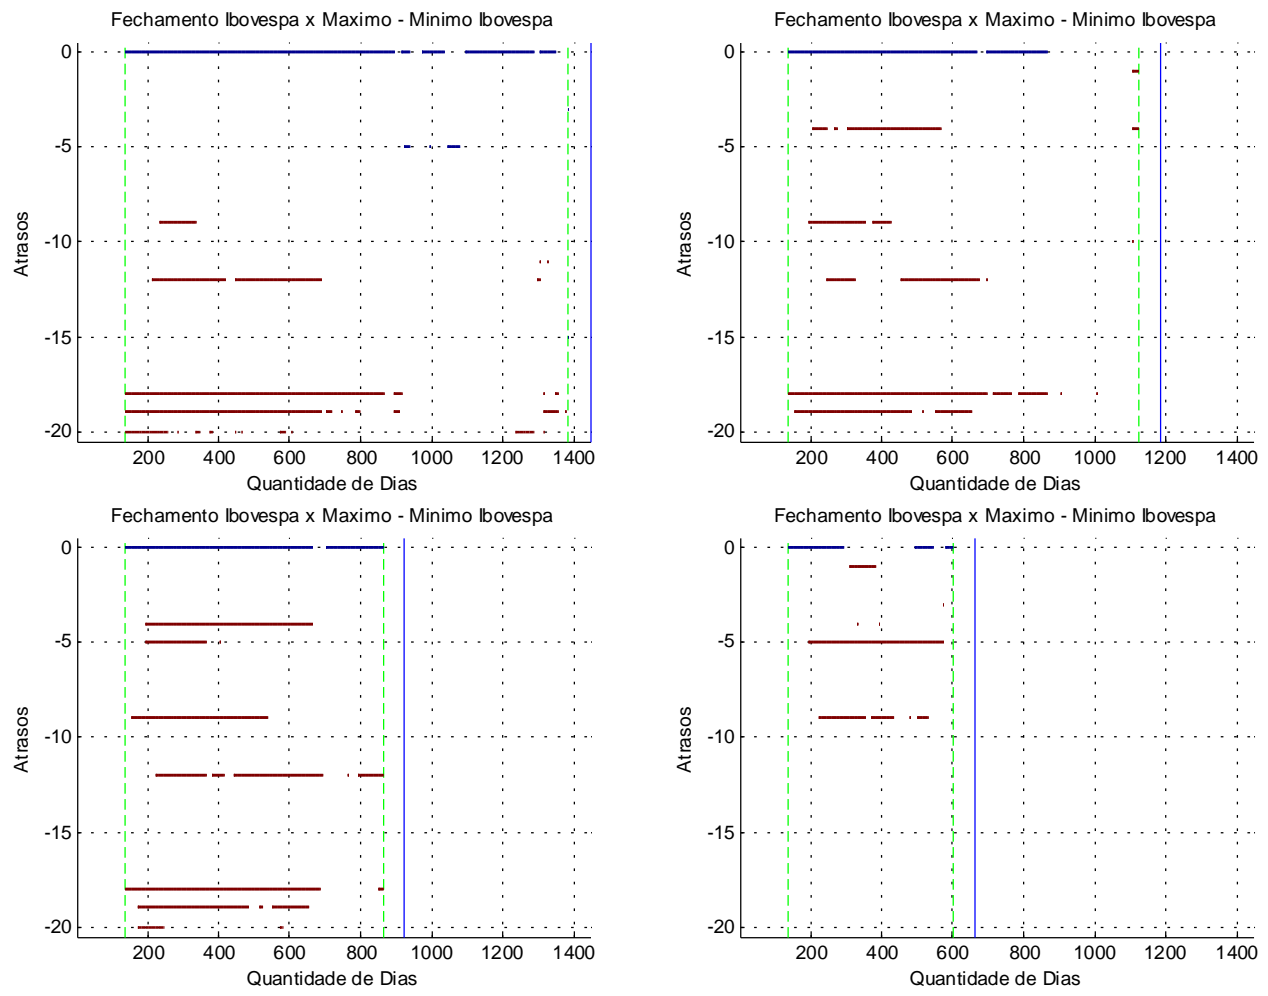


Figura 174: Correlação Variação Máxima IBOVESPA em Sentido Inverso.

