



IGOR RIBEIRO LIMA

**SISTEMAS INTELIGENTES PARA AUXILIAR
NA TOMADA DE DECISÕES EM MERCADO DE
CAPITAIS**

LAVRAS – MG

2012

IGOR RIBEIRO LIMA

**SISTEMAS INTELIGENTES PARA AUXILIAR NA TOMADA DE
DECISÕES EM MERCADO DE CAPITAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para obtenção do título de Mestre.

Orientador

DSc. Sérgio Martins de Souza - DEX/UFLA

Coorientador

DSc. Heitor Augustus Xavier Costa - DCC/UFLA

LAVRAS – MG

2012

**Ficha Catalográfica Elaborada pela Divisão de Processos Técnicos da
Biblioteca da UFLA**

Lima, Igor Ribeiro.

Sistemas inteligentes para auxiliar na tomada de decisões em
mercado de capitais / Igor Ribeiro Lima. – Lavras : UFLA, 2012.
192 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2012.

Orientador: Sérgio Martins de Souza.

Bibliografia.

1. Lógica fuzzy. 2. Redes neurais. 3. Análise técnica. 4. Ativos
financeiros. 5. Inteligência computacional. I. Universidade Federal
de Lavras. II. Título.

CDD – 620.00113

IGOR RIBEIRO LIMA

**SISTEMAS INTELIGENTES PARA AUXILIAR NA TOMADA DE
DECISÕES EM MERCADO DE CAPITAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para obtenção do título de Mestre.

APROVADA em 27 de junho de 2012.

Prof. _____

Prof. _____

DSc. Sérgio Martins de Souza - DEX/UFLA
Orientador

LAVRAS – MG

2012

AGRADECIMENTOS

Agradeço...

Ao Prof. Heitor, por sua orientação,
incentivo, paciência e disponibilidade
no andamento da pesquisa.

Aos meus pais e familiares
que sempre acreditaram
no estudo e sempre me apoiam;

A minha namorada, pela compreensão
diante das intermináveis horas de estudo;

A todas as outras pessoas que direta ou
Indiretamente contribuíram na realização desse
trabalho.

Muito obrigado!

RESUMO

A capacidade da inteligência computacional em mapear sistemas complexos tem se tornado uma ferramenta atrativa, por ser aplicável em processos relacionados ao comportamento de ativos de mercados financeiros. A utilização de técnicas de inteligência computacional é uma das estratégias para prever esse comportamento por usar sistemas não lineares, visto que este sofre influências de vários fatores políticos e econômicos. O objetivo é apresentar a modelagem e uma análise comparativa de sistemas computacionais inteligentes no apoio à tomada de decisão em mercado de capitais, utilizando duas técnicas de inteligência computacional: lógica fuzzy e redes neurais artificiais (RNAs). Essas modelagens ajudam a prever o movimento do mercado de capitais e obter informações importantes para tomada de decisão por parte do investidor, possibilitando maior ganho em liquidez nas negociações. Em suma, esse sistema fornece apoio a decisão aos investidores que desejam acompanhar suas aplicações financeiras.

Palavras-chave: Lógica Fuzzy, Redes Neurais, Sistemas Inteligentes, Mercado de Capitais, Análise Técnica.

ABSTRACT

The ability of computational intelligence in mapping complex systems has become an attractive tool, because it is applicable in processes related to the behavior of financial market assets. The use of computational intelligence techniques is one of the strategies to predict this behavior by using non-linear systems, since it is influenced by various political and economic factors. The goal is to present a comparative analysis and modeling of computer systems in support of intelligent decision making in capital markets, using two computational intelligence techniques: fuzzy logic and artificial neural networks (ANN). These modeling to help predict market movement of capital and important information for decision making by the investor, enabling greater gain in liquidity in the negotiations. In short, this system provides decision support for investors who wish to track their investments.

Key words: Fuzzy Logic, Neural Networks, Intelligent Systems, Capital Markets, Technical Analysis.

LISTA DE FIGURAS

Figura 1	Tipos de pesquisa científica	20
Figura 2	Função características do conjunto (método convencional).....	35
Figura 3	Função característica do conjunto <i>fuzzy</i>	35
Figura 4	Função de pertinência crescente.....	36
Figura 5	Função de pertinência decrescente.....	36
Figura 6	Função de pertinência triangular	37
Figura 7	Função de pertinência trapezoidal.....	38
Figura 8	Função de pertinência gaussiana	38
Figura 9	Operação de união.....	39
Figura 10	Operação de intersecção.....	40
Figura 11	Operação de negação.....	40
Figura 12	Produto cartesiano	41
Figura 13	Máquina de inferência <i>fuzzy</i>	46
Figura 14	Diagrama demonstrativo de inferência <i>fuzzy</i>	51
Figura 15	Método de Mamdani com composição max-min	53
Figura 16	Exemplo genérico de regras TSK.....	54
Figura 17	Estrutura de um neurônio natural	58
Figura 18	Neurônio como unidade limite	62
Figura 19	Funções de ativação	63
Figura 20	Fases do processo de aprendizagem de uma RNA.....	64
Figura 21	RNA recorrente	67
Figura 22	RNA de uma só camada	71
Figura 23	Gráfico do indicador IFR	78
Figura 24	Gráfico de força relativa.....	78
Figura 25	Planilha para o cálculo do indicador IFR	78
Figura 26	Indicador IFR da cotação diária do EBAY	79

Figura 27	Indicador IFR da cotação diária do ouro	80
Figura 28	Planilha para o cálculo do indicador oscilador estocástico	82
Figura 29	Gráfico do indicador oscilador estocástico	82
Figura 30	Gráfico do indicador oscilador estocástico ilustrando momentos de compra e de venda	83
Figura 31	Gráfico ilustrativo do indicador MACD	85
Figura 32	Interpretação do cruzamento da linha MACD e da linha de sinal MACD	85
Figura 33	Planilha para o cálculo de MME	87
Figura 34	Gráfico ilustrativo de interpretação do indicador histograma MACD	89
Figura 35	Planilha para o cálculo do indicador OBV	91
Figura 36	Gráfico OBV indicando divergência com o preço	92
Figura 37	Arquitetura para obtenção dos dados	96
Figura 38	Modelagem utilizando lógica <i>fuzzy</i>	97
Figura 39	Universo IFR	98
Figura 40	Universo oscilador estocástico	98
Figura 41	Universo OBV e histograma MACD	99
Figura 42	Universos sinal, volume e momento	102
Figura 43	Universo C&V	102
Figura 44	Modelagem do banco de dados do sistema <i>fuzzy</i>	107
Figura 45	Modelagem utilizando RNAs	108
Figura 46	RNA para o indicador IFR	110
Figura 47	RNA para o indicador oscilador estocástico	111
Figura 48	RNA para o indicador MACD	112
Figura 49	RNA para o indicador histograma MACD	112
Figura 50	RNA para o indicador OBV	113
Figura 51	RNA para a variável momento	114

Figura 52	RNA para a variável <i>signal</i>	115
Figura 53	RNA para a variável <i>volume</i>	116
Figura 54	RNA para o Indicador <i>C&V</i>	117
Figura 55	Proposta 1: modelagem híbrida utilizando RNA- <i>fuzzy-fuzzy</i>	118
Figura 56	Proposta 2: modelagem híbrida utilizando <i>fuzzy-RNA-RNA</i>	120
Figura 57	Proposta 3: modelagem híbrida utilizando RNA- <i>fuzzy-RNA</i>	121
Figura 58	Proposta 4: modelagem híbrida utilizando <i>fuzzy-RNA-fuzzy</i>	123
Figura 59	Proposta 5: modelagem híbrida utilizando RNA-RNA- <i>fuzzy</i>	124
Figura 60	Proposta 6: modelagem híbrida utilizando <i>fuzzy-fuzzy-RNA</i>	125
Figura 61	Estrutura de diretório no Scilab.....	142
Figura 62	Tela de <i>login</i>	149
Figura 63	Tela principal do Cell Invest.....	149
Figura 64	Barra de título da aplicação <i>Web</i>	150
Figura 65	Formulário para efetuar cálculos no sistema <i>fuzzy</i>	151
Figura 66	Formulário para "fuzzificar" uma variável linguística.....	152
Figura 67	Visualização gráfica do universo <i>fuzzy</i> IFR.....	152
Figura 68	Consulta dos dados cadastrados de um determinado universo <i>fuzzy</i>	153
Figura 69	Formulário para cadastro sistema <i>fuzzy</i>	154
Figura 70	Formulário para efetuar cálculos no ambiente Scilab.....	155
Figura 71	Visualização da estrutura de diretório das RNAs.....	155
Figura 72	Conteúdo da aba <i>Dados de Entrada</i>	156
Figura 73	Conteúdo da aba <i>Indicadores</i>	156
Figura 74	Lista para a visualização gráfica dos indicadores técnicos.....	157
Figura 75	Gráfico do indicador IFR do ativo financeiro BBAS3.....	158
Figura 76	Gráfico do indicador oscilador estocástico do ativo financeiro BBAS3.....	158
Figura 77	Gráfico do indicador MACD do ativo financeiro BBAS3.....	159

Figura 78	Gráfico do indicador histograma MACD do ativo financeiro BBAS3	159
Figura 79	Gráfico do indicador OBV do ativo financeiro BBAS3.....	160
Figura 80	Resultado do exemplo do conjunto <i>fuzzy</i> IFR.....	164
Figura 81	Resultado do exemplo do conjunto <i>fuzzy</i> oscilador estocástico ..	164
Figura 82	Resultado do exemplo da máquina de inferência momento	164
Figura 83	Resultado do exemplo do conjunto <i>fuzzy</i> MACD	165
Figura 84	Resultado do exemplo do conjunto <i>fuzzy</i> Histograma MACD....	165
Figura 85	Resultado do exemplo da máquina de inferência sinal.....	166
Figura 86	Resultado do exemplo do conjunto <i>fuzzy</i> OBV.....	166
Figura 87	Resultado do exemplo da máquina de inferência volume.....	167
Figura 88	Resultado do exemplo da máquina de inferência C&V.....	167
Figura 89	Estatística obtida com a modelagem utilizando lógica <i>fuzzy</i>	168
Figura 90	Resultado do exemplo da camada de saída da RNA do indicador IFR	169
Figura 91	Resultado do exemplo da camada de saída da RNA do indicador oscilador estocástico.....	170
Figura 92	Resultado do exemplo da camada de saída da RNA da variável momento	170
Figura 93	Resultado do exemplo da camada de saída da RNA do indicador MACD.....	171
Figura 94	Resultado do exemplo da camada de saída da RNA do indicador histograma MACD	171
Figura 95	Resultado do exemplo da camada de saída da RNA da variável sinal.....	172
Figura 96	Resultado do exemplo da camada de saída da RNA do indicador OBV	172

Figura 97	Resultado do exemplo da camada de saída da RNA da variável volume	173
Figura 98	Resultado do exemplo da camada de saída da RNA indicador C&V.....	173
Figura 99	Estatística obtida com a modelagem utilizando RNA.....	174
Figura 100	Estatística obtida com as modelagens híbridas	175

LISTA TABELAS

Tabela 1	Regras para o universo de discurso MACD	101
Tabela 2	Regras para o universo de discurso histograma MACD	101
Tabela 3	Regras <i>fuzzy</i> para calcular a intensidade da variável momento.	103
Tabela 4	Regras <i>fuzzy</i> para calcular a intensidade da variável sinal.....	103
Tabela 5	Regras <i>fuzzy</i> para calcular a intensidade da variável volume ...	104
Tabela 6	Regras <i>fuzzy</i> para calcular a intensidade do indicador C&V.....	104
Tabela 7	Tabela para calcular a distância da linha MACD ao eixo zero ...	127
Tabela 8	Tabela para calcular a diferença entre a linha MACD e a linha de sinal MACD	128
Tabela 9	Tabela para calcular o ângulo da linha MACD.....	130
Tabela 10	Tabela para calcular o valor da diferença entre o ângulo da linha MACD e o ângulo da linha de sinal MACD	132
Tabela 11	Tabela para calcular a distância do valor do indicador histograma MACD ao eixo zero.....	133
Tabela 12	Tabela para calcular o ângulo do indicador histograma MACD.	135
Tabela 13	Tabela para calcular o ângulo do indicador OBV	137
Tabela 14	Equações de normalização	138
Tabela 15	Exemplos de normalização.....	140
Tabela 16	Exemplos de normalização.....	141
Tabela 17	Descrição do conteúdo dos arquivos de cada RNA.....	144
Tabela 18	Ativos utilizados na análise dos resultados	162
Tabela 19	Dados de entrada de exemplo para a modelagem utilizando lógica <i>fuzzy</i>	163
Tabela 20	Dados de entrada de exemplo para a modelagem utilizando RNAs.....	169
Tabela 21	Síntese dos resultados entre as modelagens	176

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Justificativa	17
1.2	Objetivo	18
1.3	Metodologia de desenvolvimento	19
1.3.1	Tipo de pesquisa	19
1.3.2	Procedimentos metodológicos	21
1.4	Estrutura do trabalho	22
2	TRABALHOS RELACIONADOS	23
3	LÓGICA FUZZY	28
3.1	Considerações iniciais	28
3.2	Lógica clássica versus lógica <i>fuzzy</i>	29
3.3	Aplicações da lógica <i>fuzzy</i>	30
3.4	Conjuntos <i>fuzzy</i>	32
3.5	Função de pertinência	34
3.6	Operações com conjuntos <i>fuzzy</i>	39
3.7	Fundamentos da modelagem <i>fuzzy</i>	42
3.8	Sistemas baseados em lógica <i>fuzzy</i>	44
3.8.1	Módulo de fuzzificação	46
3.8.2	Módulo da base de regras	47
3.8.3	Módulo de inferência	48
3.8.4	Módulo de "defuzzificação"	48
3.9	Inferência <i>fuzzy</i>	49
3.9.1	Inferência <i>fuzzy</i> - Método de Mamdani	52
3.9.2	Inferência <i>fuzzy</i> - modelo de Takagi-Sugeno-Kang	54
3.10	Considerações finais	55
4	REDES NEURAIAS ARTIFICIAIS	56
4.1	Considerações iniciais	56
4.2	Fundamentos biológicos	57
4.3	Vantagens e desvantagens da utilização de RNAs	59
4.4	Principais componentes das RNAs	61
4.5	Preparação dos dados	63
4.6	Topologias de RNAs	66
4.7	Aprendizagem das RNAs	67
4.8	RNAs <i>perceptrons</i>	70

4.9	Mínimos locais	71
4.10	Sobreajuste e generalização.....	72
4.11	Considerações finais	73
5	ANÁLISE TÉCNICA.....	75
5.1	Considerações iniciais	75
5.2	Índice de força relativa (IFR).....	76
5.3	Oscilador estocástico	80
5.4	<i>Moving average convergence-divergence</i> (MACD).....	83
5.5	Histograma MACD	87
5.6	<i>On balance volume</i> (OBV).....	89
5.7	Considerações finais	92
6	SISTEMAS INTELIGENTES PARA O MERCADO DE CAPITAIS.....	94
6.1	Considerações iniciais	94
6.2	Arquitetura para obtenção dos dados	95
6.3	Modelagem dos sistemas	96
6.3.1	Modelagem utilizando lógica <i>fuzzy</i>	96
6.3.2	Modelagem utilizando das redes neurais artificiais	108
6.3.3	Modelagens híbridas	117
6.4	Normalização dos dados	122
6.4.1	Normalização dos valores na modelagem utilizando lógica <i>fuzzy</i>	125
6.4.1.1	Normalização da distância da linha MACD ao eixo zero	126
6.4.1.2	Normalização da diferença entre a linha MACD e a linha de sinal MACD	127
6.4.1.3	Normalização do ângulo da linha MACD	129
6.4.1.4	Normalização da diferença entre o ângulo da linha MACD e o da linha de sinal MACD.....	131
6.4.1.5	Normalização da distância do histograma MACD ao eixo zero	133
6.4.1.6	Normalização do ângulo do histograma MACD.....	134
6.4.1.7	Normalização do ângulo do indicador OBV	136
6.4.2	Normalização dos valores na modelagem utilizando RNAs	138
6.4.3	Normalização dos valores na modelagem utilizando RNAs	139
6.5	Implementação das modelagens	140
6.5.1	Organização da RNA em meio persistente.....	140
6.5.2	Cell Invest.....	148
6.6	Análise dos resultados	157

6.6.1	Resultados obtidos com o sistema modelado utilizando lógica <i>fuzzy</i>	160
6.6.2	Resultados obtidos com o sistema modelado utilizando RNAs	168
6.6.3	Resultados obtidos com os sistemas híbridos	174
6.7	Considerações finais	175
7	CONSIDERAÇÕES FINAIS	177
7.1	Conclusões	177
7.2	Contribuições	178
7.3	Limitações	179
7.4	Trabalhos Futuros	180
	REFERÊNCIAS	182

1 INTRODUÇÃO

A inteligência computacional tem se tornado uma ferramenta atrativa por possibilitar o mapeamento de sistemas complexos e ser aplicada em processos relacionados ao comportamento de ativos de mercados financeiros. Dessa forma, um investidor pode minimizar riscos de perda em investimentos e maximizar lucros ao utilizar técnicas de inteligência computacional. Para isso, não é necessário fazer previsões exatas do preço de cada ativo de ação, bastaria prever movimentos de alta de baixa no mercado de ativos financeiros (PEDRONETTE; GUILHERME, 2004).

Diversas pesquisas foram e continuam sendo realizadas visando à predição da movimentação do mercado de ativos financeiros, sendo parte delas utilizando inteligência computacional para efetuar tal predição (GONZALEZ; GONZALEZ, 2011). Modelos baseados na teoria do caos (ZANETTI JUNIOR; ALMEIDA, 1998) partem do princípio que existe um componente determinístico no movimento dos preços dos ativos financeiros que não seguem um processo aleatório. Esse não seguimento está consoante com a hipótese do comportamento dos preços de um ativo financeiro poder ser originado a partir de um processo determinístico complexo (ZANETTI JUNIOR; ALMEIDA, 1998).

Na literatura, podem ser reconhecidos diversos tipos de aplicações utilizando técnicas de inteligência computacional no apoio a tomada de decisões no mercado de ativos financeiros (BARBOSA; ALMEIDA, 2002; CICHINI; CASTRO; FLAUZINO, 2007). A maioria dessas aplicações converge para a utilização de séries históricas (PEDRONETTE; GUILHERME, 2004) como auxílio de decisões futuras, nas quais as técnicas de inteligência computacional se diferem em como abordar essa problemática, sendo que (i) algumas focam em decidir qual os melhores ativos financeiros para investir em um determinado momento, (ii) umas propõem identificar formas nos gráficos para distinguir

momentos de compra ou de venda e (iii) outras objetivam prever valores de cotações dos ativos financeiros.

Métodos dinâmicos e adaptativos podem ser capazes de determinar padrões e relacionamentos nos dados globais do mercado (PARRACHO, 2010). Esses métodos dinâmicos são importantes na identificação de oportunidades de compra e de venda de ativos financeiros, pois, em um mercado rápido e extremamente interligado, os preços de um ativo financeiro refletem instantaneamente informações relevantes do mercado. Essas informações implicam em decisões por parte dos agentes econômicos no que diz respeito à compra e à venda de ativos financeiros. Assim, a agilidade da tomada de decisão é fator determinante aos investidores para obterem melhores retornos no mercado.

As oportunidades de compra e de venda de ativos financeiros podem ser identificadas por meio de sistemas desenvolvidos utilizando técnicas de inteligência computacional baseadas em dados históricos para prever o comportamento futuro desses ativos. Essas técnicas possibilitam ao investidor realizar suas transações na tentativa de minimizar seus erros. Além disso, esses sistemas devem oferecer resultados em tempo hábil para que o investidor esteja atualizado e competitivo (PEDRONETTE; GUILHERME, 2004).

1.1 Justificativa

No início do século XXI, os países emergentes, como o Brasil, viveram um momento de aumento da entrada de capital estrangeiro (NASCIMENTO et al., 2007), o que impactou na elevação dos preços das empresas de capital aberto listadas na Bolsa de Valores, pois foi uma importante fonte de financiamento empresarial e um meio de captação de recursos individuais (MELLO, 2004 citado por BAUER, 2008). Preços de ativos negociados em mercado apresentam

um padrão oscilatório de alternância de movimentos de alta e de baixa no decorrer do tempo, em consonância com o processo de realinhamento dos valores relativos na economia. Operadores de Bolsa de Valores buscam prever estes movimentos, obtendo indicações antecipadas de quando comprar ou vender um ativo financeiro. Nessa busca, a preocupação está no mercado se mover em um significativo espaço de tempo em um sentido (THOMAS; VELLASCO, 2005).

O Índice da Bolsa de Valores de São Paulo (IBOVESPA) foi criado com a finalidade de acompanhar o desempenho médio dos preços dos principais ativos financeiros negociados na Bolsa de Valores do estado de São Paulo (NASCIMENTO et al., 2007). Este índice é composto por ativos financeiros escolhidos principalmente por sua representatividade em termos de quantidade de negócios (medido por um índice de negociabilidade) apresentada em um período (MELLAGI FILHO; ISHIKAWA, 2000). A utilização de técnicas de inteligência computacional é uma das estratégias para estimar o valor desse índice por usar sistemas não lineares, da mesma forma como se comporta o mercado, visto que este sofre influências de vários fatores políticos e econômicos (MELLO, 2004 citado por BAUER, 2008).

1.2 Objetivo

Nesta dissertação, o objetivo do autor é apresentar modelagens, implementações e uma análise comparativa de sistemas computacionais inteligentes no apoio a tomada de decisão em mercado de capitais. Além de desenvolver de maneira modular, em duas modelagens, foram utilizadas as técnicas de inteligência computacional lógica *fuzzy* e redes neurais artificiais (RNAs) do tipo *perceptron* com uma camada, respectivamente. As demais são

desenvolvidas com a reorganização dos módulos das modelagens anteriores, o que permite obter mais 6 modelagens (híbridas).

A aplicabilidade e a avaliação dos resultados desses sistemas foram feitas utilizando dados históricos reais advindos do mercado de capitais. Isso permitiu realizar a análise de (i) acurácia e corretude dos resultados e (ii) como a modelagem utilizando unicamente lógica *fuzzy*, (iii) como a modelagem utilizando unicamente RNAs e (iv) as modelagens híbridas se comportaram no apoio à tomada de decisão em mercado de capitais.

1.3 Metodologia de desenvolvimento

A metodologia de pesquisa é um conjunto de métodos, técnicas e procedimentos cuja finalidade é viabilizar a execução da pesquisa. Essa execução tem como resultado um novo produto, processo ou conhecimento (JUNG, 2009).

1.3.1 Tipo de pesquisa

Uma pesquisa pode ser classificada em (Figura 1) (JUNG, 2009):

- a) Quanto à Natureza: i) Pesquisa Básica (gerar conhecimento sem finalidades de aplicação) e ii) Pesquisa Aplicada (gerar conhecimento com finalidades de aplicação);
- b) Quanto aos Objetivos: i) Exploratória (descobrir/innovar); ii) Descritiva (como?); e iii) Explicativa (por que?);
- c) Quanto as Abordagens: i) Quantitativa; e ii) Qualitativa;
- d) Quanto aos Procedimentos: i) Survey; ii) Pesquisa-Ação; iii) Estudo de Caso Único ou Múltiplos; iv) Operacional; e v) Experimental.

Além disso, os métodos para a coleta dos dados podem ser por meio de (i) observação do participante, (ii) grupos focados, (iii) entrevistas, (iv) questionário, (v) experimentação e (vi) observação.

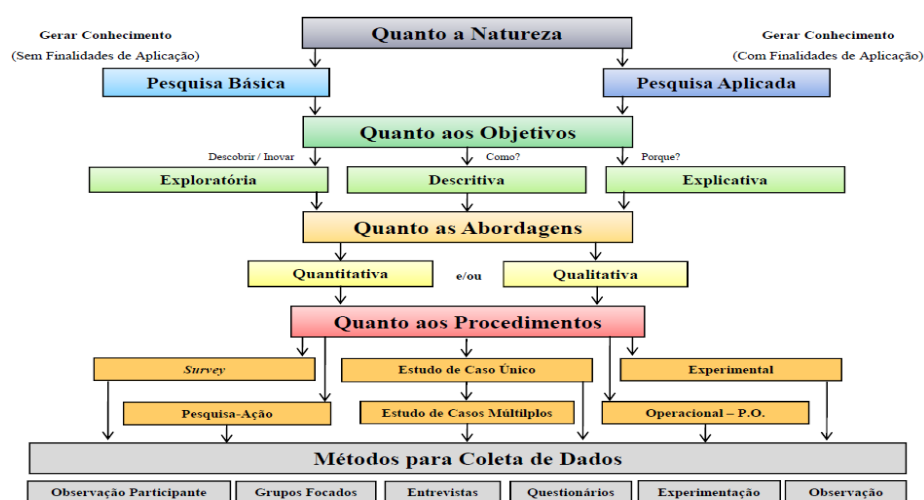


Figura 1 Tipos de pesquisa científica

Fonte: Jung (2009)

Quanto à natureza, este trabalho pode ser classificado como **pesquisa aplicada**, pois foi realizada sobre um problema com finalidades de aplicação. Quanto aos seus objetivos, este trabalho pode ser caracterizado como **pesquisa exploratória**, pois técnicas de inteligência computacional foram avaliadas para descobrir possíveis métodos para a previsão do mercado financeiro. Quanto à sua abordagem, este trabalho pode ser caracterizado como **pesquisa quantitativa**, pois se teve como finalidade a medição e a análise de sistemas utilizando duas técnicas de inteligência computacional: lógica *fuzzy* e RNAs. Quanto aos procedimentos, este trabalho pode ser caracterizado como **estudo de caso**, pois um estudo da aplicação da lógica *fuzzy* e das RNAs é apresentado. A

coleta de dados deste trabalho é feita por meio de **observação** de dados financeiros históricos.

1.3.2 Procedimentos metodológicos

Inicialmente, uma pesquisa bibliográfica foi realizada a fim de levantar conceitos de mercado financeiro, de lógica *fuzzy* e de RNAs. Em seguida, alguns trabalhos relacionados à previsão do mercado financeiro foram analisados, os quais possibilitaram verificar como técnicas de inteligência computacional podem ser utilizadas para este tipo previsão.

Em seguida, foram estabelecidas, para a construção da modelagem utilizando a lógica *fuzzy*, (i) a definição dos universos de discurso das variáveis linguísticas, (ii) a definição da quantidade de termos primários e graus de pertinência dos conjuntos *fuzzy* que representam cada termo, (iii) a determinação das regras que formam o mecanismo de controle e (iv) a definição de parâmetros de projeto, como método de inferência, lógica a ser empregada, forma de "defuzzificação" e atuação do controlador. Após a construção dessa modelagem, um sistema *web mobile* foi implementado para possibilitar a sua avaliação.

Em seguida, foi construída a modelagem utilizando RNAs. Para isso, a modelagem anterior foi utilizada como base, para que cada máquina de inferência *fuzzy* possuísse uma representação nas RNAs. Além dessas, RNAs auxiliares foram utilizadas, o que possibilitou melhor comparação entre ambas as modelagens. Da mesma forma, um sistema *web* foi implementado para viabilizar a sua avaliação.

Após o desenvolvimento e a implementação dessas duas modelagens, os seus módulos foram recombinados e reorganizados, o que permitiu desenvolver seis modelagens híbridas com respectivas implementações. Em seguida, observações, análises e constatações foram feitas a respeito das diferenças e das

semelhanças dos resultados obtidos pelos oito sistemas entre si e com os dados históricos reais.

1.4 Estrutura do trabalho

Este trabalho está organizado da seguinte forma.

Trabalhos relacionados aos assuntos abordados por essa dissertação são tratados no Capítulo 2.

Conceitos, propriedades e fundamentos da técnica de inteligência computacional lógica *fuzzy* são abordados sucintamente no Capítulo 3.

Breve resumo dos conceitos, das propriedades, dos fundamentos, o lado histórico e o funcionamento da técnica de inteligência computacional RNAs são apresentados no Capítulo 4.

Conceitos, definição e cálculo dos indicadores financeiros para realizar análise técnica são tratados no Capítulo 5.

Metodologia e análise aplicadas nas modelagens utilizando lógica *fuzzy* e RNAs são apresentadas no Capítulo 6.

Considerações finais com conclusões, contribuições, limitações e sugestões de trabalhos futuros são discutidos Capítulo 7.

2 TRABALHOS RELACIONADOS

O desenvolvimento da computação e de técnicas de inteligência computacional tem proporcionado melhor compreensão dos chamados sistemas complexos e não lineares. Um sistema complexo é um sistema não pré-determinístico que evolui no tempo com comportamento desequilibrado e aperiódico, sendo que o estado futuro é extremamente dependente do estado atual, podendo ser mudado radicalmente a partir de pequenas mudanças no presente. Estes sistemas se caracterizam por apresentar um comportamento não linear, cujos fatores, de diferente natureza, são influenciados com a evolução do tempo (REZENDE, 2002).

O surgimento de novas técnicas computacionais proporcionou melhor entendimento da estrutura desses sistemas, fornecendo dados experimentais suficientes que levam a melhor compreensão do seu comportamento. Com relação ao mercado de ativos financeiros, os métodos estatísticos são uma alternativa para entender e prever o mercado. Porém, técnicas de inteligência computacional, tais como, RNAs, lógica *fuzzy* e algoritmos genéticos, podem ser encontradas em diversos trabalhos desenvolvidos por pesquisadores para concretizar essa previsão. Alguns desses estudos são brevemente descritos.

Em um trabalho (GHIASSI; SAIDANE; ZIMBRA, 2005), estudos comparativos entre RNAs quanto a forma para a previsão de eventos de séries temporais foram apresentados. A partir desses estudos, um modelo de RNA dinâmico foi proposto para a previsão de eventos de séries temporais que utiliza uma arquitetura diferente dos modelos tradicionais. Nesse modelo, uma RNA com um processo iterativo sequencial de aprendizagem foi utilizada a abordagem de *backpropagation*. Dados de séries temporais, a partir dos dados da literatura, foram utilizados para avaliar a eficácia. Esses resultados mostraram

que o modelo foi preciso e executa significativamente melhor do que métodos tradicionais, bastando escolher as variáveis de entrada.

Evidências empíricas apontaram que modelos de RNAs programados geneticamente consistem em um quadro promissor para a modelagem de séries temporais não lineares (MENEZES; NIKOLAEV, 2006). Com essas evidências, notou-se que esses modelos podem superar outras abordagens não lineares e podem ser aplicáveis à série temporal em períodos de até 120 meses. Resumindo, três conclusões principais podem ser destacadas: i) o sistema utilizando estes modelos de RNAs pode descobrir polinômios que melhor capturam a dinâmica das séries temporais em períodos de 24 horas; ii) este modelo pode ajudar a compreender as dependências de uma série de tempo, pois variáveis significativas de entrada durante o aprendizado são isoladas; e iii) a parcimônia do modelo afeta o desempenho de previsão.

Uma abordagem para investigar a previsibilidade das taxas de câmbio nos períodos de 1, 3 e 6 meses por meio de especificações lineares e não lineares foi apresentada para a construção de modelos de previsão com base nessas especificações (PREMINGER; FRANCK, 2007). Com os resultados obtidos, observou-se que os modelos não lineares podem proporcionar melhor desempenho fora da amostra, em comparação aos modelos lineares. No entanto, o desempenho de previsão do modelo proposto é menos satisfatório comparado aos modelos que possuem propriedades de ajuste instantâneo, os quais são utilizados para prever mercados em que as variações de preços são independentes da sequência de negociações. A utilização dessa abordagem deve ser generalizada para estudar a previsibilidade das taxas de câmbio e pode ser aplicada a outras questões de previsão, por exemplo, prever taxas de câmbio com os fundamentos monetários ou previsão de outras séries de retornos financeiros.

Um modelo híbrido entre RNA e séries temporais financeiras para prever a volatilidade do índice de preço dos ativos financeiros foi proposto, especificando que RNAs e séries temporais podem aumentar o poder preditivo para a perspectiva de desvio e precisão de direção do preço (ROH, 2007). Nesse trabalho, coeficientes de variáveis de entrada de processo financeiro de séries temporais foram encontrados e variáveis que influenciam os resultados utilizando a análise de domínio do mercado de ativos financeiros foram obtidas. Nesses resultados experimentais, percebeu-se que o modelo pode ser melhorado para prever a volatilidade das séries temporais dos preços do índice.

Uma ampla revisão de técnicas inteligentes e estatísticas para prever falências em bancos e empresas entre os anos 1968 e 2005 foi apresentada, concluindo a importância da utilização de técnicas inteligentes para realizar essa previsão (KUMAR; RAVI, 2007). Nesse trabalho, foi relatado que técnicas estatísticas não são mais empregadas e técnicas de inteligência computacional foram as mais utilizadas, entre elas, RNA, lógica *fuzzy* e abordagens evolutivas. Dadas às limitações das técnicas de inteligência computacional, a pesquisa realizada pelo autor com esse trabalho sinalizou a importância de investigar novas arquiteturas de computação flexível (sistemas híbridos inteligentes), a fim de ampliar as vantagens dos modelos individuais e minimizar as suas limitações.

Algoritmos de aprendizagem *neurofuzzy* foram apresentados para prever a taxa de câmbio, agrupando conjuntos de dados de séries temporais de forma granular e utilizando intervalos estatísticos (ZHANG; WAN, 2007). Estes intervalos são baseados em médias, erros máximos de estimativa e desvios padrão utilizados para a aprendizagem *neurofuzzy* para descobrir regras *fuzzy* SE-ENTÃO. Com o resultado dessa abordagem, obteve-se um auxílio na previsão da taxa de câmbio e na tomada de decisão.

Estudos para melhorar a previsão de séries temporais difusas com aplicação de RNAs foram apresentados como dois modelos bivariados, tendo o

preço dos ativos financeiros e os índices futuros correspondentes como entrada para as RNAs a fim de prever o movimento do dia seguinte (YU; HUARNG, 2008). Os resultados demonstraram que o modelo bivariado baseado em séries temporais *fuzzy* obteve melhor desempenho em comparação ao modelo bivariado de regressão. No entanto, esse modelo obteve pior desempenho dentre outros modelos bivariados.

O desenvolvimento de um sistema *neurofuzzy* para prever as tendências dos preços dos ativos financeiros foi abordado a partir de perspectivas conceituais e técnicas, justificando os seus aspectos de modelagem (ATSALAKIS; VALAVANIS, 2009). Os resultados mostraram que, quando dados históricos são utilizados, é possível prever os preços dos ativos financeiros. Esta declaração foi apoiada por vários estudos de caso de diferentes ativos financeiros de dois mercados financeiros (um emergente e um desenvolvido). Com esse, foi possível averiguar o potencial da utilização da modelagem *neurofuzzy* para a previsão do mercado financeiro.

Um estudo de um modelo utilizando o sistema *fuzzy* Takagi-Sugeno-Kang com base de regras de indicadores técnicos (como variáveis de entrada) foi relatado e testado na Bolsa de Valores de Tóquio e em alguns índices da Bolsa de Valores de Teerã, tais como Índice Total, *Top 50 Index*, Índice de Indústria e Índice *Financial Group* (ESFAHANIPOUR; AGHAMIRI, 2010). Os resultados de desempenho superaram outras abordagens, tais como as redes neurais *backpropagation*. Além disso, neste trabalho, aperfeiçoamentos são sugeridos com o objetivo de prever a tendência de variação de preços, incluindo vários fatores influentes, tais como, razões políticas, análise fundamental, indicadores técnicos e mudança macro econômica. Cabe ressaltar que esse sistema pode ser utilizado com o propósito de negociação diária.

Os trabalhos resumidamente apresentados buscam de certa forma prever movimentos futuros de preços, porém eles divergem quanto às técnicas e aos

métodos utilizados para a previsão. Nesta dissertação, são utilizados cinco indicadores técnicos como dados de entrada. Apesar da utilização destes cinco indicadores, as modelagens são extensíveis, o que permite a inclusão de outros indicadores técnicos e outros tipos de entrada de diferentes naturezas, tais como, indicadores fundamentalistas. Como pôde ser visto nos trabalhos relacionados, há trabalhos que utilizam indicadores técnicos como dados de entrada, porém eles não mostram flexibilidade e extensibilidade de modo a receber tipos de entrada de diferentes naturezas.

Além disso, apesar desta dissertação estar limitada ao uso de duas técnicas de inteligência computacional, pode-se utilizar outras técnicas, por exemplo, algoritmo genético. Isso é possível por causa da modularidade das modelagens que permite flexibilidade e extensibilidade na sua utilização e na construção de modelagens híbridas.

3 LÓGICA FUZZY

3.1 Considerações iniciais

A primeira ocorrência da expressão "lógica *fuzzy*" para ser utilizada com base na teoria de conjuntos *fuzzy* foi usada no artigo *Fuzzy Sets* (ZADEH, 1965). Nesse artigo, foi demonstrado matematicamente o tratamento dos aspectos imprecisos e ambíguos apresentados na lei da contradição. Esta lei, proposta por Jan Lukasiewicz em 1930, preconiza que uma determinada afirmação pode ser verdadeira e falsa ao mesmo tempo (OTTAVIANO; FEITOSA, 2003). Isso se torna possível desde que não apresentem apenas dois níveis (verdadeiro e falso), mas um grau de verdade, o que acarreta a existência vários níveis (CAMPOS FILHO, 2004). Essa é a ideia da lógica *fuzzy*, a não restrição entre apenas dois valores afirmada na lógica clássica, verdadeiro e falso, preto e branco, mas, por exemplo, vários tons de cinza que indicam a ideia de conjuntos com graus de pertinência.

A lógica *fuzzy* trata de um raciocínio que busca classificar em números uma determinada realidade ou situação que trabalha com muitas variáveis incertas e vagas, a fim de facilitar o trabalho e a manipulação dos computadores (SHAW; SIMÕES, 1999). Assim, a lógica *fuzzy* busca uma generalização da lógica clássica, flexibilizando-a entre $[0,1]$ de modo que a implementação de um projeto de sistema *fuzzy* possa ser reduzida a um ponto em que problemas anteriormente intratáveis passam a ter possíveis soluções. A característica de lidar com a imprecisão e a ambiguidade da linguagem natural fez com que a lógica *fuzzy* se tornasse alvo de pesquisas em diversas áreas, por exemplo, controle de sistemas e inteligência artificial (BOTELHO, 2002).

Este capítulo está organizado da seguinte forma. Benefícios dos modelos baseados em lógica *fuzzy* são discutidos na Seção 3.2. Aplicações utilizando

lógica *fuzzy* são relatadas na Seção 3.3. Conceitos dos conjuntos *fuzzy* são resumidos na Seção 3.4. Funções de pertinências e operações com os conjuntos *fuzzy* são abordadas na Seção 3.5 e na Seção 3.6, respectivamente. Fundamentos de modelagem *fuzzy* são discutidos na Seção 3.7. Sistemas baseados em lógica *fuzzy* são apresentados na Seção 3.8. Métodos de inferência *fuzzy* são tratados na Seção 3.9.

3.2 Lógica clássica versus lógica *fuzzy*

A lógica *fuzzy* incorpora regras simples baseadas em

Se X e Y então Z

utilizadas para resolver um problema de controle, em vez da tentativa de modelar um sistema matematicamente.

Para representar apropriadamente o conhecimento do mundo com algum formalismo, é necessário expressar não somente proposições verdadeiras ou falsas, mas expressar/descrever objetos e generalizações sobre categorias de objetos. Com a lógica clássica, pode-se descrever e generalizar. Uma das vantagens dessa representação é a facilidade de manipular e deduzir novos fatos a partir de fatos conhecidos. Uma das desvantagens é a dificuldade para determinar quais fatos podem ou não ser relevantes durante um processo (THÉ, 2001).

A lógica *fuzzy* apresenta as seguintes vantagens em relação à lógica clássica (PEREIRA, 2010):

- a) naturalidade a torna conceitualmente fácil de entender;
- b) flexibilidade;

- c) tolerância com dados imprecisos;
- d) possibilidade de modelar as funções não lineares;
- e) possibilidade de ser construída com base na experiência de especialistas;
- f) possibilidade de ser integrada às técnicas convencionais de controle;
- g) simplificação ou ampliação das possibilidades e dos recursos dos métodos convencionais de controle, em muitos casos;
- h) baseada na linguagem natural, base da comunicação humana.

A lógica *fuzzy* tem sido bastante empregada em vários campos de pesquisa, por ser capaz de modelar e descrever processos reais desconhecidos, com características não lineares e variáveis no tempo (VIEIRA; LING, 2006). Um benefício significativo dos modelos baseados em lógica *fuzzy* é a habilidade de codificação de conhecimentos inexatos, em uma forma que se aproxima dos processos de decisão. Os sistemas de inferências baseados em lógica *fuzzy* possibilitam a captura do conhecimento próximo ao "modelo cognitivo" utilizado na análise de problemas. Isto significa que o processo de aquisição do conhecimento é mais fácil e confiável e menos sujeito a erros não identificados (RUHOFF et al., 2005).

3.3 Aplicações da lógica *fuzzy*

Ao longo dos últimos 30 anos, o desenvolvimento de vários métodos matemáticos e conceitos têm ampliado a aplicação prática da lógica *fuzzy*, principalmente na concepção de controladores de processos industriais complexos (MASSAD; ORTEGA; STRUCHINER, 2003). Os japoneses foram os pioneiros na utilização da lógica *fuzzy*, adquirindo conhecimento por

aplicarem com frequência no aperfeiçoamento de diversos aparelhos elétrico-eletrônicos.

A lógica *fuzzy* pode ser encontrada em aparelhos como aspiradores de pó, que utilizam controladores *fuzzy* nos sensores de pó, ajustando o poder de sucção por meio de complexos mecanismos. Além disso, há dispositivos nas câmeras fotográficas inteligentes que medem a claridade das imagens em seis regiões do campo de visão; essas informações determinam o foco e rastreiam a taxa de mudança no movimento da lente, procurando o melhor foco. Outro exemplo é as máquinas de lavar da empresa *Hitachi*, que utilizam controladores *fuzzy* para verificar peso, tipo de tecido e tipo de sujeira e, automaticamente, adaptar ciclos de lavagem para a utilização otimizada de potência, de água e de detergente (CAMBOIM, 2008).