APÊNDICE IV – MODELO GARCH

No Apêndice II, foi observado que a série objetivo é ligeiramente leptocúrtica, ou seja, apresenta caudas ligeiramente mais alongadas que as de uma distribuição normal. Além disso, pode-se observar a presença de *clusters* de volatilidade, persistência, indicando que períodos de altas variações na série de retornos sejam linearmente dependentes de períodos anteriores. Portanto, pode-se concluir que há indícios suficientes da presença de *heteroscedasticity*, ou seja, variância variante no tempo, o que confirma a hipótese da utilização de um modelo GARCH para previsão da variância da série de retornos.

O modelo GARCH pode ser descrito como dois modelos complementares, um modelo de previsão de média condicional e um de previsão da variância condicional.

Para sustentar a utilização de um modelo GARCH foi estimada a autocorrelação da série, a autocorrelação parcial¹ e a autocorrelação do quadrado da série, considerando-se até vinte dias de atraso e com um limiar de significância de 5 %² dado por:

$$\text{Significância} = \frac{2}{\sqrt{N}} \quad (16)$$

Onde:

N – número de elementos da série de retornos;

Os resultados podem ser observados nos gráficos a seguir:

¹ A autocorrelação parcial de uma série em uma determinada defasagem k mede a correlação entre observações da série que estão separadas por esta defasagem k após remover o efeito das defasagens intermediárias.

² Supondo uma distribuição normal.




Figura 175: Autocorrelação Fechamento IBOVESPA




Figura 176: Autocorrelação Parcial Fechamento IBOVESPA




Figura 177: Autocorrelação Quadrado do Fechamento IBOVESPA

Analisando-se os resultados da autocorrelação da série de retornos (figura 175) verifica-se que nenhum coeficiente de correlação atinge efetivamente o limiar de significância de 5 %. Isto é um indício de que a utilização de um modelo de previsão de média condicional para descrever o comportamento da série possivelmente não obterá resultados satisfatórios.

Tampouco nos resultados da autocorrelação parcial (figura 176) foi verificada correlação que tenha atingido claramente o limiar de significância, ratificando a hipótese anterior da não aplicabilidade de um modelo de média condicional. Caso houvesse correlação significativa, o atraso máximo em que a correlação fosse verificada seria um indicativo da ordem a ser utilizada neste modelo.

Entretanto, quando se passa a análise dos resultados ao quadrado da série de retornos (figura 177) o mesmo não pode ser afirmado. Neste caso, verifica-se correlação significativa para alguns atrasos analisados, reforçando-se a idéia da utilização de um modelo GARCH para a previsão de variância condicional.

A fim de ratificar os resultados anteriores, a série de retornos foi submetida ao teste estatístico *Ljung-Box*, usualmente conhecido como Q-estatístico. Este teste verifica a hipótese da existência de correlação significativa nos elementos da série entre atrasos definidos. Assumiu-se um limiar de significância de 5 % para o teste e os resultados para os atrasos de 5, 10, 15 e 20 dias estão descritos na tabela a seguir:

Tabela 29: Níveis de significância resultantes do teste *Ljung-Box*

	Atrasos (dias)			
	5	10	15	20
Série de Retornos	$3,24 \times 10^{-1}$	$3,39 \times 10^{-1}$	$2,04 \times 10^{-1}$	$0,93 \times 10^{-1}$
Quadrado da Série de Retornos	$1,26 \times 10^{-11}$	$0,49 \times 10^{-11}$	$0,12 \times 10^{-11}$	$3,03 \times 10^{-11}$

Como era previsto, para o quadrado da série observam-se níveis de significância dentro do limiar pré-estabelecido e, portanto, a hipótese é confirmada, ou seja, coeficientes de correlação significativos são encontrados no quadrado da série. Por outro lado, no caso da série de retornos em nenhum dos casos a hipótese foi confirmada.