A lógica *fuzzy* não é utilizada apenas para facilitar o dia a dia, mas para diminuir gastos nas execuções de tarefas, como no caso do aparelho de ar condicionado industrial projetado pela empresa *Mitsubishi*. Esse aparelho possui um controlador *fuzzy* que utiliza 25 regras *fuzzy* de aquecimento e 25 regras *fuzzy* de refrigeração. Comparado com outros tipos de ar condicionado, a utilização desse controlador *fuzzy* permite a esse aparelho aquecer e esfriar cinco vezes mais rápido, reduzir o consumo de energia e manter a temperatura duas vezes mais estável (PEREIRA, 2010).

Além desses exemplos, percebe-se que a utilização da lógica *fuzzy* vem crescendo a cada dia nas diversas áreas. Por exemplo, várias empresas a aplicam para reconhecimento de caracteres (*scanners*); na indústria automotiva, destaca-se nas transmissões automáticas (*Nissan* e *Lexus*), na injeção eletrônica, na suspensão ativa e nos freios antibloqueantes (*ABS*). Sistemas industriais a incluem no controle de grupo de elevadores (*Hitachi* e *Toshiba*), nos veículos autoguiados, nos robôs móveis (*Nasa* e *IBM*), na ventilação de túneis urbanos (*Toshiba*) e no controle de tráfego urbano (*Sendai*) (PEREIRA, 2010).

Existem várias empresas (*Siemens, Daimler-Benz, Klockner-Moeller, SGS-Thomson, General Motors, Motorola, Hewlett-Packard, etc.*) que possuem laboratórios de pesquisa em lógica *fuzzy* para desenvolvimento de seus produtos (ORTEGA, 2001). No Brasil, algumas indústrias e empresas vêm desenvolvendo produtos e serviços, por exemplo, *Otis* (com elevadores inteligentes), *Villares* (peças para guindastes e empilhadeiras), *IBM* (na área de computação), *Yokogawa* (com medidores de umidade) e *Robertshaw* (controles eletromecânicos, termostatos, *timers*) (RUHOFF et al., 2005).

As aplicações da lógica *fuzzy* são ainda incipientes ou insuficientemente desenvolvidas apesar do seu potencial de aplicação (MASSAD; ORTEGA; STRUCHINER, 2003). Porém, uma abordagem interdisciplinar pode orientar e motivar profissionais de diferentes áreas para comporem equipes a fim de contornarem dificuldades que ainda limitam as aplicações da lógica *fuzzy*. Embora haja consenso sobre a necessidade de técnicas de representação de incerteza, o debate sobre a metodologia mais adequada está longe do fim (PEREIRA, 2010).

3.4 Conjuntos *fuzzy*

Os conjuntos *fuzzy* são conjuntos que não possuem fronteiras bem definidas. Esses conjuntos são utilizados por causa dos conjuntos da lógica clássica apresentarem limitações para lidar com problemas em que as transições de uma classe para outra acontecer de forma suave. Sua definição, suas propriedades e suas operações são obtidas da generalização da teoria de conjuntos clássicos, recaindo em um caso particular da teoria de conjuntos *fuzzy* (BOTELHO, 2002). Para obtenção da formalização matemática de um conjunto *fuzzy*, houve o embasamento no fato de qualquer conjunto clássico poder ser

caracterizado por uma função, denominada função característica (ZADEH, 1965), cuja definição é:

Seja U um conjunto universo e A um subconjunto de U . A função característica de A é dada por:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases}$$

sendo x um elemento de U , ou seja, a função característica é um mapeamento do conjunto universo no conjunto $\{0,1\}$.

Essa função característica discrimina, entre os elementos de U , aqueles que pertencem ou não ao subconjunto A segundo algum critério, dividindo o conjunto U em duas partes com fronteira bem definida. Todavia, existem casos em que a pertinência entre elementos e conjuntos não é precisa, isto é, não se sabe se um elemento pertence ou não a um conjunto. Por outro lado, pode-se saber qual elemento do conjunto U se enquadra "melhor" ao termo que caracteriza o subconjunto A . Por exemplo, seja o subconjunto dos números reais "próximos de 2" (LIMA, 2011), cuja representação é:

$$A = \{x \in \mathbb{R} \mid x \text{ é próximo de } 2\}$$

Como responder as seguintes perguntas: i) o número 7 pertence ao subconjunto A ?; e ii) o número 2,001 pertence ao subconjunto A ? A resposta para estas perguntas é incerta, pois não se sabe até que ponto pode-se dizer objetivamente quando um número está próximo de 2. Neste caso, a única

afirmação razoável é: o número 2,001 está mais próximo de 2 do que o número 7.

Para obtenção dos conjuntos *fuzzy*, é preciso generalizar a função característica da lógica clássica para o intervalo $[0,1]$, ou seja, $\mu_A(x) = U \rightarrow [0,1]$, o que implica em considerar valores de pertinência e não apenas "pertence" e "não pertence". Assim, o elemento x pertencerá ao subconjunto A com um grau de pertinência cujo valor está no intervalo $[0,1]$. De modo análogo, pode-se considerar o grau de pertinência como uma medida que expressa a possibilidade que um dado elemento seja membro de um conjunto *fuzzy* (BOTELHO, 2002).

3.5 Função de pertinência

Cada conjunto *fuzzy* é caracterizado pela sua função de pertinência que corresponde a uma curva que define o grau de pertinência (valor entre 0 e 1) de cada entrada. Para exemplificar o conceito de função de pertinência, tem-se a classificação da estatura de uma pessoa alta, média ou baixa, tendo três grupos de classificação: baixo, médio e alto. Os conjuntos de pessoas de estatura baixa, média e alta utilizando o método convencional de conjuntos e utilizando o método *fuzzy*, mostrando as funções de pertinência de cada um dos conjuntos, são ilustrados na Figura 2 e na Figura 3, respectivamente (SILVA, 2009).




Figura 2 Função características do conjunto (método convencional)

Fonte: Silva (2009)




Figura 3 Função característica do conjunto *fuzzy*

Fonte: Silva (2009)

Em ambos os gráficos, os graus de pertinência (intervalo de 0 a 1) estão no eixo vertical, a altura de cada pessoa é representada no eixo horizontal e a função de pertinência associa cada entrada (altura) a uma saída (grau de pertinência) (lado esquerdo). Na Figura 3, pode-se observar que uma pessoa com altura 1,85 m possui grau de pertinência de 0,7 para estatura alta e 0,2 para estatura média. Por outro lado, na Figura 2, pode-se perceber que não é trivial definir se a estatura de uma pessoa com 1,85 m é média ou alta.

Vale salientar que as funções de pertinência podem assumir várias formas, ficando a cargo do projetista a escolha da forma mais conveniente para sua aplicação. Um conjunto *fuzzy* é caracterizado por uma função de pertinência e o grau de pertinência pode ser considerado como uma medida que expressa a possibilidade de um dado elemento ser membro de um conjunto *fuzzy* (SANTOS, 2010).

Quando os conjuntos *fuzzy* são contínuos sua representação é a própria função de pertinência. As formas para as funções de pertinência são totalmente arbitrárias. Todavia, as funções mais utilizadas são (SANTOS, 2010):

Crescente. Essa função é definida pela Equação 1 e representada na Figura 4;

$$A(x) = \begin{cases} \left(\frac{b}{c-a}\right)(x-a), & \text{quando } a \leq x \leq c \\ 0, & \text{caso contrário} \end{cases} \quad (1)$$




Figura 4 Função de pertinência crescente

Decrescente. Essa função é definida pela Equação 2 e representada na Figura 5;

$$A(x) = \begin{cases} \left(\frac{b}{a-c}\right)(x-c), & \text{quando } a \leq x \leq c \\ 0, & \text{caso contrário} \end{cases} \quad (2)$$




Figura 5 Função de pertinência decrescente

Triangular. Essa função é definida pela Equação 3 e representada na Figura 6;

$$A(x) = \begin{cases} b \left(\frac{1 - |x - a|}{s} \right), & \text{quando } a - s \leq x \leq a + s \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$




Figura 6 Função de pertinência triangular

Fonte: Silva (2009)

Trapezoidal. Essa função é definida pela Equação 4 e representada na Figura 7.

$$A(x) = \begin{cases} \frac{(a-x)s}{a-b}, & \text{quando } a \leq x \leq b \\ s, & \text{quando } b \leq x \leq c \\ \frac{(d-x)s}{d-c}, & \text{quando } c \leq x \leq d \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$




Figura 7 Função de pertinência trapezoidal

Fonte: Silva (2009)

Gaussiana. Essa função é definida pela Equação 5 e representada na Figura 8.

$$A(x) = c \cdot e^{-\frac{(x-a)^2}{b}} \quad (5)$$




Figura 8 Função de pertinência gaussiana

Fonte: Silva (2009)

As funções crescente, decrescente, triangular e trapezoidal são as mais populares por causa da sua simplicidade. O custo computacional adicional exigido pelos outros tipos de função não refletem, em geral, em uma melhoria significativa na qualidade dos valores de saída dos sistemas (ORTEGA, 2001).

3.6 Operações com conjuntos *fuzzy*

Os conjuntos *fuzzy* possuem operações de intersecção, de união, de negação, entre outras (SANDRI; CORREA, 1999). A seguir, as definições dessas operações com suas respectivas representações gráficas (RADU; WILKERSON, 1996) são apresentadas. Sejam A e B subconjuntos de um mesmo universo de discurso.

A definição da operação de união é determinada pela Equação 6. A união é implementada pelo conectivo lógico OU (OR) e pode ser ilustrada conforme apresentada na Figura 9.




Figura 9 Operação de união

Fonte: Magalhães (2009)

A definição da operação de intersecção é determinada pela Equação 7. Esta operação é implementada pelo conectivo lógico E (AND) e pode ser ilustrada conforme apresentada na Figura 10.

$$A \cap B = \min\{\mu_A(u), \mu_B(u)\} \quad (7)$$




Figura 10 Operação de intersecção

Fonte: Magalhães (2009)

A definição da operação de negação é determinada pela Equação 8. Esta operação é implementada pelo conectivo NÃO (*NOT*) e pode ser ilustrada conforme apresentada na Figura 11.

$$\bar{B} = \{1 - \mu_B(u)\} \quad (8)$$




Figura 11 Operação de negação

Fonte: Magalhães (2009)

Por outro lado, sejam dois conjuntos *fuzzy* definidos em universos de discurso diferentes, ou seja, A em X e B em Y, tem-se a noção de produto cartesiano entre conjuntos *fuzzy* determinada pela Equação 9. O produto cartesiano $A \times B$ é uma relação R contida no produto cartesiano $X \times Y$ e pode ser ilustrada conforme apresentada na Figura 12 (BARROS, 2002).

$$A \times B = \{(x, y), \mu_{A \times B}(x, y)\} \forall x \in X, \forall y \in Y \quad (9)$$




Figura 12 Produto cartesiano

Fonte: Magalhães (2009)

As relações de causa e consequência, fundamental na técnica de modelagem de sistemas com base em lógica *fuzzy*, são definidas pela operação de inferência *fuzzy* e simbolizada por " \rightarrow ". Considerando cada relação R como uma regra, que consiste em uma "premissa" (conjunto A) e uma "consequência" (conjunto B) da aplicação da operação de inferência *fuzzy*, a inferência é determinada pela Equação 10.

$$A \rightarrow B = (A \times B) \cup (\bar{A} \times Y) \quad (10)$$

Sejam os valores $x \in A$ e $y \in B$, A e B conjuntos *fuzzy* definidos respectivamente nos universos de discurso X e Y. Sem discordar da definição da Equação 10, para a relação *fuzzy* $R = A \rightarrow B$, as formas práticas de inferências *fuzzy* são determinadas pela Equação 11, pela Equação 12,

pela Equação 13 e pela Equação 13 (SANDRI; CORREA, 1999; WEBER; KLEIN, 2003).

$$\mu_{\bar{A}}(x, y) = \mu_{A \times \bar{B}}(x, y) = \min[\mu_A(x), \mu_{\bar{B}}(y)] \quad (11)$$

$$\mu_{\bar{B}}(x, y) = \mu_{A \times \bar{B}}(x, y) = \min[1, (1 - \mu_A(x) + \mu_{\bar{B}}(y))] \quad (12)$$

$$\mu_{\bar{B}}(x, y) = \mu_{A \times \bar{B}}(x, y) = \min[1, (\mu_A(x) + \mu_{\bar{B}}(y))] \quad (13)$$

$$\mu_{\bar{B}}(x, y) = \mu_{A \times \bar{B}}(x, y) = \min[1, \mu_{\bar{B}}(y)/\mu_A(x)] \quad (14)$$

3.7 Fundamentos da modelagem *fuzzy*

Um sistema caracterizado por n variáveis pode ser modelado por um sistema *fuzzy* de acordo com o entendimento e com as experiências práticas de uma pessoa especializada em determinado assunto a respeito de como este sistema se desenvolve no decorrer de sua observação e operação (MAGALHÃES, 2009).

Os modelos *fuzzy* têm como principais características a facilidade de compreensão, por sua simplicidade estrutural. Em geral, eles são de grande destreza para a solução de problemas não lineares e aproximação de comportamentos complexos, cujas variáveis são pouco compreensíveis (MENDEL, 2003).

A construção de um sistema *fuzzy* inicia-se pela identificação de variáveis linguísticas que representam as variáveis de entrada e de saída do sistema. A ideia central é desobrigar-se de boa parte dos padrões matemáticos rigorosos para mensurar os estados das variáveis de um sistema dinâmico. Estas

variáveis, quando analisadas durante a observação do comportamento, deixam de ser consideradas e aferidas somente de forma numérica exata e passam a admitir que os seus estados sejam descritos segundo palavras, usuais na forma subjetiva de pensar e de se comunicar do ser humano (THIELE, 1999).

Os vocábulos, que transmitem um conhecimento incerto a respeito do estado de uma variável, são abstraídos e concebidos matematicamente por meio da construção de alguns conjuntos *fuzzy*, os quais recebem o nome do termo de valor linguístico que representam. Um conjunto *fuzzy* denotado por T_x^i é denominado "termo linguístico" da variável x (LAMBERT-TORRES; SILVA; ROSSI, 2002).

Em geral, os termos linguísticos são adjetivos empregados para caracterizar de forma subjetiva o estado de uma variável. Por exemplo, o termo $T_x^i = \text{Ambiente}$ para qualificar uma variável " $x = \text{Temperatura}$ " na frase "À temperatura ambiente ocorrem reações que demandam 136 kcal" (LEWIS, 1995). Sendo a variável $x = \text{Temperatura}$, ela pode ser associada ao conjunto $T(x) = \{T_x^1, T_x^2, T_x^3\}$ com $T_x^1 = \text{alta}$, $T_x^2 = \text{baixa}$ e $T_x^3 = \text{ambiente}$, definidos intuitiva ou estatisticamente, de acordo com os critérios de apreciação da variável adotados (a partir de quantos graus Celsius a temperatura é considerada alta? Ou baixa? Ou ambiente?) (MAGALHÃES, 2009).

Assim, a criação de um sistema especialista baseado em regras linguísticas resulta na representação do processo ao qual é proposta a modelagem. Esta representação são relações *fuzzy* entre as ideias e os fatos do evento observado com o enunciado das possíveis proposições entre os vocábulos.

Termos linguísticos são utilizados para propor uma caracterização aproximada para fenômenos cujos estados das variáveis são mal definidos quantitativamente, transmite-se a expressão da semântica utilizada por pessoas. Essa transmissão é feita por meio de afirmações verbais nas quais é declarada a associação da variável com cada termo linguístico que conota um estado (LEWIS, 1995).

A descrição de um sistema utilizando lógica *fuzzy* é feito com conjecturas lógicas que descrevem a relação entre suas variáveis. Estas conjecturas mapeiam os elementos de um universo de discurso, X , de entradas em outro conjunto, Y , de saídas. Nelas, as leis do sistema são implementadas sob a forma de proposições condicionais, no qual as variáveis de entrada (X) estão dispostas nas premissas das proposições e as variáveis de saída (Y) estão nas consequências (MATLAB..., 2012).

Com o uso de termos linguísticos para qualificar as variáveis de um evento, características *fuzzy* são conferidas às proposições. Por causa destas características, tais conjecturas são denominadas proposições condicionais *fuzzy*, as quais são a chave do mecanismo de funcionamento do modelo *fuzzy* (MENDEL, 2003). Essas proposições descrevem regras de controle linguísticas ou simplesmente regras linguísticas, que implementam computacionalmente a base de conhecimento do sistema especialista (LAMBERT-TORRES; SILVA; ROSSI, 2002).

3.8 Sistemas baseados em lógica *fuzzy*

Os sistemas *fuzzy* podem produzir estimativas de um sistema não linear complexo desde que informações de especialista sejam fornecidas com entrada para esses sistemas. A lógica de tomada de decisões, incorporada na estrutura de

inferência da base de regras, usa inferência *fuzzy* para simular tomada de decisão humana (PEREIRA, 2010).

Os sistemas *fuzzy* são o resultado de uma generalização dos sistemas clássicos, ou seja, nessa abordagem, os conceitos *fuzzy* são incorporados a esses sistemas. Os sistemas *fuzzy* estimam funções com descrição parcial do comportamento do sistema, onde especialistas podem prover o conhecimento heurístico ou esse conhecimento pode ser inferido a partir de dados de entrada e de saída do sistema. Desta forma, pode-se dizer que os sistemas *fuzzy* são sistemas baseados em regras que utilizam variáveis linguísticas *fuzzy* para executar um processo de tomada de decisão (THÉ, 2001).

O conhecimento não é um valor ou conceito preciso e/ou exato, ele pode refletir ao mesmo tempo o quanto se sabe e o quanto não se sabe, sem que ambos sejam complementares. Quanto maior a quantidade de informações com qualidade, mais certo e preciso ele é, contudo continua a expressar um desconhecimento ou incerteza (PEREIRA, 2010).

Um modelo esquemático da máquina de inferência *fuzzy* é ilustrado na Figura 13. Um modelo linguístico *fuzzy* é um sistema baseado em regras que usa a teoria de conjuntos *fuzzy* para lidar com um fenômeno particular (COSTA, 2004). Em geral, cada entrada *fuzzy* (um número real ou par de números reais ou n-upla de números reais) tem uma saída *fuzzy* correspondente. Neste caso, um sistema *fuzzy* é uma função de \mathbb{R}^n em \mathbb{R} , construída de alguma maneira específica. A estrutura básica de um sistema *fuzzy* inclui quatro componentes (ou módulos) principais: i) um "fuzzificador"; ii) um mecanismo de inferência; iii) uma base de regras; e iv) um "defuzzificador".

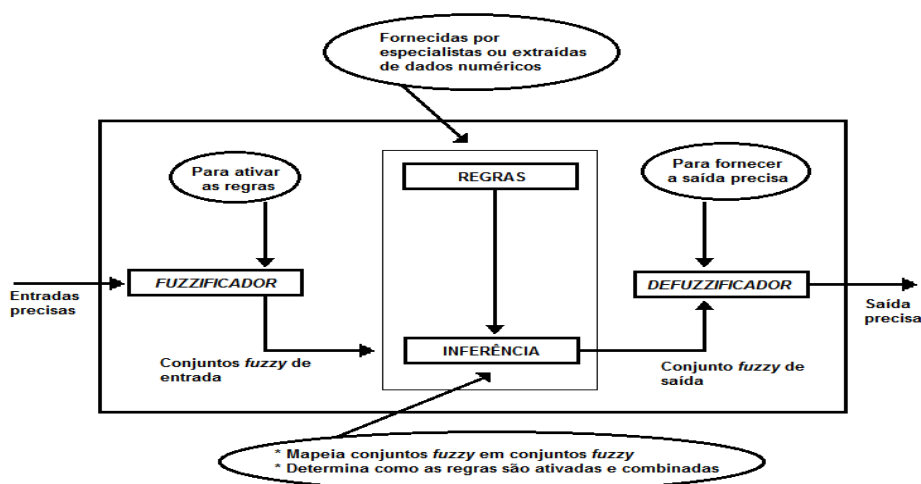


Figura 13 Máquina de inferência *fuzzy*

Fonte: Ortega (2001)

3.8.1 Módulo de fuzzificação

O módulo "fuzzificador" é número clássico valorado, que se traduz por entradas em valores *fuzzy*. Com esse módulo, pode-se modelar matematicamente a informação das variáveis de entrada por meio de conjuntos *fuzzy*. Além disso, ele mostra a importância do especialista no processo a ser analisado, pois termos linguísticos que representam os estados das variáveis deve ser atribuído para cada variável de entrada e um conjunto *fuzzy* por uma função de pertinência deve ser associado para cada termo linguístico (PEREIRA, 2010).

A "fuzzificação" é o processo de associar ou calcular um valor para representar um grau de pertinência da entrada em um ou mais grupos qualitativos, chamados de conjuntos *fuzzy*. O grau de pertinência é determinado por uma função de pertinência que foi definida com base na experiência ou intuição. Funções de pertinência são o meio pelo qual um controlador é

sintonizado para alcançar respostas desejadas a determinadas entradas (DIAS et al., 2005).

O processo de "fuzzificação" envolve a definição de entradas e saídas, bem como as respectivas funções de pertinência que transformam o valor numérico de uma variável em um grau de adesão a um conjunto *fuzzy*, que descreve uma propriedade da variável. Uma vez que nem todas as variáveis têm a mesma importância, é necessário estabelecer uma forma de orientar a influência de cada variável na pontuação final (OCAMPO-DUQUE et al., 2006).

3.8.2 Módulo da base de regras

Este módulo é o núcleo do sistema e é nele onde as variáveis e suas classificações linguísticas estão "guardadas". A regra *fuzzy* é uma unidade capaz de capturar algum conhecimento específico e um conjunto de regras é capaz de descrever um sistema em suas várias possibilidades. Cada regra *fuzzy*, da mesma forma que uma afirmação clássica, é composta por uma parte antecedente (a parte SE) e uma parte consequente (a parte ENTÃO), resultando em uma estrutura do tipo SE {antecedentes} ENTÃO {consequentes} (PEREIRA, 2010).

Os antecedentes descrevem uma condição (premissas), enquanto a parte consequente descreve uma conclusão ou uma ação que pode ser esboçada quando as premissas se verificam. A diferença entre uma regra *fuzzy* e uma regra clássica é: a primeira descreve uma condição elástica (uma condição que pode ser parcialmente satisfeita) e a segunda descreve uma condição rígida (a regra não funciona se os antecedentes não são completamente satisfeitos).

A construção do módulo de regras inclui a aplicação *fuzzy* para variáveis antecedentes, a definição dos métodos de inferência do antecedente para o

consequente de cada regra e a utilização de um método de agregação para participar nos consequentes das regras (OCAMPO-DUQUE et al., 2006).

3.8.3 Módulo de inferência

Esse módulo consiste em um mecanismo de inferência, que aplica uma estrutura de raciocínio para obter uma saída *fuzzy*. Nesse módulo, são definidos quais são os conectivos lógicos utilizados para estabelecer a relação *fuzzy* que modela a base de regras. Além disso, o sucesso do sistema *fuzzy* depende desse módulo, pois ele fornece a saída (controle) *fuzzy* a ser adotada pelo controlador a partir de cada entrada *fuzzy*. Uma vez construído o conjunto de regras *fuzzy*, necessita-se de uma máquina de inferência para obter resposta final (PEREIRA, 2010).

Existem vários métodos de inferência possíveis e a escolha depende do sistema em análise. No entanto, a inferência mais comum e amplamente utilizada no controle de sistema é o Método de Mamdani (MELO, 2009).

3.8.4 Módulo de "defuzzificação"

O resultado da operação de um sistema *fuzzy* é um conjunto *fuzzy* e, portanto, requer "defuzzificação" para chegar a um valor convencional, exigido pelo usuário não especialista (ALTUNKAYNAK; ÖZGER; ÇAKMAKCI, 2005). Neste módulo, a saída *fuzzy* é traduzida ou transformada em um valor convencional. A "defuzzificação" consiste em transformar a saída *fuzzy* em um valor numérico que pode ser utilizado em contextos não-*fuzzy* (OCAMPO-DUQUE et al., 2006).

Na "defuzzificação", o valor da variável linguística de saída, inferida pelas regras *fuzzy*, é traduzida em um valor real. O objetivo é obter um único

número real que melhor represente os valores *fuzzy* inferidos da variável linguística de saída.

Três métodos de "defuzzificação" são predominantes na literatura sobre sistemas *fuzzy*: i) Método do Centro da Área; ii) Método do Centro de Máxima; e iii) Método da Média Máxima. O Método do Centro da Área é um dos métodos mais utilizados para encontrar o número que melhor representa a saída *fuzzy*. Os outros dois métodos tendem a reforçar, no processo de "defuzzificação", a influência dos valores máximos. Em contraste, o Método do Centro da Área considera a área sobre o gráfico da função de pertinência e os resultados em um único valor que poderia ser interpretado como um valor esperado da variável em estudo (PEREIRA, 2010).

3.9 Inferência *fuzzy*

A inferência *fuzzy* é o método de raciocínio lógico pelo qual obtêm conclusões a partir dos fatos e proposições que a base de conhecimento de um sistema especialista oferece (MAGALHÃES, 2009). Efetivamente, a inferência *fuzzy* é a utilização do modelo para mapear o espaço de entradas em um espaço de saídas. Dispondo as entradas e as saídas em uma linha lógica de causa-efeito, obtêm-se conclusões a respeito da informação contida na "consequência" por meio de analogias, induções ou deduções, a partir da "premissa" (RADU; WILKERSON, 1996).

Há vários métodos para inferência *fuzzy* em um sistema *fuzzy*, porém o mais comum entre eles para a alocação do vetor de saídas é o algoritmo desenvolvido e implementado por Mamdani (*Mamdani-type*). Uma noção do funcionamento de uma inferência *fuzzy*, demonstrando-a para um sistema de múltiplas entradas e única saída (extensível a múltiplas saídas), foi apresentada anteriormente (Figura 13).

Esse funcionamento está organizado em cinco etapas críticas (WEBER; KLEIN, 2003) (Figura 14). Na primeira etapa (*Fuzzificação das Variáveis de Entrada*), um valor numérico é transformado em um termo de linguagem natural (valor *fuzzy*) utilizando uma função de pertinência. Na segunda etapa (*Aplicação das Operações Lógicas*), o resultado da "fuzzificação" é utilizado para executar operações lógicas entre os conjuntos *fuzzy* das premissas contidas nas regras do tipo SE-ENTÃO. Na terceira etapa (*Aplicação da Implicação*), aplicação da inferência (implicação) é realizada sobre os valores *fuzzy*, deduzindo qual é o grau de pertinência que a informação de entrada influi sobre os termos linguísticos que descrevem cada uma das variáveis de saída contidas nos consequentes das regras. Assim, cada regra tem como consequência conjuntos *fuzzy* decorrentes dos termos linguísticos que expressam as saídas, com intensidades proporcionais à "fuzzificação" da entrada (MATLAB..., 2012). Uma relação de inferência é uma regra SE-ENTÃO que deve determinar o tipo de operação de inferência *fuzzy* que recebe os valores de entrada ($\mu_A(x)$) resultantes da "fuzzificação" e os valores de saída ($\mu_B(x)$) contidos na inferência. O resultado da operação é o dado de saída da relação de implicação. Na etapa 4 (*Agregação dos Conjuntos Truncados nas Consequências das Regras Envolvidas*), a agregação dos conjuntos *fuzzy* é realizada, cujo resultado é um gráfico que representa a união entre os conjuntos *fuzzy* de saída resultantes da etapa 3 (GOMIDE; GUDWIN; TANSCHKEIT, 1995). Na etapa 5 (*Defuzzificação*), a transformação de um conjunto *fuzzy* resultante da agregação em um dado numérico é realizada. A "defuzzificação" tem impacto significativo no desempenho do controlador *fuzzy*. Deste modo, a escolha do critério "defuzzificador" é de fundamental importância para a produção de respostas com a precisão necessária ao projeto (RUSSEL; NORVIG, 2003).

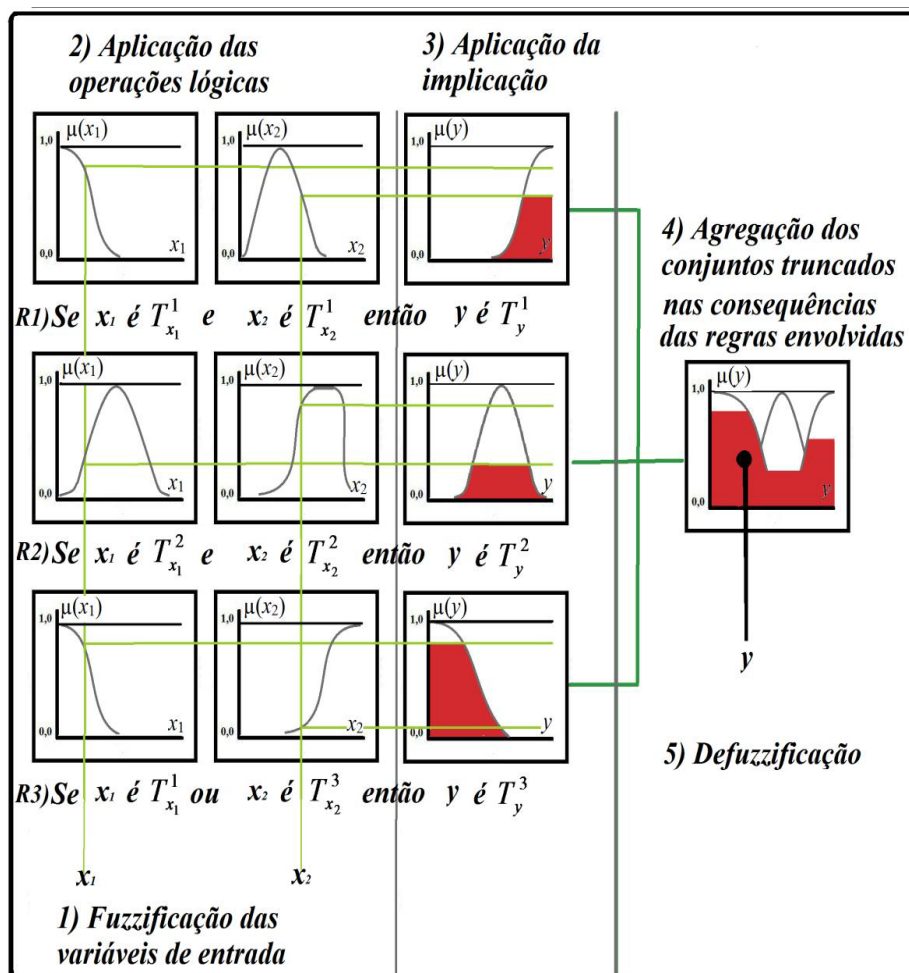


Figura 14 Diagrama demonstrativo de inferência *fuzzy*

Fonte: Magalhães (2009)

Para a "defuzzificação", o método mais utilizado é o Centro de Gravidade (WEBER; KLEIN, 2003), cuja resposta é obtida pela abscissa do centro da área do da etapa 4 representada na Figura 14, embaixo da curva resultante da agregação (y), área preenchida do gráfico, dada pela Equação 15.

$$y = \frac{\int x \mu(x) dx}{\int \mu(x) dx} \quad (15)$$

3.9.1 Inferência *fuzzy* - Método de Mamdani

Uma regra SE (antecedente) ENTÃO (consequente) é definida pelo produto cartesiano *fuzzy* dos conjuntos *fuzzy* que compõem o antecedente e o consequente da regra. O método de Mamdani agrega as regras, utilizando o operador lógico OU modelado pelo operador máximo e, em cada regra, o operador lógico E é modelado pelo operador mínimo. Eis as regras (LOPES; JAFELICE; BARROS, 2005):

- a) Regra 1: SE (x é A1) E (y é B1) ENTÃO (z é C1);
- b) Regra 2: SE (x é A2) E (y é B2) ENTÃO (z é C2).

Um exemplo prático de utilização dessas regras pode ser um controlador *fuzzy* de uma máquina de resfriamento de uma sala de aula. Por exemplo, considerando x a umidade do ar, y a temperatura da sala, z o nível de resfriamento da máquina, A1 e A2 os conjuntos *fuzzy* do universo de discurso umidade do ar, B1 e B2 os conjuntos *fuzzy* do universo de discurso temperatura e C1 e C2 os conjuntos *fuzzy* do universo de discurso nível de resfriamento, pode-se ter várias regras, entre elas:

- a) SE (umidade do ar é MUITO BAIXA) e (temperatura é QUENTE) ENTÃO (nível resfriamento é MUITO ALTO);
- b) SE (umidade do ar é MUITO ALTA) e (temperatura é MORNA) ENTÃO (nível resfriamento é BAIXO).

O conjunto *fuzzy* de saída de um sistema de inferência do método de Mamdani é a união dos resultados dos consequentes das regras utilizando o operador lógico OU. Essa união é uma composição de relações *fuzzy* binária (a regra de composição max-min), definida pela Equação 16. A saída (número real) é a "defuzzificação" do conjunto *fuzzy* de saída.

$$U_{A_2}(X_2) = U_{R(A_1, A_2)}(X_2) = \max \left[\min (U_{A_1}(X_1), U_R(X_1, X_2)) \right] \quad (16)$$

O funcionamento de uma máquina de inferência do método de Mandani é apresentado na Figura 15. Nessa figura, é apresentada a operação entre a regra "SE x é A1 E y é B1 ENTÃO z é C1" (regra 1) e a regra "SE x é A2 E y é B2 ENTÃO z é C2" (regra 2). O resultado dessas regras (C'1 e C'2) é obtido utilizando o operador lógico E (C'1 E C'2). O conjunto *fuzzy* de saída é a união dos resultados da regra 1 e regra 2, utilizando o operador lógico OU (C'1 OU C'2).

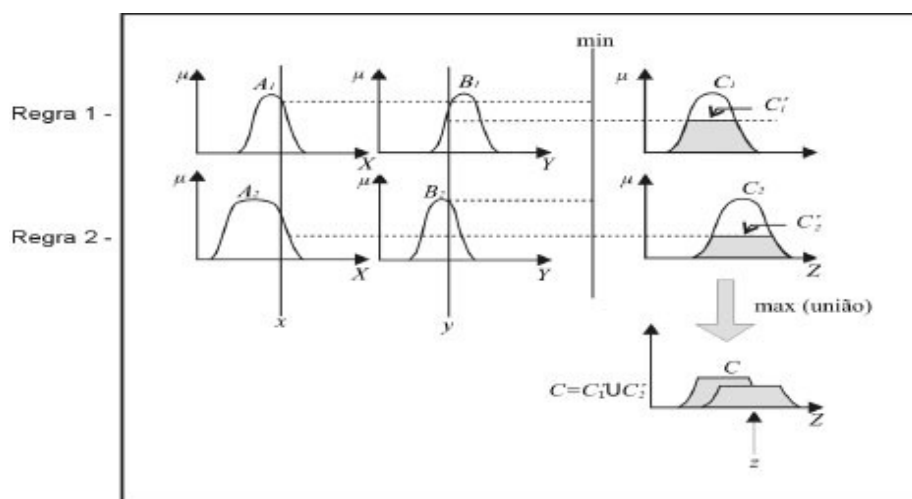


Figura 15 Método de Mamdani com composição max-min

Fonte: Lopes, Jafelice e Barros (2005)

3.9.2 Inferência *fuzzy* - modelo de Takagi-Sugeno-Kang

Na década de 80, uma estrutura de inferência baseada na teoria de conjuntos *fuzzy* foi proposta, denominada sistema de inferência de Sugeno, modelo de inferência *fuzzy* paramétrico ou simplesmente modelo TSK (Takagi-Sugeno-Kang - proponentes do modelo). Esses modelos funcionam como aproximadores para sistemas que podem ser completa ou satisfatoriamente representados por meio de suas relações de entrada e de saída (REZENDE, 2002; SHAW; SIMÕES, 1999).

Uma aplicação comum dos modelos de inferência *fuzzy* é sua utilização para aproximação de funções não lineares. Pelas suas propriedades sintáticas, os modelos TSK são mais adequados a este fim. A existência de funções paramétricas nos consequentes de suas regras e a facilidade de ajustarem-se a partir de um conjunto de dados de entrada e saída fazem com que os modelos TSK sejam intrinsecamente relacionados com a tarefa de aproximação de funções em geral. Um exemplo genérico de regras TSK é apresentado na Figura 16 (DURÃES, 2009).

If $x_1 = A_i$ and $x_2 = A_j$ and ... and $x_p = A_m$ then $y = F(x_1, x_2, \dots, x_p)$

Figura 16 Exemplo genérico de regras TSK

Fonte: Durães (2009)

O processamento de conhecimento em um modelo TSK é similar ao ocorrido nos modelos de Mamdani. A etapa "fuzzificação" é idêntica, porém a etapa Aplicação das Operações Lógicas entre os conjuntos *fuzzy* nas premissas contidas nas regras do tipo SE-ENTÃO se divergem pelo fato do modelo de

Mandani utilizar a função Min e o modelo TSK utilizar a função Prod (multiplicação) (REZENDE, 2002). Nos dois modelos, a saída numérica é calculada diretamente pela soma das saídas das regras ponderada pelos valores de ativação de cada uma delas.

3.10 Considerações finais

Um sistema utilizando lógica *fuzzy* é um sistema baseado no conhecimento especialmente projetado para emular a especialização humana de algum domínio específico. Esse conhecimento é formado por fatos, por regras e por heurísticas sobre o domínio.

A arquitetura geral de um sistema *fuzzy* compreende dois componentes principais: i) um conjunto de declarações totalmente dependentes do domínio do problema chamado de base de conhecimento ou base de regras; e ii) um programa independente do domínio do problema (apesar de altamente dependente das estruturas de dados) chamado de motor de inferência. Esses sistemas são relevantes para várias áreas da ciência em constante desenvolvimento, não se limitando a área de inteligência computacional.

4 REDES NEURAIS ARTIFICIAIS

4.1 Considerações iniciais

Uma rede neural artificial (RNA), terminologia genérica que abrange grande quantidade de arquiteturas e paradigmas, tem como objetivo compreender o funcionamento do cérebro humano e, de alguma forma, tentar reproduzi-lo. As RNAs são sistemas paralelos de processamento, compostos por unidades de processamento (neurônios) e calculam determinadas funções matemáticas (normalmente não lineares). Geralmente, essas unidades estão interligadas por canais de transmissão com um determinado peso e fazem operações sobre as entradas recebidas pelas suas conexões. O comportamento "inteligente" de uma RNA advém das interações entre as várias unidades de processamento da rede (PORTELINHA, 2006).

Uma das definições de RNAs é um processador paralelamente distribuído, constituído por unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para utilização (HAYKIN, 2001). Isto significa que uma RNA é um sistema computacional com capacidade de aprender com o seu próprio uso, pois produz saídas adequadas para entradas não presentes durante a sua aprendizagem, de forma a atingir um objetivo específico. Essa capacidade de generalização possibilita a resolução de problemas computacionais complexos.

Por conseguinte, pode-se utilizar RNAs em uma vasta gama de problemas encontrados nas mais diversas áreas de aplicação, tais como, classificação, diagnóstico, análises de sinais e de imagens, otimização e controle. Do ponto de vista prático, as RNAs têm a vantagem de não necessitarem de especialistas para a tomada de decisões, pois elas se baseiam unicamente nos exemplos que lhes são fornecidos.

Como as RNAs conseguem reproduzir o comportamento de funções matematicamente desconhecidas à priori, modelagem de um sistema que as utiliza aparece como um potencial substituto dos modelos estatísticos convencionais. Isso se deve à fácil interpretação das interfaces dos programas por parte do usuário e a não necessidade de conhecimento prévio da relação entre as variáveis envolvidas. Há diversas aplicações em que as RNAs têm apresentado um desempenho superior aos métodos estatísticos (FALAS, 1995; SUBRAMANIAN; HUNG; HU, 1993).

Este capítulo está organizado da seguinte forma. Fundamentos biológicos da estrutura de um neurônio natural são apresentados na Seção 4.2. Vantagens e desvantagens da utilização de RNAs são discutidas na Seção 4.3. Principais componentes das RNAs são mostrados na Seção 4.4. Preparação dos dados de entrada de RNAs é comentada na Seção 4.5. Topologias de RNAs são abordadas na Seção 4.6. Tipos de aprendizagem das RNAs são apresentados na Seção 4.7. RNAs *perceptrons* são comentadas na Seção 4.8. Mínimos locais são tratados na Seção 4.9. Sobreajustamento e generalização são abordadas na Seção 4.10.

4.2 Fundamentos biológicos

A RNA foi inspirada no cérebro humano, uma estrutura de processamento altamente complexa, não linear e paralela. Ao contrário da arquitetura tradicional de computadores, o cérebro humano possui grande quantidade de processadores, conhecidos por unidades de processamento ou neurônios, que executam funções simples. Entre essas funções, o neurônio apresenta a capacidade de transmissão de impulsos nervosos a outros neurônios e células musculares (HAYKIN, 1998).

O sistema de processamento de informação do cérebro humano possui a capacidade de organizar os neurônios de tal forma que o seu desempenho na execução de certas tarefas (por exemplo, reconhecimento de exemplos, percepção e controle motor) seja realizado de forma rápida em comparação ao mais potente computador, apesar da sua velocidade de processamento ser relativamente mais baixa. Esta rapidez na execução de certas tarefas deve-se à quantidade de neurônios existentes no cérebro humano, pois se presume que a quantidade de neurônios existentes no cérebro esteja na casa dos bilhões (COTTRELL, 1985).

Como foi mencionado, o corpo humano tem grande variedade de tipo de neurônios cujas funções não são totalmente conhecidas. Contudo, um neurônio natural é basicamente constituído por dendrites, sinapses, axônio e corpo celular (Figura 17).

À medida que novos exemplos são apresentados durante o processo de aprendizagem, ligações entre os neurônios são ajustadas, reforçando-as e/ou enfraquecendo-as. Este ajuste é uma das características mais importantes das redes neurais biológicas (HOPFIELD, 1982). Contudo e apesar da investigação contínua sobre o assunto, o conhecimento sobre o funcionamento das redes neurais biológicas ainda não foi totalmente adquirido.