Dando continuidade ao processo, foi aplicado o teste ARCH às séries de retornos para verificar a existência de efeitos ARCH/GARCH nos elementos correspondentes a atrasos definidos. Novamente, considerou-se uma significância de 5 % e atrasos de 5, 10, 15 e 20 dias, os resultados são descritos na tabela baixo:

Tabela 30: Níveis de significância resultantes do teste ARCH

	Atrasos (dias)			
	5	10	15	20
Série de Retornos	$0,15 \times 10^{-7}$	$1,66 \times 10^{-7}$	$0,73 \times 10^{-7}$	$8,61 \times 10^{-7}$

Como previsto para todos os casos a hipótese foi aceita com níveis de significância inferiores ao definido, ou seja, a presença de efeito ARCH/GARCH é confirmada pelo teste.

Com todos os resultados anteriores apoiando a utilização de um modelo GARCH para a previsão da variância condicional da série de retornos, partiu-se para a definição desse modelo.

A fim de realizar a validação do modelo após sua definição, a série de retornos foi dividida em dois grupos distintos, um conjunto correspondendo a 261 dias referentes ao último ano em análise (08/2003 a 08/2004) a ser utilizado na definição do modelo e um conjunto dos últimos três meses do conjunto de dados a ser utilizado na validação de resultados.

O modelo de previsão da média condicional pode ser definido de forma genérica como um modelo $ARMAX(R, M, Nx)$ dado por:

$$y_t = C + \sum_{i=1}^R \phi_i y_{t-i} + \varepsilon_t + \sum_{j=1}^M \theta_j \varepsilon_{t-j} + \sum_{k=1}^{Nx} \beta_k X(t, k) \quad (17)$$

Onde:

C – representa uma constante do modelo;

ϕ_i – representa os coeficientes de autoregressão;

θ_j – representa os coeficientes de média móvel;

ε_t – representa as inovações;

y_t – representa os retornos;

X – representa uma matriz de regressão explicativa;

β_k – representa os coeficientes de regressão;

Espera-se pelas análises anteriores que a constante C tenda ao valor médio da série, muito próximo de zero, e que, como não foi verificada nenhuma autocorrelação parcial significativa, as parcelas do modelo referentes a atrasos da série de retornos não acrescentem informações relevantes. Portanto, optou-se por utilizar um modelo de média condicional $ARMAX(0, M, 0)$ descartando desta forma as parcelas que não estariam agregando informações aos resultados.

Desta forma o modelo de média condicional será descrito unicamente pelas inovações ε_t . Apesar do termo inovações sugerir variáveis totalmente aleatórias, para o modelo GARCH as inovações são definidas em função da variância condicional e são estimadas de acordo com a seguinte relação:

$$\varepsilon_t = \sigma_t z_t \quad (18)$$

Onde:

ε_t – representa as inovações;

σ_t – representa o desvio padrão condicionado;

z_t – representa um coeficiente aleatório definido através de uma função independente e identicamente distribuída¹;

¹ No modelo GARCH para descrever o coeficiente aleatório estimado usualmente utiliza-se uma dentre duas distribuições: Gaussiana e *Student's T*.

Três modelos de variância condicional foram utilizados para descrever o comportamento da série objetivo. A estimação dos parâmetros destes modelos foi realizada utilizando-se o conjunto de dados de pré-processamento. Os modelos testados são descritos a seguir:

- GARCH(P, Q)

$$\sigma_t^2 = K + \sum_{i=1}^P G_i \sigma_{t-i}^2 + \sum_{j=1}^Q A_j \varepsilon_{t-j}^2 \quad (19)$$

Onde:

K – representa uma constante do modelo;

ε_t – representa as inovações no instante t ;

σ_t – representa o desvio padrão condicionado no instante t ;

G_i – representa um vetor de coeficientes GARCH;