Figura 17 Estrutura de um neurônio natural

Fonte: Cortez (2002)

Uma vez que, as redes neurais biológicas têm a sua base de fundamentação na neurotransmissão ocorrida nas células nervosas, é importante conhecer o funcionamento básico de um neurônio biológico. O neurônio tem uma estrutura simples, que permite três funções básicas: entrada, processamento e saída de sinais. As dendrites são conexões pelas quais os sinais de entrada chegam aos neurônios. A célula ou corpo celular é o processador do neurônio, recebe sinais de entrada pelas dendrites e soma esses sinais. Se o valor resultante estiver acima de certo limite, o neurônio excita-se e tende a propagar o estímulo; caso contrário, ele fica inibido. O axônio serve como canal de saída do neurônio e está ligado às dendrites de outros neurônios pelas sinapses. As sinapses não são ligações físicas, mas ligações químicas e temporárias (BARRETO, 2002).

4.3 Vantagens e desvantagens da utilização de RNAs

As RNAs são capazes de aprender pela experiência, generalizar os casos anteriores e encontrar características essenciais a partir de entradas. Isto faz com que ofereçam numerosas vantagens e, em consequência disso, são inúmeras as áreas onde podem ser aplicadas (SUBRAMANIAN; HUNG; HU, 1993). Assim, destacam-se as seguintes vantagens:

- a) **Aprendizagem adaptativa.** Capacidade de aprender a realizar tarefas baseadas em treino ou em experiência inicial. Esta é uma das características mais atrativas das RNAs: aprendem certas tarefas mediante um treino com exemplos ilustrativos;
- b) **Não linearidade.** Capacidade de modelar funções não lineares. Dado que muitos problemas são de natureza não linear, esta é uma das razões principais para que as RNAs apresentem desempenho superior a outras técnicas, em termos de conhecimento preditivo;

- c) **Tolerância a falhas**¹. Enquanto os meios computacionais tradicionais perdem a sua funcionalidade quando sofrem um pequeno erro de memória, se existir uma falha em uma quantidade não elevada de neurônios em uma RNA, ela continua funcional;
- d) **Operação em tempo real**. Uma das prioridades das várias áreas de aplicação é a necessidade de realizar processos com dados de forma rápida. As RNAs são constituídas por grande quantidade de unidades de processamento trabalhando em paralelo, podendo trabalhar em velocidades consideráveis em relação aos métodos tradicionais comuns;
- e) **Adaptabilidade às tecnologias existentes**. Uma RNA pode ser treinada para desenvolver uma ou mais tarefas bem definidas. Com as ferramentas computacionais existentes, a RNA pode ser facilmente treinada e verificada. Assim, não há dificuldades para a inserção de RNAs em áreas específicas.

No entanto, existem situações em que as características do problema tornam desaconselhável a utilização de RNAs. Além disso, o campo de estudos onde se inserem é muito recente e alguns problemas continuam ainda por resolver (AMBRÓSIO, 2002; SUBRAMANIAN; HUNG; HU, 1993). Assim, são apontadas algumas desvantagens na sua utilização:

- a) **Treino demorado**. O treino de uma RNA pode ser demorado, dependendo da aplicação e da quantidade de dados;

¹ Existem dois aspectos distintos a respeito da tolerância a falhas: i) as RNAs podem aprender a reconhecer padrões com ruídos, distorcidos ou incompletos. Esta é uma tolerância a falhas de dados; e ii) as RNAs podem continuar a realizar as suas funções (com algum grau de degradação), ainda que destrua um dos seus nós. Esta é uma tolerância a falhas da RNA.

- b) **Resultados desconcertantes.** As RNAs podem chegar a situações conflitantes, tais como, conclusões que contrariam as regras e as teorias estabelecidas e considerar dados irrelevantes como básicos. Há apenas uma solução para essas situações: participação do profissional da área;
- c) **Obscuridade.** O conhecimento está armazenado de modo implícito, o que torna difícil compreender o que realmente uma RNA aprendeu;
- d) **Grande quantidade de exemplos.** A carência de dados pode impossibilitar a obtenção de um bom desempenho de uma RNA;
- e) **Preparação dos dados.** Os dados de entrada necessitam de um tratamento prévio, devendo ser normalizados e cuidadosamente selecionados para que a RNA aprenda corretamente.

Em diversas circunstâncias, incluindo problemas com amostras com pequena quantidade e funções mais complexas, as RNAs apresentam soluções satisfatórias. O desempenho das RNAs tem mostrado melhores resultados em relação aos métodos estatísticos utilizados para os mesmos fins (FALAS, 1995; KWON; GOLDEN; WASIL, 1995).

4.4 Principais componentes das RNAs

Um modelo de uma RNA pode ter três componentes (COSTA, 2003; RUMELHART; MCCLELLAND, 1986):

- a) **Unidade de processamento.** A unidade de processamento ou neurônio artificial é o principal elemento das RNAs. Um neurônio como uma unidade que representa um limite a ser ultrapassado é

apresentado na Figura 18. Cada entrada possui um sinal x (x_1, \dots, x_n) adicionado (Σ). Em seguida, esse sinal é processado utilizando uma função de ativação $f()$ que representa o limite que produz um sinal de saída.




Figura 18 Neurônio como unidade limite

Fonte: Portelinha (2006)

- b) As unidades de processamento da RNA podem ser identificadas pela letra x , seguidas de um índice i que indica a posição em que o neurônio ocupa na rede. Cada neurônio x_i calcula um valor numérico líquido de saída de um estado de ativação. O cálculo da função de ativação $f()$ é realizado a partir dos sinais de saída dos demais neurônios conectados diretamente a este neurônio e dos pesos correspondentes dessas conexões;
- c) **Função de ativação.** A função de ativação calcula o valor de saída do neurônio a partir do seu valor de ativação ou integração (Σ). As funções de ativação mais utilizadas são linear (Figura 19 A), rampa (Figura 19 B), degrau (Figura 19 C) e logística² (Figura 19 D). Dentre estas, a função logística é a mais utilizada, visto que ela permite aprendizagem não linear, sendo definida pela Equação 17;

² Também conhecida por *Sigmoid*.

- d) **Ligações entre as unidades de processamento.** As ligações entre os neurônios podem ser representadas por uma matriz de pesos w , sendo w_{ij} a influência do neurônio u_i sobre o neurônio u_j . Conexões com pesos positivos, chamadas de excitadoras, indicam o reforço na ativação do neurônio u_j . Conexões com pesos negativos, chamadas de inibidoras, indicam inibição na ativação do neurônio u_j . O objetivo principal da aprendizagem/treino consiste em determinar o melhor conjunto de pesos capazes de responder de modo adequado a um dado problema.




Figura 19 Funções de ativação

Fonte: Portelinha (2006)

$$y = \frac{1}{1 + \exp(-x)}$$

17

4.5 Preparação dos dados

Sobre um ponto de vista simplista, as RNAs podem ser encaradas como modelos que recebem estímulos de entrada e geram respostas de acordo com o conhecimento adquirido durante um processo de aprendizagem. As fases do

processo de aprendizagem das RNAs são ilustradas na Figura 20. O ponto de partida (A) é a obtenção dos dados que representam um determinado domínio. No pré-processamento (B), os atributos numéricos devem ser normalizados dentro de uma escala de valores. Os atributos discretos precisam ser codificados em valores numéricos. Os valores desconhecidos precisam ser preenchidos utilizando métodos, por exemplo, médias dos valores do atributo ou definição de novos valores (PORTELINHA, 2006). O conjunto de dados devidamente pré-processados deve ser dividido em subconjuntos distintos de treino e teste (C). Em seguida, a RNA é treinada (D) com os dados selecionados para treino, de forma a ajustar os seus pesos que lhe permitirão apresentar conhecimento.




Figura 20 Fases do processo de aprendizagem de uma RNA

Fonte: Portelinha (2006)

A fase de testes (E) é necessária para verificar se a aprendizagem foi bem sucedida, utilizando conjunto de dados de teste não usados no treinamento (EDMAR, 1999). Em seguida, é apresentado um conjunto de regras a ser seguido (PYLE, 1999):

- a) **Valores desconhecidos.** Devem ser tratados de alguma forma. Existem diversas possibilidades:
 - **Média.** Valores desconhecidos de um atributo podem ser substituídos pela média de seus valores. Em atributos que

representam valores ordenados, a média de n valores anteriores e posteriores pode ser utilizada para a definição do valor desconhecido;

- **Definição de novos valores.** De acordo com cada problema, valores arbitrários podem ser definidos para o preenchimento de atributos desconhecidos;
 - **Eliminação dos valores em falta.** Caso se trate de valores que sejam de difícil previsão.
- b) **Variáveis discretas.** Os valores não numéricos devem ser codificados em valores numéricos:
- **Atributos binários.** Esses atributos devem ser codificados como os valores limite definidos pela função de ativação (por exemplo, não = -1,0 e sim = 1,0);
 - **Atributos nominais.** Os atributos com c valores possíveis devem ser transformados com uma codificação 1-de- c , que gera uma variável binária por cada classe (por exemplo, verde = -1,0; 1,0; 1,0 - azul = -1,0; 1,0; -1,0 e vermelho \rightarrow -1,0; -1,0; 1,0).
- c) **Normalização.** Os atributos de entrada devem ser normalizados, dado que os algoritmos de treino são sensíveis a intervalos e a distribuições diferentes nas suas entradas. Assim, os valores de cada entrada devem ser escalonados, de forma que a média dos seus valores no conjunto de dados de treino seja nula.

4.6 Topologias de RNAs

Em geral, as topologias de RNAs podem ser agrupadas em duas classes (BOCANEGRA, 2002):

- a) **RNAs não-recorrentes.** As saídas dessas RNAs não possuem realimentação para as suas entradas. A sua estrutura é em camadas, podendo ser formadas por uma (RNA de uma só camada) ou mais camadas (RNA multicamadas). As RNAs de uma só camada são unidirecionais (convergentes ou divergentes). A RNA é composta por um conjunto de neurônios de entrada. Esta entrada não é considerada como camada, pois não são efetuados cálculos, apenas contém os valores de entrada da rede (WASSERMAN, 1993) e uma camada de saída. As RNAs multicamadas são compostas por neurônios de entrada, neurônios de saída e neurônios entre a camada de entrada e a camada de saída, sendo organizados em uma ou mais camadas intermediárias;
- b) **RNAs recorrentes.** A saída de um neurônio dessas RNAs influencia de alguma forma a entrada desse mesmo neurônio, estabelecendo um circuito fechado (Figura 21) e a existência de conexões cíclicas na RNA. Além disso, a sua estrutura não é obrigatoriamente organizada em camadas. Quando a RNA é organizada em camada, pode possuir interligações entre neurônios da mesma camada e entre camadas não consecutivas. Uma RNA recorrente alcança um estado estável quando possuir conexões simétricas (WASSERMAN, 1993). Em 1982, houve importantes contribuições com as chamadas redes Hopfield, RNAs recorrentes que podem ser utilizadas para roteamento (HOPFIELD, 1982). Em 1986, regras para treino de

RNAs recorrentes, denominadas de Máquinas de Boltzmann, foram introduzidas por causa do cálculo das saídas dos neurônios artificiais ser efetuado utilizando probabilidade segundo a distribuição de Boltzmann (HINTON; SEJNOWSKI, 1986).




Figura 21 RNA recorrente

Fonte: Cortez (2002)

4.7 Aprendizagem das RNAs

Existe grande diversidade de arquiteturas de RNAs e de correspondentes algoritmos de aprendizagem, cada um com diferentes possibilidades, finalidades, vantagens e inconvenientes. Uma das principais vantagens e importâncias das RNAs é a sua capacidade de aprender e de melhorar sempre o seu desempenho baseado nessa aprendizagem. Duas importantes etapas para o treinamento das RNAs são (RAUBER, 2005):

- a) **Métodos de aprendizagem.** As RNAs podem ser agrupadas em duas formas de classificação principais: i) supervisionada; e ii) não supervisionada. Um método conhecido é a aprendizagem por reforço, que pode ser considerado um caso particular da aprendizagem supervisionada. A aprendizagem por competição é um caso particular da aprendizagem não supervisionada (COSTA, 2003; RUMELHART; HINTON; WILLIAMS, 1986):

- **Aprendizagem supervisionada.** Os conjuntos de padrões de entrada e os seus correspondentes padrões de saída são sucessivamente apresentados à RNA. Durante este processo, a RNA realiza o ajuste dos pesos das conexões entre os elementos de processamento até o erro entre os padrões da saída gerados pela RNA e os padrões de saída apresentados alcançar um valor mínimo desejado. O exemplo mais conhecido de algoritmo para aprendizagem supervisionada é a regra delta generalizada, utilizada no algoritmo de retropropagação. A aprendizagem por reforço consiste na RNA receber o valor que indica se o valor de saída está ou não correto, ou seja, a aprendizagem é feita por tentativa de erro, de modo a otimizar um índice de performance chamado sinal de reforço;
- **Aprendizagem não supervisionada.** A RNA analisa o conjunto de dados recebidos, determina algumas propriedades desses conjuntos de dados e "aprende" a refletir essas propriedades. A RNA utiliza padrões, regularidades e correlações para agrupar o conjunto de dados em classes. As propriedades adquiridas pela RNA sobre os dados podem variar em função da arquitetura e da regra de aprendizagem utilizada. Este tipo de aprendizagem é possível quando existe grande quantidade de dados de entrada; caso contrário, torna-se difícil ou mesmo impraticável apurar quaisquer padrões ou características nos dados de entrada. A aprendizagem por competição consiste em segmentar os dados introduzidos na RNA. Desta forma, informações similares são classificadas formando parte da mesma categoria e, por conseguinte, devem ativar a mesma saída, existindo uma competição entre as unidades de saída para decidir qual delas

será a vencedora, tendo sua saída ativada e os seus pesos atualizados no treino. A unidade mais forte tem maior peso e o seu efeito inibidor sobre as outras unidades de saída torna-se dominante. Com o tempo, as outras unidades de saída ficam completamente inativas.

b) **Regras de aprendizagem.** A regra a ser aplicada está intimamente relacionada com a arquitetura da RNA. As cinco regras básicas de aprendizagem são (HAYKIN, 1998):

- **Regra gradiente descendente.** O erro de saída de um neurônio é obtido comparando o resultado por ele calculado com o resultado desejado. O erro atua como mecanismo de controle, sendo que ajustes melhoram a resposta;
- **Regra baseada na memória.** Procura-se um padrão aproximado de entrada, sendo que a seleção do padrão aproximado da região vizinha tem por base as experiências passadas;
- **Regra de Hebb.** Esta regra estabelece que, quando um neurônio de uma célula A está suficientemente perto para excitar uma célula B e, repetida ou persistentemente, ocorre um disparo, algum processo de crescimento ou mudança metabólica acontece em uma ou ambas as células, tal que a eficiência da célula A, como uma das células disparadores da célula B, é aumentada. Esta regra foi proposta por Hebb em 1949;

- **Regra competitiva.** Na aprendizagem competitiva, utilizada nas populares redes de Kohonen, neurônios são inibidos por outros

neurônios de modo que a competição entre eles deixe apenas um neurônio excitado. Neste tipo de aprendizagem, somente um neurônio de saída fica ativado;

- **Regra de Boltzmann.** Este algoritmo de aprendizagem realiza o ajuste dos pesos, baseando-se na probabilidade e na mecânica estatística. A RNA que utiliza esta regra é denominada máquina de Boltzmann.

4.8 RNAs *perceptrons*

As RNAs *perceptron*, introduzidas por Rosenblatt em 1958, mostraram algumas aplicações práticas. Elas são uma forma simples de RNAs, em que a sua principal aplicação é a classificação de padrões, ou seja, o processo pelo qual um padrão/sinal recebido é atribuído a uma classe dentre um número predeterminado de classes (categorias) (HAYKIN, 1998). Os dois tipos de camadas existentes são:

- a) **RNA *Perceptron* de camada única.** Essa RNA é o mais simples, no qual várias unidades de processamento estão conectadas a uma única camada de saída por meio de pesos sinápticos (Figura 22). O neurônio de saída é do tipo binário que pode ser utilizado como classificador ou como representação de funções booleanas (verdadeiro/falso) (BRÍO; MOLINA, 2006). Essa RNA pode treinar pesos vinculados a padrões de entrada fornecidos à rede, além do uso de um conceito de controle de neurônio (*bias*) para se obter uma saída correta. O conceito *bias* é uma forma de controlar o limite (*threshold*) do neurônio. Esse limite é o valor a partir do qual o somatório dos pesos convencionais determinará se o neurônio estará

ativo (1) ou inativo (0), ou seja, se pertence ou não à classe que representa (RUSSEL; NORVIG, 1995). Apesar das RNAs *perceptron* terem causado grande euforia na época, elas não tiveram "vida longa" por serem criticadas quanto às suas limitações. Esta visão pessimista da sua capacidade mudou com as descrições da rede de Hopfield (multicamadas) em 1982 e o algoritmo de retropropagação em 1986 (COSTA, 2003);




Figura 22 RNA de uma só camada

Fonte: Cortez (2002)

- b) **RNAs *Perceptron* multicamada.** Como o *perceptron* de uma única camada só é capaz de classificar padrões linearmente separáveis, o que acontece somente em uma quantidade limitada de aplicações, torna-se necessário recorrer à RNA *perceptron* de multicamada. Sua arquitetura constitui o modelo neural artificial mais utilizado e conhecido. Tipicamente, consiste em um conjunto de dados de entrada, uma ou mais camadas intermediárias e uma camada de saída.

4.9 Mínimos locais

Um mínimo local é o valor mais reduzido em uma dada vizinhança (PORTELINHA, 2006). Quando uma função é convexa, apresenta-se como um grande "vale", pelo que o mínimo global é mais facilmente encontrado por métodos de minimização. Quando isso não acontece, ou seja, se existir uma série de "montes" e "vales", há diversos mínimos locais. Os métodos baseados no gradiente tendem a encontrar mínimos locais, pois a função de erro é não convexa (HASTIE; TIBSHIRANI; FRIEDMAN, 2001).

Assim que um mínimo local é encontrado, o algoritmo de treino consegue melhorias diminutas e, em geral, deve-se parar a aprendizagem por falta de progresso. Este fenômeno pode ocorrer independentemente de uma alteração da taxa de aprendizagem e/ou do termo *momentum*³ (FREEMAN, 1992). Como resultado, a solução final obtida é dependente da escolha dos pesos iniciais.

4.10 Sobreajuste e generalização

As RNAs utilizam um conjunto de dados de treino para ajustar os pesos da rede. Uma vez treinada, a RNA deve ser utilizada para prever dados desconhecidos, isto é, dados não usados como dados de treino. Uma RNA pode apresentar fraca capacidade de generalização se for demasiada complexa, quando há muitas unidades de processamento, em um fenômeno designado por sobreajuste (*overfitting*). O que acontece é, ao ter alta capacidade, a RNA “memorizar” os dados de treino e perder a capacidade para generalizar. Por outro lado, com quantidade reduzida de unidades de processamento, subajuste pode ocorrer. Assim, a determinação da quantidade ideal de unidades de processamento que pertencem às camadas internas deve ser definida de forma

³ *Momentum* é uma constante que determina o efeito das mudanças passadas dos pesos na direção atual do movimento no espaço de pesos (BRAGA, 2007; HAYKIN, 2000).

empírica e depende da distribuição dos padrões de treino e teste da RNA (SARLE, 1995).

Acontece sobreajuste quando o modelo da RNA obtém desempenho quase perfeito nos dados de treino, mas desempenho pobre nos novos dados. Neste caso, um modelo que descreve os dados de treino é criado pela RNA, ao invés de um modelo de generalização. Isto se deve à possibilidade de existir ruído nos dados ou à existência de um conjunto de dados inadequado ou insuficiente. A solução para este tipo de problema, considerado crítico para as RNAs, pode ser (SARLE, 1995): i) utilizar um conjunto de dados de treino com alta cardinalidade; ii) utilizar paragem antecipada, terminando o treino quando o erro obtido em um conjunto de validação (com exemplos não utilizados durante o treino) aumenta; e iii) utilizar métodos de regularização que penalizam modelos complexos (HASTIE et al., 2001).

4.11 Considerações finais

A utilização de RNAs tem sido intensificada em diversos domínios nos últimos anos. No entanto, o poder oferecido pelas RNAs esbarra em um problema: dificuldade para explicar de forma compreensível as suas respostas ou as suas decisões. Este problema é um fator de motivação para as várias pesquisas relacionadas com o desenvolvimento de técnicas de extração de conhecimento de RNAs. Essas técnicas têm a finalidade de fornecer capacidade de explicação (SETIONO, 2002).

As RNAs não são mais do que um modelo artificial e simplificado do cérebro humano, o exemplo mais perfeito de que existe capaz de adquirir conhecimento utilizando experiência. Uma RNA é um novo sistema para o tratamento da informação, cuja unidade básica de processamento está inspirada em uma célula fundamental do sistema nervoso humano: neurônio.

Grande parte do tempo necessário para a construção de uma RNA é gasto em duas tarefas: i) processo de identificação da melhor topologia; e ii) treinamento. Por isso, o binômio *topologia versus treino* é o fator que se apresenta como barreira a ser transposta para o sucesso de uma solução baseada em RNAs. Assim, é necessário ter uma ideia, ainda que genérica, sobre os algoritmos de aprendizagem disponíveis para treinamento e das diversas topologias de redes existentes.