A_j – representa um vetor de coeficientes ARCH;

Sendo:

$$\sum_{i=1}^P G_i + \sum_{j=1}^Q A_j < 1$$

$$K > 0$$

$$G_i \geq 0 \quad i = 1, 2, \dots, P$$

$$A_j \geq 0 \quad j = 1, 2, \dots, Q$$

- GJR(P, Q)

$$\sigma_t^2 = K + \sum_{i=1}^P G_i \sigma_{t-i}^2 + \sum_{j=1}^Q A_j \varepsilon_{t-j}^2 + \sum_{j=1}^Q L_j S_{t-j}^- \varepsilon_{t-j}^2 \quad (20)$$

Onde:

K – representa uma constante do modelo;

ε_t – representa as inovações no instante t ;

σ_t – representa o desvio padrão condicionado no instante t ;

G_i – representa um vetor de coeficientes GARCH;

A_j – representa um vetor de coeficientes ARCH;

L_j – representa um vetor de coeficientes de *leverage*¹;

Sendo:

$$S_{t-j}^- = \begin{cases} 1 & \varepsilon_{t-j} < 0 \\ 0 & \text{demais casos} \end{cases}$$

$$\sum_{i=1}^P G_i + \sum_{j=1}^Q A_j + \frac{1}{2} \sum_{j=1}^Q L_j < 1$$

$$K > 0$$

$$G_i \geq 0 \quad i = 1, 2, \dots, P$$

$$A_j \geq 0 \quad j = 1, 2, \dots, Q$$

$$A_j + L_j \geq 0 \quad j = 1, 2, \dots, Q$$

- EGARCH(P, Q)

$$\log \sigma_t^2 = K + \sum_{i=1}^P G_i \log \sigma_{t-i}^2 + \sum_{j=1}^Q A_j \left[\frac{|\varepsilon_{t-j}|}{\sigma_{t-j}} - E \left\{ \frac{|\varepsilon_{t-j}|}{\sigma_{t-j}} \right\} \right] + \sum_{j=1}^Q L_j \left(\frac{\varepsilon_{t-j}}{\sigma_{t-j}} \right) \quad (21)$$

Onde:

K – representa uma constante do modelo;

ε_t – representa as inovações no instante t ;

σ_t – representa o desvio padrão condicionado no instante t ;

G_i – representa um vetor de coeficientes GARCH;

A_j – representa um vetor de coeficientes ARCH;

L_j – representa um vetor de coeficientes de *leverage*;

Sendo:

¹ Característica das séries de retornos serem negativamente correlatas com mudanças na volatilidade, ou seja, a volatilidade tende a aumentar em resposta a retornos mais baixos do que o esperado e a cair em resposta a retornos mais altos.

$$E \left\{ \frac{\varepsilon_{t-j}}{\sigma_{t-j}} \right\} = E \left\{ \left| \frac{\varepsilon_{t-j}}{\sigma_{t-j}} \right| \right\} = \begin{cases} \sqrt{\frac{2}{\pi}} & \text{Gaussiana} \\ \sqrt{\frac{\nu-2}{\pi}} \frac{\Gamma\left(\frac{\nu-1}{2}\right)}{\Gamma\left(\frac{\nu}{2}\right)} & \text{Student's } T \end{cases}$$

A definição da ordem dos modelos de variância condicional descritos acima foi feita comparando-se os resultados preditos pelo modelo para o conjunto de validação e os resultados da variância instantânea da série de retornos descrita por:

$$\sigma_k^2 = (x_k - \mu)^2 \quad (22)$$

Onde:

σ_t – representa o desvio padrão instantâneo no instante k ;

x_t – representa o valor da série de retornos no instante k ;

μ – representa o valor médio da série de retornos;

Para que esta comparação fosse mais precisa, foi analisada a resposta em frequência da variância condicional predita pelos modelos, estimando-se as frequências máximas encontradas. Em seguida, ambos os conjuntos foram submetidos a um filtro passa-baixas de terceira ordem na frequência especificada.