Um modelo bem ajustado perde a capacidade de generalização (sobreajuste). Para evitar isso, é necessário colocar restrições ao processo de aprendizagem e recorre-se à utilização de técnicas tais como a constante de decaimento.

Pode-se concluir que as RNAs consistem em unidades de processamento não lineares, que trocam dados e informação e são utilizadas para reconhecimento de padrões, incluindo imagens, manuscritos e sequências de tempo, tendências financeiras, entre outras aplicações, com a virtude de aprender e de melhorar o seu funcionamento de forma automática.

5 ANÁLISE TÉCNICA

5.1 Considerações iniciais

A análise técnica de ativos financeiros surgiu por volta do ano 1700, quando famílias japonesas passaram a acompanhar as variações do preço do arroz, com o intuito de formular tendências para tais variações. Esse método ficou conhecido como Candlesticks (VIDOTTO; MIGLIATO; ZAMBON, 2009). Essa análise é o estudo dos movimentos passados dos preços e dos volumes de negociação de ativos financeiros, com o objetivo de fazer previsões sobre comportamento futuro dos preços (PINHEIRO, 2012). Além disso, ela baseia-se no princípio dos preços dos ativos financeiros, em data futura, serem influenciados pelos preços passados, sendo possível prever a tendência de movimentação desses preços em determinado período de tempo.

A teoria de Charles Dow, um dos expoentes na utilização da análise técnica, sinaliza que eventos passados podem determinar eventos futuros (MATSURA, 2007). A configuração gráfica dos preços tende a se relacionar com a direção que eles tomarão no futuro. Isso significa que ocorrem formações indicando previamente a movimentação que deve ocorrer em relação a determinado ativo financeiro, antes de um movimento significativo de alta ou de baixa nas cotações de um ativo financeiro. A análise técnica possui três premissas básicas das quais decorrem os estudos acerca do comportamento do mercado e suas tendências (BRUM, 2006):

- 1) **Tudo pode ser resumido no preço dos ativos financeiros.** A expectativa, boa ou má, dos investidores com relação a determinado ativo financeiro reflete no seu preço diário;

- 2) **Os preços movem-se por meio de tendências.** Uma vez identificadas as tendências por meio de gráficos, o investidor tem condições de operar de acordo com elas. Assim, após identificar essa tendência, é mais provável que ela continue do que reverta, o que não significa necessariamente que ela irá durar para sempre;
- 3) **A história se repete e a compreensão de tendências futuras pode estar no estudo de acontecimentos passados.**

A previsão dos movimentos dos futuros preços baseada na análise técnica de preços passados, cujo resultado sobre o futuro não é absoluto, pode ajudar investidores a antecipar seus investimentos de acordo com o resultado dessa previsão. A análise técnica utiliza gráficos que mostram os preços sobre o tempo (STOCKCHARTS, 2010), cujos indicadores mais utilizados são (INFOMONEY, 2010; ONLINE TRADING CONCEPTS, 2010; STOCKCHARTS, 2010): Índice de Força Relativa (IFR), *Moving Average Convergence-Divergence* (MACD), Histograma MACD, Oscilador Estocástico e *On Balance Volume* (OBV).

Este capítulo está organizado da seguinte forma. Conceitos, definições, interpretações gráficas e cálculos para a obtenção dos indicadores IFR, Oscilador Estocástico, MACD, Histograma MACD e OBV são apresentados na Seção 5.2, na Seção 5.3, na Seção 5.4, na Seção 5.5 e na Seção 5.6, respectivamente.

5.2 Índice de força relativa (IFR)

J. Welles Wilder formulou o conceito do indicador Índice de Força Relativa (IFR) em seu livro intitulado "*New Concepts in Technical Trading Systems*", sendo ele um oscilador de momento que mede a velocidade e a

mudança dos movimentos de preços, cuja oscilação é entre 0 e 100. Tradicionalmente e de acordo com Wilder, esse indicador é considerado sobrecomprado quando seu valor estiver acima de 70 e sobrevendido quando seu valor estiver abaixo de 30, podendo ser utilizado para identificar a tendência geral. Apesar de ser desenvolvido antes da era do computador, o indicador IFR tem resistido ao tempo e permanece extremamente popular (STOCKCHARTS, 2010).

Esse indicador é obtido pela razão entre a média dos preços de fechamento nos dias em que o ativo financeiro fechou em alta e a média dos preços de fechamento nos dias em que o ativo financeiro fechou em baixa. O indicador IFR é menos volátil em relação aos demais por considerar preços em períodos mais longos (MEISSNER, 2001; RODRÍGUEZ-GONZÁLEZ et al., 2011).

O valor do indicador IFR é obtido pela Equação 18, sendo FR (força relativa) a razão entre a média de ganho e a média de perda, e baseado em períodos de 14 dias. Cabe ressaltar que as perdas são representadas como valores positivos. O gráfico do indicador IFR e o gráfico de força relativa são apresentados na Figura 23 e na Figura 24, respectivamente.

Uma planilha ilustrativa do passo a passo para o cálculo do indicador IFR é apresentada na Figura 25. Os primeiros cálculos são para obter a média de ganho e a média de perda. Depois, os cálculos são baseados nas médias. A primeira coluna contém a sequência de dias, começando pelo número 1. A segunda e a terceira colunas possuem datas do período de 14 de dezembro de 2009 a 3 de fevereiro de 2010 e os valores de fechamento de um determinado ativo financeiro, respectivamente.

$$IFR = \frac{100}{1 + FR}$$




Figura 23 Gráfico do indicador IFR
Fonte: adaptada de StockCharts (2010)




Figura 24 Gráfico de força relativa
Fonte: adaptada de StockCharts (2010)

	Data	Preço Fechamento	Variação	Ganho	Perda	Média Ganho	Média Perda	FR	IFR 14dias
1	14-dez-09	28,15							
2	15-dez-09	28,15							
3	16-dez-09	27,84	-0,32		0,32				
4	17-dez-09	26,75	-1,09		1,09				
5	18-dez-09	26,88	0,14	0,14					
6	21-dez-09	26,52	-0,36		0,36				
7	22-dez-09	26,46	-0,06		0,06				
8	23-dez-09	26,52	0,05	0,05					
9	28-dez-09	26,52							
10	29-dez-09	26,46	-0,05		0,05				
11	30-dez-09	27,15	0,69	0,69					
12	4-jan-10	27,33	0,18	0,18					
13	5-jan-10	27,05	-0,27		0,27				
14	6-jan-10	27,09	0,04	0,04				FR	IFR
15	7-jan-10	27,10	0,01	0,01		0,08	0,15	0,51	33,86
16	8-jan-10	27,26	0,16	0,16		0,08	0,14	0,59	37,09
17	11-jan-10	27,47	0,21	0,21		0,09	0,13	0,70	41,27
18	12-jan-10	27,24	-0,23		0,23	0,09	0,14	0,62	38,29
19	13-jan-10	27,58	0,35	0,35		0,11	0,13	0,81	44,80
20	14-jan-10	27,19	-0,39		0,39	0,10	0,15	0,66	39,70
21	15-jan-10	26,73	-0,46		0,46	0,09	0,17	0,53	34,74
22	18-jan-10	26,74	0,01	0,01		0,08	0,16	0,54	34,92
23	19-jan-10	27,19	0,45	0,45		0,11	0,15	0,75	42,99
24	20-jan-10	26,38	-0,81		0,81	0,10	0,19	0,53	34,60
25	21-jan-10	25,95	-0,43		0,43	0,10	0,21	0,45	31,14
26	22-jan-10	26,09	0,14	0,14		0,10	0,20	0,50	33,43
27	26-jan-10	25,38	-0,70		0,70	0,09	0,23	0,39	28,24
28	27-jan-10	25,18	-0,20		0,20	0,09	0,23	0,37	26,96
29	28-jan-10	25,23	0,05	0,05		0,08	0,21	0,38	27,76
30	29-jan-10	25,68	0,46	0,46		0,11	0,20	0,55	35,43
31	1-fev-10	27,42	1,74	1,74		0,23	0,18	1,22	54,98
32	2-fev-10	27,97	0,55	0,55		0,25	0,17	1,45	59,18
33	3-fev-10	27,28	-0,69		0,69	0,23	0,21	1,11	52,57

Figura 25 Planilha para o cálculo do indicador IFR

Fonte: adaptada de StockCharts (2010)

A quarta coluna contém a variação do preço atual em relação ao preço de fechamento anterior, sendo que as células vazias indicam que não houve variação. A quinta coluna possui as variações positivas, sendo que as células vazias indicam que não houve variação ou a variação é negativa. A sexta coluna possui o valor absoluto das variações negativas, sendo que as células vazias indicam que não houve variação ou a variação é positiva. A sétima e a oitava colunas possuem o ganho médio e a perda média, respectivamente, no período de 14 dias. A nona coluna contém a razão entre a média de ganho e a média de perda (força relativa). A décima coluna tem o indicador IFR, calculado pela Equação 18. A média de ganho, a média de perda, a força relativa e o índice de força relativa não foram calculados nas treze primeiras linhas por serem necessários dados de pelo menos 14 dias.

O gráfico do ativo financeiro eBay (EBAY) é apresentado na Figura 26. Nesse gráfico, os momentos de compra e de venda são indicados, utilizando o indicador IFR (ONLINE TRADING CONCEPTS, 2010).



Figura 26 Indicador IFR da cotação diária do EBAY

Fonte: adaptada de Online Trading Concepts (2010)

A variação do período de tempo do indicador IFR pode aumentar ou diminuir a quantidade de sinais de compra e de venda. O gráfico dos períodos de tempo de 14 dias (padrão) e 5 dias do indicador IFR é apresentado na Figura 27. Pode-se observar que quanto menor for o período utilizado, maior é a

volatilidade, o que aumenta substancialmente a quantidade de sinais de compra e de venda (ONLINE TRADING CONCEPTS, 2010).



Figura 27 Indicador IFR da cotação diária do ouro

Fonte: adaptada de Online Trading Concepts (2010)

5.3 Oscilador estocástico

Na década de 1950, George C. Lane desenvolveu o indicador Oscilador Estocástico, que corresponde a um indicador de momento o qual mostra a localização do preço de fechamento relativo às faixas de alta-baixa ao longo de um determinado período. Esse indicador não segue o preço, não segue o volume ou qualquer valor similar, ele segue a velocidade ou a dinâmica de preços. Como regra geral, a dinâmica muda de direção antes do preço. Dessa forma, a alta e a baixa no indicador Oscilador Estocástico podem ser utilizadas para prever reversões. Este indicador foi o primeiro e mais importante sinal identificado e utilizado para identificar o *bull market*⁴ e o *bear market*⁵ para antecipar uma reversão no futuro.

O valor deste indicador é obtido pela Equação 19, sendo *Fechamento* o preço de fechamento atual, *Menor Preço* o menor preço de um determinado período e *Maior Preço* o maior preço de um determinado período. O

⁴ Mercado do touro, jargão americano otimista, para mercados em alta.

⁵ Mercado do urso, jargão americano indicador de pessimismo, para mercados em baixa.

resultado é multiplicado por 100 para mover o ponto decimal em dois lugares. Como este indicador tem limite de escala [0, 100], ele é útil para identificar níveis de sobrecompra e de sobrevenda (STOCKCHARTS, 2010).

$$\%K = (\text{Fechamento} - \text{Menor Preço}) / (\text{Maior Preço} - \text{Menor Preço}) * 100$$

19

Uma planilha ilustrativa do passo a passo para o cálculo deste indicador é apresentada na Figura 28. A primeira coluna contém a sequência de dias, começando pelo número 1. A segunda, a terceira e a quarta colunas possuem as datas do período de 23 de fevereiro de 2010 a 6 de abril de 2010, a maior e a menor alta do dia de um determinado ativo financeiro, respectivamente. A quinta e a sexta colunas contêm o maior preço e o menor preço registrados em 14 dias. A sétima coluna contém o preço de fechamento do dia corrente. A oitava coluna contém o valor do indicador Oscilador Estocástico, calculado pela Equação 19. Os valores na quinta, na sexta, na sétima e na oitava colunas não foram calculados nas treze primeiras linhas, pois são necessários dados de pelo menos 14 dias.

Um gráfico que representa a oscilação dos ativos financeiros ao invés de indicar tendências é apresentado na Figura 29. Cabe ressaltar que, ao comparar o preço atual de um ativo financeiro com o seu comportamento recente, mostra-se se o preço atual é insustentável, o que pode levar a uma mudança de direção.

Por ser um indicador de curtíssimo prazo, sua utilização e a sua análise devem ser realizadas em conjunto com um indicador de tendências, por exemplo, o indicador MACD. Caso a cotação de um ativo financeiro esteja acima do registrado nos últimos pregões, o valor deste indicador sobe; caso contrário, seu valor desce (KIM; HAN, 2000). De forma geral, níveis acima de

80 pontos indicam potencial de queda, enquanto patamares abaixo de 20 pontos indicam oportunidade de compra (Figura 30).

	Data	Alta	Baixa	Maior Preço (14)	Menor Preço (14)	Preço Fechamento	Oscilador Estocástico 14 dias
1	23-fev-10	127,01	125,36				
2	24-fev-10	127,62	126,16				
3	25-fev-10	126,59	124,93				
4	26-fev-10	127,35	126,09				
5	1-mar-10	128,17	126,82				
6	2-mar-10	128,43	126,48				
7	3-mar-10	127,37	126,03				
8	4-mar-10	126,42	124,83				
9	5-mar-10	126,90	126,39				
10	8-mar-10	126,85	125,72				
11	9-mar-10	125,65	124,56				
12	10-mar-10	125,72	124,57				
13	11-mar-10	127,16	125,07				
14	12-mar-10	127,72	126,86	128,43	124,56	127,29	70,44
15	15-mar-10	127,69	126,63	128,43	124,56	127,18	67,61
16	16-mar-10	128,22	126,80	128,43	124,56	128,01	89,20
17	17-mar-10	128,27	126,71	128,43	124,56	127,11	65,81
18	18-mar-10	128,09	126,80	128,43	124,56	127,73	81,75
19	19-mar-10	128,27	126,13	128,43	124,56	127,06	64,52
20	22-mar-10	127,74	125,92	128,27	124,56	127,33	74,53
21	23-mar-10	128,77	126,99	128,77	124,56	128,71	98,58
22	24-mar-10	129,29	127,81	129,29	124,56	127,87	70,10
23	25-mar-10	130,06	128,47	130,06	124,56	128,58	73,06
24	26-mar-10	129,12	128,06	130,06	124,56	128,60	73,42
25	29-mar-10	129,29	127,61	130,06	124,57	127,93	61,23
26	30-mar-10	128,47	127,60	130,06	125,07	128,11	60,96
27	31-mar-10	128,09	127,00	130,06	125,92	127,60	40,39
28	1-abr-10	128,65	126,90	130,06	125,92	127,60	40,39
29	5-abr-10	129,14	127,49	130,06	125,92	128,69	66,83
30	6-abr-10	128,64	127,40	130,06	125,92	128,27	56,73

Figura 28 Planilha para o cálculo do indicador oscilador estocástico

Fonte: adaptada de StockCharts (2010)



Figura 29 Gráfico do indicador oscilador estocástico

Fonte: adaptada de Online Trading Concepts (2010)




Figura 30 Gráfico do indicador oscilador estocástico ilustrando momentos de compra e de venda

Fonte: adaptada de Online Trading Concepts (2010)

5.4 *Moving average convergence-divergence* (MACD)

No final da década de 70, Gerald Appel, analista e gestor de recursos de terceiros em New York, desenvolveu o indicador *moving average convergence-divergence* (MACD) (ELDER, 2004), sendo um dos indicadores de impulso mais simples e eficaz disponível. O indicador MACD é um oscilador de momento cujo valor é obtido subtraindo a média móvel mais longa (26 dias) da média móvel mais curta (12 dias). Como resultado, ele oferece o melhor dos dois mundos: tendência e momento.

Os investidores podem olhar para o sinal de linha de cruzamentos, o cruzamento central e os cruzamentos de divergências para observar sinais de compra e de venda. O indicador MACD não é particularmente útil para identificar os níveis de sobrecompra e de sobrevenda, sendo um indicador interessante de tendências para médio e longo prazo quando as cotações diárias dos ativos financeiros são utilizadas (STOCKCHARTS, 2010).

Este indicador consiste basicamente em três médias móveis exponenciais (MME) e aparece nos gráficos como duas linhas, cujos cruzamentos emitem sinais de negociação (compra ou venda) denominadas *linha MACD* e *linha de sinal MACD*, aquela é linha cheia mais rápida e esta é linha

tracejada mais lenta. A linha MACD é composta de duas médias móveis exponenciais que responde às mudanças nos preços com relativa rapidez. A linha de sinal MACD é composta pela linha MACD, ajustada por outra média móvel exponencial, que responde às mudanças nos preços com mais lentidão. Os sinais de compra e de venda são emitidos quando a linha MACD cruza acima ou abaixo da linha de sinal MACD. Nesse caso, ao analisar um ativo financeiro, se a linha MACD cruzar a linha de sinal MACD para baixo, é indicativo de sua venda; por outro lado, se a linha MACD cruzar a linha de sinal MACD para cima, é indicativo de sua compra (ELDER, 2004).

O indicador MACD é um dos mais utilizados para determinar a tendência na qual o preço do ativo financeiro se encontra. Seus valores são obtidos pela Equação 20 e pela Equação 21, sendo MACD o valor da linha MACD, MME 12D a média móvel exponencial de 12 dias, MME 16D a média móvel exponencial de 16 dias, Linha de Sinal o valor da linha de sinal MACD e MME 9D do MACD a média móvel exponencial de 9 dias do indicador MACD.

$$\text{MACD} = \text{MME 12D} - \text{MME 16D} \quad 20$$

$$\text{Linha de Sinal} = \text{MME 9D do MACD} \quad 21$$

Um gráfico representativo do indicador MACD é apresentado na Figura 31. Nesse gráfico, há (i) a linha MACD que indica a diferença entre as médias móveis de 12 dias e de 26 dias e (ii) a linha de sinal MACD que indica a média móvel do próprio MACD de 9 dias. Quando essas linhas estão acima de zero, o ativo financeiro está em tendência de alta.




Figura 31 Gráfico ilustrativo do indicador MACD

Fonte: adaptada de Online Trading Concepts (2010)

Outra interpretação do cruzamento das médias móveis do indicador MACD é apresentada na Figura 32. O histograma MACD e avisos de divergência MACD são dois importantes métodos de utilizar o indicador MACD.




Figura 32 Interpretação do cruzamento da linha MACD e da linha de sinal MACD

Fonte: adaptada de Online Trading Concepts (2010)

As médias móveis exponenciais reduzem a defasagem, aplicando mais peso aos preços mais recentes. A ponderação para o preço mais recente depende da quantidade de períodos na média móvel. Há três etapas para o cálculo da média móvel exponencial: i) calcular a média móvel simples (Equação 22); ii) calcular o coeficiente multiplicador (Equação 23); e iii) calcular a média móvel

exponencial (Equação 24). O período de 10 dias foi utilizado para obter o cálculo da média móvel exponencial.

$$\text{Média Móvel Simples} = \text{Soma do período de 10 dias} / 10 \quad 22$$

$$\text{Multiplicador} = (2 / (\text{período de tempo} + 1)) = (2 / (10 + 1)) = 0,1818(18,18\%) \quad 23$$

$$\text{MME} = \{ \text{Preço}_{(\text{atual})} - \text{MME}_{(\text{anterior})} \} \times \text{multiplicador} + \text{MME}_{(\text{anterior})} \quad 24$$

Uma planilha ilustrativa do passo a passo para o cálculo da média móvel exponencial de 10 dias é apresentada na Figura 33. A primeira coluna contém a sequência de dias, começando pelo número 1. A segunda e a terceira colunas possuem as datas do período de 23 de fevereiro de 2010 a 6 de abril de 2010 e o preço de fechamento do dia de um ativo financeiro, respectivamente. A quarta coluna contém a média dos 10 últimos preços. A quinta e a sexta colunas contêm o multiplicador da média móvel exponencial e a média móvel exponencial de 10 dias, respectivamente, aquela utilizando a Equação 23 e esta utilizando a Equação 24. Os valores na quarta, na quinta e na sexta colunas não foram calculados nas nove primeiras linhas, pois são necessários dados de pelo menos 10 dias.

	Data	Preço	MMS 10d	Multiplicador 2/(10 + 1)	MME 10d
1	14-dez-09	28,15			
2	15-dez-09	28,15			
3	16-dez-09	27,84			
4	17-dez-09	26,75			
5	18-dez-09	26,88			
6	21-dez-09	26,52			
7	22-dez-09	26,46			
8	23-dez-09	26,52			
9	28-dez-09	26,52			
10	29-dez-09	26,46	27,02		27,02
11	30-dez-09	27,15	26,92	0,1818	27,05
12	4-jan-10	27,33	26,84	0,1818	27,10
13	5-jan-10	27,05	26,76	0,1818	27,09
14	6-jan-10	27,09	26,80	0,1818	27,09
15	7-jan-10	27,10	26,82	0,1818	27,09
16	8-jan-10	27,26	26,89	0,1818	27,12
17	11-jan-10	27,47	26,99	0,1818	27,18
18	12-jan-10	27,24	27,07	0,1818	27,19
19	13-jan-10	27,58	27,17	0,1818	27,26
20	14-jan-10	27,19	27,25	0,1818	27,25
21	15-jan-10	26,73	27,20	0,1818	27,16
22	18-jan-10	26,74	27,15	0,1818	27,08
23	19-jan-10	27,19	27,16	0,1818	27,10
24	20-jan-10	26,38	27,09	0,1818	26,97
25	21-jan-10	25,95	26,97	0,1818	26,78
26	22-jan-10	26,09	26,86	0,1818	26,66
27	26-jan-10	25,38	26,65	0,1818	26,43
28	27-jan-10	25,18	26,44	0,1818	26,20
29	28-jan-10	25,23	26,21	0,1818	26,02
30	29-jan-10	25,68	26,06	0,1818	25,96

Figura 33 Planilha para o cálculo de MME

Fonte: adaptada de StockCharts (2010)

5.5 Histograma MACD

Em 1986, Thomas Aspray desenvolveu o indicador Histograma MACD (simplesmente Histograma), que mede a distância entre a linha MACD e a linha de sinal MACD e auxilia na antecipação dos cruzamentos dessas linhas. Por utilizar médias móveis e médias móveis da defasagem de preços, os cruzamentos no gráfico MACD podem ser visto tardiamente e afetar a relação da recompensa

e os riscos de uma negociação. As divergências de alta ou de baixa no gráfico desse indicador alertam uma iminente passagem do sinal das linhas MACD (STOCKCHARTS, 2010).

Como o indicador MACD, o indicador Histograma MACD é um oscilador que flutua acima e abaixo da linha do zero. Seu valor é obtido pela Equação 25, sendo *Linha MACD* o valor da linha MACD, *Linha de Sinal* o valor da linha de sinal MACD.

$$\text{Histograma} = \text{Linha MACD} - \text{Linha de Sinal} \quad 25$$

O indicador Histograma MACD deve ser utilizado com a tendência do indicador MACD, o que permite realizar análises mais precisas das tendências presentes no preço dos ativos financeiros. A intersecção positiva ocorre quando a linha de sinal MACD cruza acima da linha MACD, sendo vista como um evento positivo, pois sinaliza que uma nova tendência de alta se inicia. Por outro lado, quando a linha de sinal MACD cruza abaixo da linha MACD, isso significa o inverso na maior parte dos casos. As intersecções positivas mais efetivas são aquelas que ocorrem acima de zero, indicando a existência de uma tendência de alta. As intersecções negativas tendem a ser mais significativas quando ocorrem em pontos mais distantes de zero (RAGHAVENDRA; PARASCHIV; VASILIU, 2008).

Um gráfico ilustrativo de interpretação do indicador Histograma MACD é apresentado na Figura 34. A letra T e a letra B representam a ocorrência de um pico e a ocorrência do ponto mais baixo, respectivamente, desse indicador.



Figura 34 Gráfico ilustrativo de interpretação do indicador histograma MACD

Fonte: adaptada de Online Trading Concepts (2010)

5.6 On balance volume (OBV)

Em 1963, Joe Granville desenvolveu o indicador *On balance volume* (OBV) e o publicou em seu livro *Granville New Key to Stock Market Profits*. Este indicador foi um dos primeiros a medir o volume de fluxo positivo e negativo, o que possibilita prever os movimentos de preços olhando para as divergências entre o indicador OBV e o preço. Além disso, este indicador pode ser utilizado para confirmar as tendências de preços (STOCKCHARTS, 2010).

O indicador OBV é calculado adicionando ou subtraindo o volume⁶ em que o ativo financeiro subiu ou caiu, respectivamente (CAO; TAY, 2011). Se o preço de fechamento for (i) maior que, (ii) menor que ou (iii) igual a o preço de fechamento anterior, então a Equação 26, a Equação 27 e a Equação 28 são utilizadas, respectivamente. Ao contrário dos outros indicadores que utilizam escalas de 0 a 100 ou valores relativamente proporcionais à cotação dos ativos, o indicador OBV é medido de acordo com o volume dos ativos financeiros analisados.

$$OBV = OBV \text{ Anterior} + \text{Volume Atual}$$

⁶ Nesse caso, o "volume" indica a quantidade de ações negociadas.

$$OBV = OBV \text{ Anterior} - \text{Volume Atual} \quad 27$$

$$OBV = OBV \text{ Anterior} \quad 28$$

Uma planilha ilustrativa do passo a passo para o cálculo do indicador OBV é apresentada na Figura 35. A primeira coluna contém a sequência de dias, começando pelo número 1. A segunda e a terceira colunas possuem as datas do período de 27 de outubro de 2010 a 8 de dezembro de 2010 e o preço de fechamento do dia de um determinado ativo financeiro, respectivamente. A quarta coluna contém (i) o valor 1 para indicar alta, (ii) o valor 0 para indicar nenhuma variação ou (iii) o valor -1 para indicar baixa em relação ao dia anterior.

	Data	Fecha mento	Alta Baixa	Volume	Positivo Negativo	OBV
1	27-out-10	53,26				
2	28-out-10	53,30	1	8200	8200	8200
3	29-out-10	53,32	1	8100	8100	16300
4	1-nov-10	53,72	1	8300	8300	24600
5	2-Nov-10	54,19	1	8900	8900	33500
6	3-nov-10	53,92	-1	9200	-9200	24300
7	4-nov-10	54,65	1	13300	13300	37600
8	5-nov-10	54,60	-1	10300	-10300	27300
9	8-nov-10	54,21	-1	9900	-9900	17400
10	9-nov-10	54,53	1	10100	10100	27500
11	10-nov-10	53,79	-1	11300	-11300	16200
12	11-nov-10	53,66	-1	12600	-12600	3600
13	12-nov-10	53,56	-1	10700	-10700	-7100
14	15-Nov-10	53,57	1	11500	11500	4400
15	16-nov-10	53,94	1	23800	23800	28200
16	17-nov-10	53,27	-1	14600	-14600	13600
17	18-nov-10	53,60	1	11700	11700	25300
18	19-nov-10	53,65	1	10400	10400	35700
19	22-nov-10	53,62	-1	9500	-9500	26200
20	23-nov-10	53,27	-1	13900	-13900	12300
21	24-nov-10	53,44	1	10400	10400	22700
22	26-nov-10	53,28	-1	4200	-4200	18500
23	29-nov-10	53,14	-1	10900	-10900	7600
24	30-nov-10	53,31	1	17600	17600	25200
25	1-dez-10	54,09	1	17900	17900	43100
26	2-dez-10	54,08	-1	15800	-15800	27300
27	3-dez-10	54,01	-1	10200	-10200	17100
28	6-dez-10	54,17	1	8700	8700	25800
29	7-dez-10	54,24	1	16000	16000	41800
30	8-dez-10	54,45	1	12500	12500	54300

Figura 35 Planilha para o cálculo do indicador OBV

Fonte: adaptada de StockCharts (2010)

A quinta coluna contém o volume total negociado no dia. A sexta coluna possui o resultado da multiplicação do valor da quarta coluna pelo valor da quinta coluna. A sétima coluna contém o valor do indicador OBV (valor cumulativo com a adição e a subtração do volume nos dias de alta e de queda, respectivamente). Isso indica a pressão de compra e de venda de um ativo financeiro. Os valores na quarta, na quinta, na sexta e na sétima colunas não foram calculados na primeira linha, pois são necessários dados de pelo menos 2 dias.

Um gráfico ilustrativo indicando possíveis movimentos nas cotações antes que ocorram é apresentado na Figura 36. O aumento do volume de transações em relação ao volume histórico de transações indica a alta do preço

dos ativos financeiros, antes que os preços subam. O indicador OBV é utilizado para confirmar tendências de preços ou avisar potenciais reversões de preço por causa de divergências entre o preço e o volume negociado.



Figura 36 Gráfico OBV indicando divergência com o preço

Fonte: adaptada de Online Trading Concepts (2010)

5.7 Considerações finais

A análise técnica defende que os fatores econômicos, políticos, psicológicos e fundamentalistas condicionam os preços dos ativos financeiros, sendo o preço desses ativos no mercado em um momento ditado antes pelas exigências da oferta e da procura, que pelo seu valor intrínseco. Desta forma, os preços seriam apenas o reflexo das mudanças do ritmo da oferta e da procura. Se a procura for maior que a oferta, o preço sobe; caso contrário, o preço desce.

Além disso, a análise técnica baseia-se no movimento dos preços conforme as tendências (para compra ou para venda); e elas persistem. O ritmo da oferta e da procura coloca uma tendência em movimento. Os preços movem-se em uma direção, criando uma tendência que continua até o movimento dos preços diminuir e emitir avisos antes de reverter e começar o movimento na direção oposta. Neste ponto, tem início uma nova tendência.

Por fim, a análise técnica baseia-se no fato de os movimentos do mercado serem repetitivos. Certos padrões repetem ciclicamente nos gráficos e

possuem significados, cuja interpretação pode ser em termos de prováveis movimentos futuros de preços. A natureza humana é tal que tende a reagir similarmente às situações de padrões. Como regra, as pessoas agem da mesma forma que agiram no passado. Como o mercado de ativos financeiros é um reflexo das ações das pessoas, o analista técnico avalia situações recorrentes com finalidade de antecipar-se a altas e a baixas do mercado.

Enfim, a análise técnica é um estudo de ações individuais das pessoas e do mercado com base na oferta e na procura, o que permite registrar em gráficos as atividades de preços e de volumes e deduzir prováveis tendências dos preços utilizando dados históricos. A combinação dos indicadores utilizados na análise técnica é uma poderosa ferramenta que, com otimizações e ponderações apropriadas, permitem calcular a probabilidade de um movimento futuro dos preços em uma direção.

6 SISTEMAS INTELIGENTES PARA O MERCADO DE CAPITAIS

6.1 Considerações iniciais

A utilização de técnicas de inteligência computacional tem proporcionado melhor compreensão de sistemas denominados complexos e não lineares, em particular os sistemas que possuem vários fatores, de diferente natureza, e influenciados com a evolução do tempo (FARIA et al., 2008). A capacidade dessa inteligência em mapear sistemas complexos torna uma ferramenta atrativa para os problemas relacionados ao comportamento do mercado financeiro. Por exemplo, a tomada de decisão, fundamental para a obtenção de melhores retornos.

Este capítulo apresenta a utilização de duas técnicas de inteligência computacional (lógica *fuzzy* e RNAs) para modelar três tipos de sistemas, sendo um utilizando apenas a lógica *fuzzy*, um utilizando apenas as RNAs e um (conjunto de sistemas híbridos) utilizando a combinação da lógica *fuzzy* e das RNAs. Esses sistemas são utilizados para realizar a previsão do mercado de capitais que usam indicadores técnicos financeiros como dados de entrada.

O sistema modelado utilizando lógica *fuzzy* consiste em obter de forma aproximada o raciocínio humano, a fim de desenvolver um sistema inteligente capaz de armazenar e de recuperar eficientemente grande quantidade de informação e de tomar decisões em ambientes de incerteza e imprecisão. O sistema modelado utilizando RNAs consiste em lidar com dados imprecisos e situações não totalmente definidas, recebendo, ao mesmo tempo, várias entradas e distribuindo-as de maneira organizadas. O sistema modelado hibridamente utiliza a combinação da modelagem dos dois sistemas anteriores.

Este capítulo está organizado da seguinte forma. A arquitetura para a obtenção dos dados é descrita na Seção 6.2. A modelagem dos sistemas é

mostrada detalhadamente na Seção 6.3. A normalização dos dados de entrada é tratada na Seção 6.4. O software desenvolvido utilizando as modelagens é apresentado na Seção 6.5. Os resultados obtidos na utilização dos sistemas implementados com base nas modelagens são discutidos na Seção 6.6.

6.2 Arquitetura para obtenção dos dados

Os dados foram obtidos de *sites* financeiros e armazenados em uma base dados. A atualização dessa base foi feita diariamente, por meio de um software acionado automaticamente de modo a evitar possível sobrecarga a esses *sites*. Quando recebia uma requisição, o servidor buscava as informações na base de dados e não diretamente nos *sites* financeiros. Após a busca, os cálculos necessários foram feitos e a informação solicitada foi retornada ao investidor.

A arquitetura para obtenção de informações é apresentada na Figura 37. Um dispositivo móvel solicita ao servidor informações sobre o mercado financeiro. O servidor procura em sua base de dados informações sobre a movimentação do cenário do mercado de capitais, filtra-os e, após analisá-los, envia ao dispositivo móvel uma sugestão para a tomada de decisão.

A principal característica dessa arquitetura é disponibilizar o máximo de informações necessárias ao investidor, para apoiá-lo na tomada de decisão (compra/venda de ativos financeiros) com menor custo de transmissão de dados. Essa característica consistiu em reunir várias informações "desagregadas" e filtrar as mais relevantes para o usuário final em apenas um lugar - infomediação (HAGEL III; SINGER, 1999).

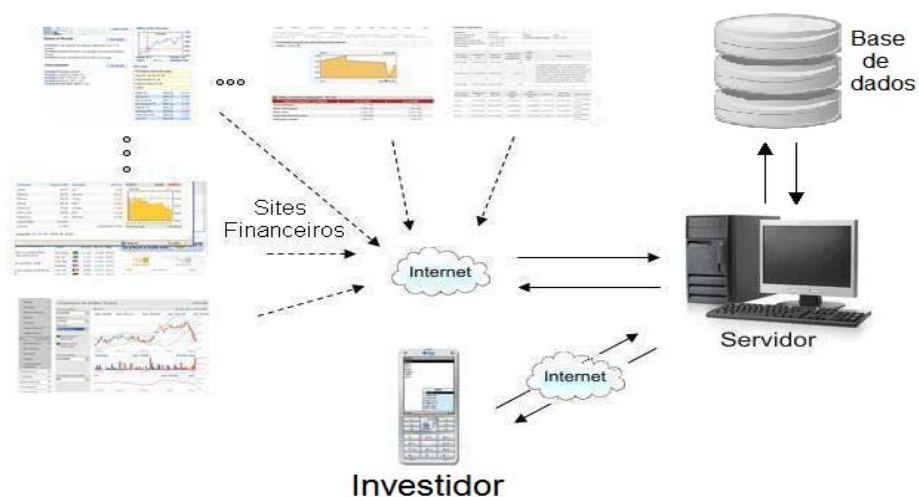


Figura 37 Arquitetura para obtenção dos dados

6.3 Modelagem dos sistemas

6.3.1 Modelagem utilizando lógica *fuzzy*

Essa modelagem consiste na (i) definição dos universos de discurso das variáveis linguísticas do sistema *fuzzy*, (ii) definição da quantidade de termos primários e graus de pertinência dos conjuntos difusos que representam cada termo, (iii) determinação das regras que formam o algoritmo de controle e (iv) definição de parâmetros de projeto, como método de inferência, lógica a ser empregada, forma de "defuzzificação" e atuação do controlador. O esquema de "fuzzificação" e de "defuzzificação" da modelagem do sistema utilizando a lógica *fuzzy* é apresentado na Figura 38.

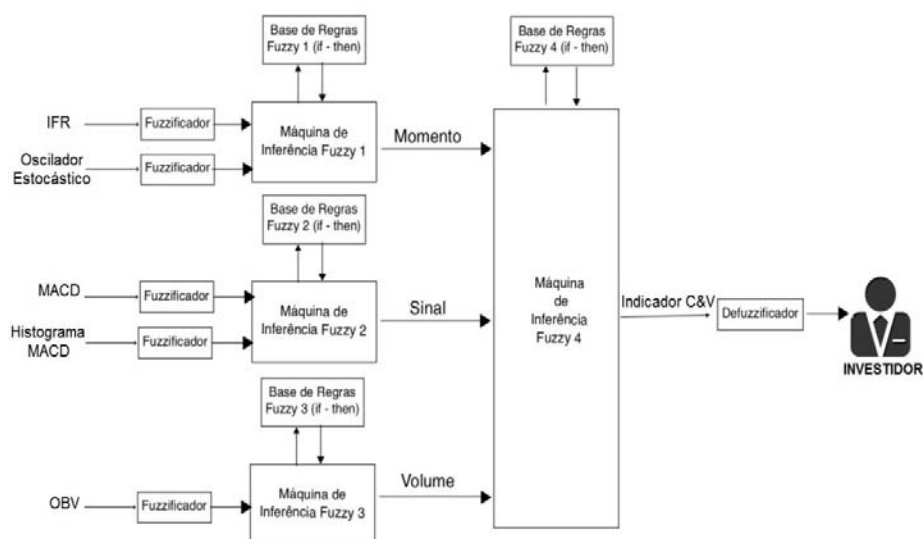


Figura 38 Modelagem utilizando lógica *fuzzy*

Para realizar a "fuzzificação", os indicadores técnicos apresentados anteriormente são utilizados e agrupados da seguinte forma: i) o indicador IFR e o indicador Oscilador Estocástico são utilizados pela Máquina de Inferência *Fuzzy* 1 com a Base de Regras *Fuzzy* 1, cujo resultado é a variável *Momento*; ii) o indicador MACD e o indicador Histograma MACD são utilizados pela Máquina de Inferência *Fuzzy* 2 com a Base de Regras *Fuzzy* 2, cujo resultado é a variável *Sinal*; e iii) o indicador OBV é utilizado pela Máquina de Inferência *Fuzzy* 3 com a Base de Regras *Fuzzy* 3, cujo resultado é a variável *Volume*. As três variáveis resultantes são utilizadas pela Máquina de Inferência *Fuzzy* 4 com a Base de Regras *Fuzzy* 4, cujo resultado é o indicador C&V (compra e venda). Essa variável é "defuzzificada" e o resultado é informado ao investidor. Estes indicadores procuram prever as cotações da

Bolsa de Valores com base na perspectiva histórica dos preços dos ativos financeiros.

Os conjuntos *fuzzy* para a "fuzzificação" do indicador IFR e do indicador Oscilador Estocástico são apresentados na Figura 39 e na Figura 40, respectivamente. A construção destes conjuntos foi baseada nas interpretações de seus gráficos e as intersecções dos conjuntos estão em torno da região sobrecomprado e da região sobrevendido.




Figura 39 Universo IFR




Figura 40 Universo oscilador estocástico

Os conjuntos *fuzzy* Baixo e Muito Baixo estão na região sobrecomprado, o que indica um início de movimento de baixa, por causa do movimento de valorização intenso ou prolongado próximo de reverter. Esses conjuntos proporcionam maior risco às operações de compra e um cenário favorável às operações de venda. A região sobrecomprado do indicador IFR é acima de 70 e do indicador Oscilador Estocástico é acima de 80.

Os conjuntos *fuzzy* Alto e Muito Alto estão na região sobrevendido, o que indica um início de movimento de alta, por causa do movimento de desvalorização intenso ou prolongado próximo de reverter. Esses conjuntos proporcionam maior risco às operações de venda e um cenário favorável às operações de compra. A região sobrevendido do indicador IFR é abaixo de 30 e do indicador Oscilador Estocástico é abaixo de 20.

Os conjuntos *fuzzy* do indicador OBV e do indicador Histograma MACD são apresentados na Figura 41. O domínio da "fuzzificação" varia entre $-\frac{\pi}{2}$ e $\frac{\pi}{2}$ que se refere ao ângulo da reta originada pela regressão linear dos três últimos valores desses indicadores. Esse domínio abrange as possíveis angulações da linha contida no gráfico de análise técnica. A angulação da reta é utilizada para interpretar pontos em declínio ou em ascensão, com apenas o uso do valor do indicador não é possível identificar momentos de declínio ou ascensão do gráfico.




Figura 41 Universo OBV e histograma MACD

No caso do indicador OBV, quanto maior for o ângulo da reta, maior a força compradora; por outro lado, quanto menor for o ângulo da reta, menor a força compradora. No caso do indicador Histograma MACD, quanto maior for o ângulo da reta, maior o indício de tendência de alta; por outro lado, quanto menor for o ângulo da reta, maior o indício de tendência de baixa.

As regras que definem os conjuntos *fuzzy* do universo de discurso MACD são apresentadas na Tabela 1. Basicamente, essas regras verificam em qual zona de tendência está a linha MACD e verificam a convergência entre a linha MACD e a linha de sinal MACD. Por exemplo, na regra número 1,

se a linha MACD ($LinMACD$) estiver acima de zero, a linha MACD ($LinMACD$) estiver acima da linha de sinal MACD ($LinSinal$), o coeficiente angular da linha MACD ($m1$) for positivo e o coeficiente angular da linha de sinal MACD ($m2$), então o indicador MACD ($MACD$) está Muito Alto.

As regras que definem os conjuntos *fuzzy* do universo de discurso Histograma MACD são apresentadas na Tabela 2. Basicamente, essas regras verificam se o gráfico desse indicador está em ascensão ou declínio. Por exemplo, na regra número 1,

se o indicador estiver próximo ao eixo zero ($distancia$) e o coeficiente angular do indicador ($alpha$) estiver uma inclinação alta, então o indicador Histograma MACD ($HIST$) está Muito Alto.

Os conjuntos *fuzzy* da variável *sinal*, da variável *volume* e da variável *momento* são apresentados na Figura 42. O universo de discurso *fuzzy* da variável *Momento* mede a velocidade e a mudança dos movimentos dos preços de um ativo financeiro. O universo de discurso *fuzzy* da variável *Volume* mede a pressão de compra e de venda de um ativo financeiro. O universo de discurso *fuzzy* da variável *Sinal* mede a tendência na qual o preço do ativo financeiro se encontra. Estas análises devem ser ajustadas de acordo com o nível de confiança do investidor. Um modelo de mesmo grau de

confiabilidade para as três análises foi considerado para a construção dos conjuntos.