Após a filtragem de ambos os sinais, analisou-se o erro médio quadrático e este foi utilizado como parâmetro indicativo da capacidade de previsão do modelo descrito. Desta forma, pode ser feita a escolha do melhor dentre todos os modelos estimados.

Foram estimados modelos para diversos valores de P e Q com as amostras do conjunto de pré-processamento tanto para as inovações como uma distribuição Gaussiana como para uma *Student's T*. Para cada um dos modelos descritos anteriormente foram escolhidos os de melhor performance para terem os resultados expostos a seguir:

- GARCH(1, 1) com Distribuição de Probabilidade Condicional Gaussiana:

Para este modelo, os parâmetros estimados podem ser visualizados na tabela 28, as inovações, os desvios padrões condicionados e os retornos definidos por estes parâmetros podem ser visualizados na figura 178.

Tabela 31: Parâmetros do modelo GARCH(1, 1)

Parâmetro	Valor	Erro Médio	Estatística T ¹
C	$1,13 \times 10^{-3}$	$5,45 \times 10^{-4}$	2,07
K	$1,61 \times 10^{-5}$	$6,95 \times 10^{-6}$	2,42
$GARCH(1)$	$8,93 \times 10^{-1}$	$2,78 \times 10^{-2}$	32,07
$ARCH(1)$	$6,35 \times 10^{-2}$	$1,53 \times 10^{-2}$	4,15




Figura 178: Conjunto de pré-processamento descrito pelo modelo GARCH(1, 1)

Como visto anteriormente, para realizar uma análise comparativa dos resultados previstos pelo modelo foram exibidos o desvio padrão condicional e o imediato no gráfico a seguir.

¹ Definido como o valor do parâmetro dividido pelo erro médio, é definido como o número de desvios padrões que o parâmetro estimado encontra-se distante do zero e usualmente um valor acima de 2 define uma boa estimativa do parâmetro.




Figura 179: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo GARCH(1, 1)

Analisando-se o espectro em frequência do desvio padrão condicional previsto pelo modelo na figura 180, pode-se observar que as máximas frequências encontradas situam-se em torno de $0,05 \text{ dia}^{-1}$ e, portanto, essa foi a frequência utilizada no filtro passa-baixas implementado.




Figura 180: Resposta em frequência do conjunto de pós processamento para o modelo GARCH(1, 1)

Os parâmetros estimados deste filtro e o espectro em frequência dos sinais filtrados podem ser visualizados nas figuras abaixo:




Figura 181: Resposta em frequência do filtro utilizado para filtragem no modelo GARCH(1, 1)




Figura 182: Resposta em frequência dos sinais filtrados no modelo GARCH(1, 1)

Comparando-se ambos os sinais filtrados, pode-se estimar o erro médio quadrático e, desta forma, inferir o melhor dentre os três modelos propostos. Os resultados comparativos entre o previsto e o real podem ser observados na figura 183.




Figura 183: Conjunto de pós-processamento filtrado predito pelo modelo GARCH(1, 1)

- GJR(1, 1) Distribuição de Probabilidade Condicional Gaussiana:

De forma análoga ao modelo anterior, são apresentados os resultados obtidos para o modelo GJR, sendo que a mesma frequência de corte foi encontrada para o filtro passa-baixas e, portanto os resultados deste filtro são suprimidos por serem os mesmos apresentados anteriormente.

Tabela 32: Parâmetros do modelo GJR(1, 1)

Parâmetro	Valor	Erro Médio	Estatística T
C	$8,87 \times 10^{-4}$	$5,31 \times 10^{-4}$	1,67
K	$1,73 \times 10^{-5}$	$6,21 \times 10^{-6}$	2,79
$GARCH(1)$	$8,95 \times 10^{-1}$	$2,76 \times 10^{-2}$	32,47
$ARCH(1)$	$1,06 \times 10^{-2}$	$1,46 \times 10^{-2}$	$7,27 \times 10^{-1}$
$Leverage(1)$	$9,11 \times 10^{-2}$	$2,37 \times 10^{-2}$	3,85




Figura 184: Conjunto de pré-processamento descrito pelo modelo GJR(1, 1)




Figura 185: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo GJR(1, 1)




Figura 186: Resposta em frequência dos sinais filtrados no modelo GJR(1, 1)




Figura 187: Conjunto de pós-processamento filtrado predito pelo modelo GJR(1, 1)

- EGARCH(1, 1) Distribuição de Probabilidade Condicional Gaussiana:

Novamente, de forma análoga aos modelos anteriores, os resultados obtidos são exibidos abaixo. Também foram suprimidos os resultados do filtro passa-baixas, em função de se ter definido uma mesma frequência de corte neste modelo.

Tabela 33: Parâmetros do modelo EGARCH(1, 1)

Parâmetro	Valor	Erro Médio	Estatística T
C	$9,45 \times 10^{-4}$	$5,30 \times 10^{-4}$	1,78
K	$-3,82 \times 10^{-1}$	$1,32 \times 10^{-1}$	-2,89
$GARCH(1)$	$9,52 \times 10^{-1}$	$1,65 \times 10^{-2}$	57,66
$ARCH(1)$	$1,16 \times 10^{-1}$	$2,96 \times 10^{-2}$	3,93
$Leverage(1)$	$-6,53 \times 10^{-2}$	$1,51 \times 10^{-2}$	-4,32




Figura 188: Conjunto de pré-processamento descrito pelo modelo EGARCH(1, 1)




Figura 189: Desvio padrão condicional e imediato do conjunto de pós processamento do modelo EGARCH(1, 1)

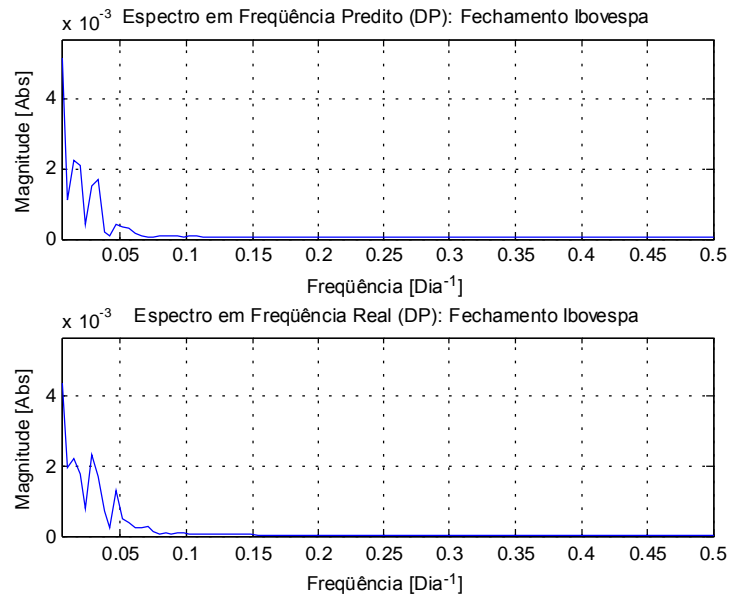


Figura 190: Resposta em frequência dos sinais filtrados no modelo EGARCH(1, 1)

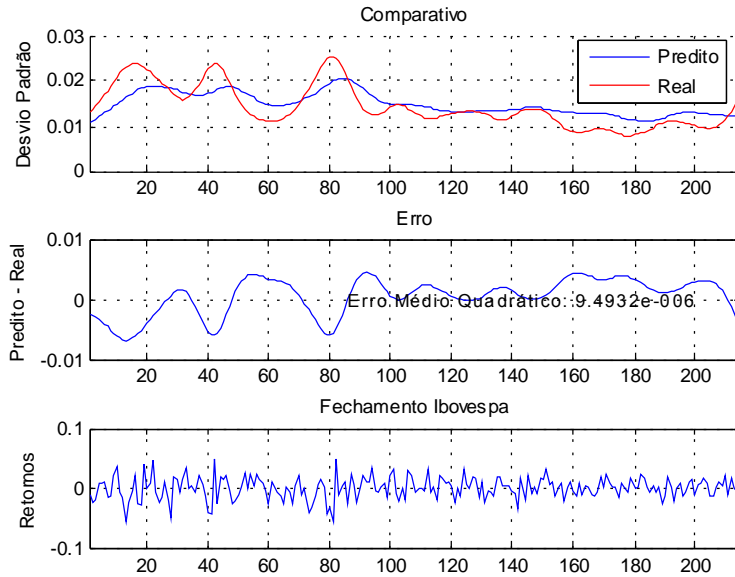


Figura 191: Conjunto de pós-processamento filtrado predito pelo modelo EGARCH(1, 1)

Finalizada a modelagem proposta, pode-se inferir o melhor deles através da análise da performance dos três modelos de variância condicional. Estes resultados foram sumarizados na tabela 31, onde se pode constatar que o modelo que melhor representa o caso proposto é GJR(1, 1).

Tabela 34: Erro Médio Quadrático dos modelos de variância condicional

Modelo	Distribuição	EMQ
GARCH(1, 1)	Gaussiana	$1,09 \times 10^{-5}$
GJR(1, 1)	Gaussiana	$8,35 \times 10^{-6}$
EGARCH(1, 1)	Gaussiana	$9,49 \times 10^{-6}$

O modelo escolhido é descrito pelas equações a seguir:

$$\sigma_t^2 = 1,73 \times 10^{-5} + 8,95 \times 10^{-1} \sigma_{t-1}^2 + 1,06 \times 10^{-2} \varepsilon_{t-1}^2 + 9,11 \times 10^{-2} S_{t-1}^- \varepsilon_{t-1}^2$$

$$y_t = 8,87 \times 10^{-4} + \varepsilon_t$$

Onde:

ε_t – representa as inovações no instante t ;

σ_t – representa o desvio padrão condicionado no instante t ;

y_t – representa a média condicionada no instante t ;

Sendo:

$$S_{t-j}^- = \begin{cases} 1 & \varepsilon_{t-1} < 0 \\ 0 & \text{demais casos} \end{cases}$$

A variância condicional predita por este modelo foi utilizada como uma das entradas da rede neural de previsão da série de retornos do fechamento do IBOVESPA, porém não apresentou ganhos de performance.

GLOSSÁRIO

ARMAX – do inglês *Autoregressive Moving Average Exogenous* modelos descritos por uma parcela autoregressiva (AR), uma média móvel (MA) e uma parcela exógena (X), parcela essa que não pode ser descrita pelo modelo.

Capitalização Bursátil – É o valor de mercado das empresas emissoras de ações integrantes da carteira teórica dos índices. Esse valor é apurado pelo resultado da multiplicação da quantidade de cada tipo/classe de ação de emissão da empresa pela sua respectiva cotação de mercado.

Coefficiente de Regressão – coeficiente de correlação estimado entre a saída real de um modelo e a saída prevista pelo mesmo.

EGARCH – termo para designar o modelo GARCH exponencial.

Emolumentos – O emolumento para ações é uma taxa operacional cobrada pela Bovespa em contraprestação de serviços por ela prestados, incidirá sobre o volume financeiro total operado no dia e obedecerá o seguinte critério: 0,035% para operações normais e 0,025% para operações *day-trade*.

EMQ – Erro Médio Quadrático.

GARCH – do inglês *Generalized AutoRegressive Conditional Heteroscedasticity*, é o modelo ARCH generalizado permite a presença de componentes auto-regressivos e de médias móveis na variância heterocedástica dos ativos financeiros.

GJR – Glosten, Jagannathan and Runkle – é outra variação assimétrica do modelo GARCH, cujo objetivo é, assim como o EGARCH, permitir a diferenciação entre impactos positivos e negativos da série temporal.