Tabela 1 Regras para o universo de discurso MACD

Número	Regras Fuzzy
1	<i>Se LinMACD > 0 e LinMACD > LinSinal e m1 > 0 e m1 > m2 então MACD = Muito Alto</i>
2	<i>Se LinMACD > 0 e LinMACD > LinSinal e m1 > 0 e m1 < m2 então MACD = Alto</i>
3	<i>Se LinMACD > 0 e LinMACD > LinSinal e m1 < 0 então MACD = Neutro</i>
4	<i>Se LinMACD < 0 e LinMACD > LinSinal e m1 > 0 e m1 > m2 então MACD = Alto</i>
5	<i>Se LinMACD < 0 e LinMACD > LinSinal e m1 > 0 e m1 < m2 então MACD = Alto</i>
6	<i>Se LinMACD < 0 e LinMACD > LinSinal e m1 < 0 então MACD = Neutro</i>
7	<i>Se LinMACD < 0 e LinMACD < LinSinal e m1 < 0 e m1 < m2 então MACD = Muito Baixo</i>
8	<i>Se LinMACD < 0 e LinMACD < LinSinal e m1 < 0 e m1 > m2 então MACD = Baixo</i>
9	<i>Se LinMACD < 0 e LinMACD < LinSinal e m1 > 0 então MACD = Neutro</i>
10	<i>Se LinMACD > 0 e LinMACD < LinSinal e m1 < 0 e m1 < m2 então MACD = Baixo</i>
11	<i>Se LinMACD > 0 e LinMACD < LinSinal e m1 < 0 e m1 > m2 então MACD = Baixo</i>
12	<i>Se LinMACD > 0 e LinMACD < LinSinal e m1 > 0 então MACD = Neutro</i>
13	<i>Se LinMACD = 0 e m1 > 0 então MACD = Muito Alto</i>
14	<i>Se LinMACD = 0 e m1 < 0 então MACD = Muito Baixo</i>
15	<i>Se m1 = 0 então MACD = Neutro</i>

LinMACD = linha MACD; LinSinal = linha de sinal MACD; m1 = ângulo da reta obtido pela regressão linear dos três últimos valores da linha MACD; m2 = ângulo da reta obtido pela regressão linear dos três últimos valores da linha de sinal MACD

Tabela 2 Regras para o universo de discurso histograma MACD

Número	Regras Fuzzy
1	<i>Se distancia = 0 e alpha = Alto então HIST = Muito Alto</i>
2	<i>Se distancia = 0 e alpha = Baixo então HIST = Muito Baixo</i>
3	<i>Se alpha = Alto então HIST = Alto</i>
4	<i>Se alpha = Muito Alto então HIST = Muito Alto</i>
5	<i>Se alpha = Baixo então HIST = Baixo</i>
6	<i>Se alpha = Muito Baixo então HIST = Muito Baixo</i>
7	<i>Se alpha = Neutro então HIST = Neutro</i>

distancia = distância do indicador Histograma MACD ao eixo zero;
alpha = ângulo da reta obtido pela regressão linear dos três últimos valores do indicador; HIST = Indicador Histograma MACD




Figura 42 Universos sinal, volume e momento

Os conjuntos *fuzzy* do indicador C&V (conjunto *fuzzy* de saída) são apresentados na Figura 43. Se o investidor for conservador, a base triangular do conjunto *fuzzy* Neutro deve ser larga e a base dos conjuntos *fuzzy* Muito Baixo e Muito Alto deve ser estreita. Se o investidor for arrojado, a base triangular do conjunto *fuzzy* Neutro deve ser estreita e a base dos conjuntos *fuzzy* Muito Baixo e Muito Alto deve ser larga. Cabe ressaltar que ajustes na base triangular dos conjuntos *fuzzy* Baixo e Alto devem estar coerentes e consistentes com as alterações dos conjuntos *fuzzy* Neutro, Muito Baixo e Muito Alto.




Figura 43 Universo C&V

As regras da Base de Regras *Fuzzy* 1, da Base de Regras *Fuzzy* 2, da Base de Regras *Fuzzy* 3 e da Base de Regras *Fuzzy* 4 são apresentadas na Tabela 3, na Tabela 4, na Tabela 5 e na Tabela 6, respectivamente.

Tabela 3 Regras *fuzzy* para calcular a intensidade da variável momento

Número	Regras Fuzzy
1	Se IFR = Muito Alto ou Alto e EST = Muito Alto então MOMENTO = Muito Alto
2	Se IFR = Muito Alto e EST = Muito Alto ou Alto então MOMENTO = Muito Alto
3	Se IFR = Alto e EST = Alto então MOMENTO = Alto
4	Se IFR = Neutro e EST = Muito Alto então MOMENTO = Alto
5	Se IFR = Muito Alto e EST = Neutro então MOMENTO = Alto
6	Se IFR = Neutro e EST = Alto ou Neutro ou Baixo então MOMENTO = Neutro
7	Se IFR = Muito Alto ou Alto e EST = Baixo ou Muito Baixo então MOMENTO = Neutro
8	Se IFR = Alto ou Neutro ou Baixo e EST = Neutro então MOMENTO = Neutro
9	Se IFR = Muito Baixo ou Baixo e EST = Muito Alto ou Alto então MOMENTO = Neutro
10	Se IFR = Neutro e EST = Muito Baixo então MOMENTO = Baixo
11	Se IFR = Muito Baixo e EST = Neutro então MOMENTO = Baixo
12	Se IFR = Baixo e EST = Baixo então MOMENTO = Baixo
13	Se IFR = Muito Baixo ou Baixo e EST = Muito Baixo então MOMENTO = Muito Baixo
14	Se IFR = Muito Baixo e EST = Muito Baixo ou Baixo então MOMENTO = Muito Baixo

EST = oscilador estocástico; MOMENTO = momento

Tabela 4 Regras *fuzzy* para calcular a intensidade da variável sinal

Número	Regras Fuzzy
1	Se MACD = Muito Alto ou Alto e HIST = Muito Alto então SINAL = Muito Alto
2	Se MACD = Muito Alto e HIST = Muito Alto ou Alto então SINAL = Muito Alto
3	Se MACD = Alto e HIST = Alto então SINAL = Alto
4	Se MACD = Muito Alto ou Alto e HIST = Baixo ou Muito Baixo então SINAL = Neutro
5	Se MACD = Neutro e HIST = Neutro então SINAL = Neutro
6	Se MACD = Muito Alto ou Alto e HIST = Neutro então SINAL = Alto
7	Se MACD = Muito Baixo ou Baixo e HIST = Neutro então SINAL = Baixo
8	Se MACD = Neutro e HIST = Muito Alto ou Alto então SINAL = Alto
9	Se MACD = Neutro e HIST = Muito Baixo ou Baixo então SINAL = Baixo
10	Se MACD = Muito Baixo ou Baixo e HIST = Alto ou Muito Alto então SINAL = Neutro
11	Se MACD = Baixo e HIST = Baixo então SINAL = Baixo
12	Se MACD = Muito Baixo ou Baixo e HIST = Muito Baixo então SINAL = Muito Baixo
13	Se MACD = Muito Baixo e HIST = Muito Baixo ou Baixo então SINAL = Muito Baixo

HIST = histograma MACD; SINAL = sinal

As regras para calcular a intensidade da variável Momento são apresentadas na Tabela 3. Basicamente, essas regras verificam a combinação do indicador IFR com o indicador Oscilador Estocástico. Por exemplo, na regra número 1,

se o indicador IFR (IFR) estiver Muito Alto ou Alto e o indicador Oscilador Estocástico (EST) estiver Muito Alto, então a variável Momento (MOMENTO) é Muito Alto.

Tabela 5 Regras *fuzzy* para calcular a intensidade da variável `volume`

Número	Regras <i>Fuzzy</i>
1	<i>Se</i> <code>OBV</code> = Muito Alto <i>então</i> <code>VOLUME</code> = Muito Alto
2	<i>Se</i> <code>OBV</code> = Alto <i>então</i> <code>VOLUME</code> = Alto
3	<i>Se</i> <code>OBV</code> = Neutro <i>então</i> <code>VOLUME</code> = Neutro
4	<i>Se</i> <code>OBV</code> = Baixo <i>então</i> <code>VOLUME</code> = Baixo
5	<i>Se</i> <code>OBV</code> = Muito Baixo <i>então</i> <code>VOLUME</code> = Muito Baixo

`VOLUME` = volume

Tabela 6 Regras *fuzzy* para calcular a intensidade do indicador `C&V`

Número	Regras <i>Fuzzy</i>
1	<i>Se</i> <code>MOMENTO</code> = Muito Alto <i>então</i> <code>C&V</code> = Alto
2	<i>Se</i> <code>MOMENTO</code> = Muito Alto ou Alto e <code>SINAL</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Alto
3	<i>Se</i> <code>MOMENTO</code> = Muito Alto ou Alto e <code>VOLUME</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Alto
4	<i>Se</i> <code>SINAL</code> = Muito Alto ou Alto e <code>VOLUME</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Alto
5	<i>Se</i> <code>MOMENTO</code> = Muito Alto ou Alto e <code>SINAL</code> = Muito Alto ou Alto e <code>VOLUME</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Muito Alto
6	<i>Se</i> <code>MOMENTO</code> = Neutro e <code>SINAL</code> = Neutro <i>então</i> <code>C&V</code> = Neutro
7	<i>Se</i> <code>MOMENTO</code> = Neutro e <code>VOLUME</code> = Neutro <i>então</i> <code>C&V</code> = Neutro
8	<i>Se</i> <code>SINAL</code> = Neutro e <code>VOLUME</code> = Neutro <i>então</i> <code>C&V</code> = Neutro
9	<i>Se</i> <code>MOMENTO</code> = Muito Alto ou Alto e <code>SINAL</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = Neutro
10	<i>Se</i> <code>MOMENTO</code> = Muito Alto ou Alto e <code>VOLUME</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = Neutro
11	<i>Se</i> <code>SINAL</code> = Muito Alto ou Alto e <code>VOLUME</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = Neutro
12	<i>Se</i> <code>MOMENTO</code> = Muito Baixo ou Baixo e <code>SINAL</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Neutro
13	<i>Se</i> <code>MOMENTO</code> = Muito Baixo ou Baixo e <code>VOLUME</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Neutro
14	<i>Se</i> <code>SINAL</code> = Muito Baixo ou Baixo e <code>VOLUME</code> = Muito Alto ou Alto <i>então</i> <code>C&V</code> = Neutro
15	<i>Se</i> <code>MOMENTO</code> = Muito Baixo <i>então</i> <code>C&V</code> = Baixo
16	<i>Se</i> <code>MOMENTO</code> = Muito Baixo ou Baixo e <code>SINAL</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = B
17	<i>Se</i> <code>MOMENTO</code> = Muito Baixo ou Baixo e <code>VOLUME</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = B
18	<i>Se</i> <code>SINAL</code> = Muito Baixo ou Baixo e <code>VOLUME</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = B
19	<i>Se</i> <code>MOMENTO</code> = Muito Baixo ou Baixo e <code>SINAL</code> = Muito Baixo ou Baixo e <code>VOLUME</code> = Muito Baixo ou Baixo <i>então</i> <code>C&V</code> = MB

`VOLUME` = volume; `MOMENTO` = momento; `C&V` = compra e venda (C&V)

As regras para calcular a intensidade da variável `Sinal` são apresentadas na Tabela 4. Basicamente, essas regras verificam a combinação do indicador `MACD` com o indicador `Histograma MACD`. Por exemplo, na regra número 1,

se o indicador `MACD` (`MACD`) estiver `Muito Alto` ou `Alto` e o indicador `Histograma MACD` (`HIST`) estiver `Muito Alto`, então a tendência é de alta, implicando em variável `Sinal` (`SINAL`) é `Muito Alto`.

As regras para calcular a intensidade da variável `Volume` são apresentadas na Tabela 5. Basicamente, essas regras verificam se o indicador `OBV` está `Alto` ou `Baixo`. Por exemplo, na regra número 1,

se o indicador `OBV` (`OBV`) estiver `Muito Alto` então a variável `Volume` (`VOLUME`) está `Muito Alto`.

As regras para calcular a intensidade do indicador `C&V` são apresentadas na Tabela 6. Essas regras são utilizadas para sugerir a tomada de decisão ao investidor. Por exemplo, na regra número 2,

se a variável `Momento` (`MOMENTO`) estiver `Muito Alto` ou `Alto` e a variável `Sinal` (`SINAL`) estiver `Muito Alto` ou `Alto` então o indicador `C&V` (`C&V`) é `Muito Alto`, uma tomada de decisão de compra.

Quanto à modelagem de dados, o Diagrama de Entidade-Relacionamento (ELMASRI; NAVATHE, 2011) é usado na modelagem utilizando a lógica *fuzzy* (Figura 44). Os seguintes tipos de dados são representados:

- a) **SistemaFuzzy**: entidade responsável por armazenar os sistemas modelados utilizando a lógica *fuzzy*, podendo conter várias máquinas de inferências e vários universos *fuzzy*;
- b) **RelSistemaFuzzyUniversoFuzzy**: relacionamento entre instâncias da entidade `SistemaFuzzy` e instâncias da entidade `UniversoDeDiscursoFuzzy`;

- c) **UniversoDeDiscursoFuzzy**: entidade responsável por armazenar os universos de discurso *fuzzy*. Por exemplo, o tipo de dado que representa o universo de discurso do indicador Oscilador Estocástico armazena os conjuntos *fuzzy* das variáveis linguísticas que pertence a esse universo de discurso;
- d) **RelConjFuzzyUniversoFuzzy**: relacionamento entre instâncias da entidade `UniversoDeDiscursoFuzzy` e instâncias da entidade `ConjFuzzy`;
- e) **ConjFuzzy**: entidade responsável por armazenar os conjuntos *fuzzy*. Exemplo: Conjunto *Fuzzy* Muito Alto = {se $x > 0$ e $x < 20$, então $f(x) = 1$; se $x > 20$ e $x < 30$, então $f(x) = 1 + (x - 20) / (-10)$; se $x > 30$, então $f(x) = 0$ }, sendo x o valor a ser "fuzzificado";
- f) **RelFuncaoConjFuzzy**: relacionamento entre instâncias da entidade `ConjFuzzy` e instâncias da entidade `Função`;
- g) **Função**: entidade responsável por armazenar as funções. Por exemplo: $\{1 + (x - 20) / (-10)\}$, sendo x o valor a ser "fuzzificado";
- h) **Domínio**: entidade responsável por armazenar os domínios das funções e dos universos *fuzzy*. Por exemplo: o domínio do universo *fuzzy* oscilador estocástico compreende de 0 a 100;
- i) **RelSistemaFuzzyMaquinaInferencia**: relacionamento entre instâncias da entidade `SistemaFuzzy` e instâncias da entidade `MaquinaInferencia`;
- j) **MaquinaInferencia**: entidade responsável por armazenar as máquinas de inferências. Por exemplo, o tipo de dado que representa uma máquina de inferência armazena a sua base de regras e as abreviações de cada regra;

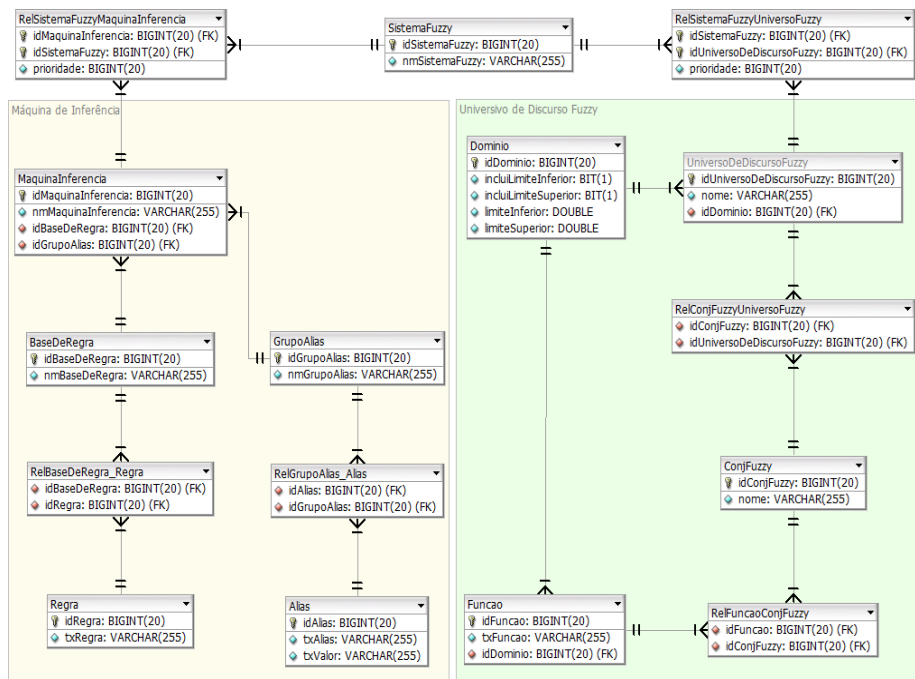


Figura 44 Modelagem do banco de dados do sistema *fuzzy*

- k) **BaseDeRegra**: entidade responsável por armazenar as bases de regras de uma determinada máquina de inferência;
- l) **RelBaseDeRegra_Regra**: relacionamento entre instâncias da entidade BaseDeRegras e instâncias da entidade Regra;
- m) **Regra**: entidade responsável por armazenar as regras. Por exemplo: Se OBV = MA então VOLUME = MA;
- n) **GrupoAlias**: entidade responsável por armazenar os grupos de abreviações de uma determinada máquina de inferência;
- o) **RelGrupoAlias_Alias**: relacionamento entre instâncias da entidade GrupoAlias e instâncias da entidade Alias;
- p) **Alias**: entidade responsável por armazenar as abreviações. Por exemplo: MA = Muito Alto; A = Alto e N = Neutro;

6.3.2 Modelagem utilizando das redes neurais artificiais

Essa modelagem é baseada na apresentada na seção anterior para possibilitar uma comparação entre os resultados obtidos entre ambas. Nessa modelagem, cada máquina de inferência *fuzzy* possui uma RNA correspondente e outras RNAs são utilizadas como redes auxiliares. A modelagem utilizando RNAs é ilustrada na Figura 45 representada de forma simplificada para evitar a perda de legibilidade; para isso, a quantidade de neurônios é indicada abaixo de cada camada de entrada das RNAs.

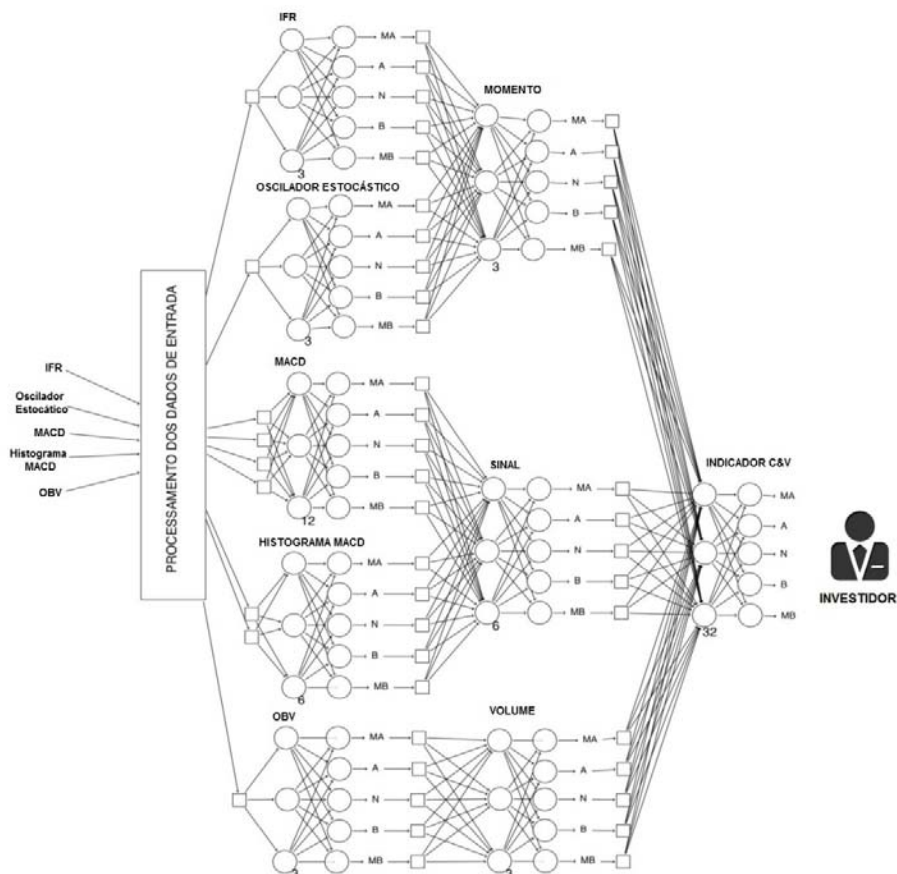


Figura 45 Modelagem utilizando RNAs

Por exemplo, a RNA para o indicador Histograma MACD possui o total de 12 neurônios e a RNA para a variável *Sinal* possui 6 neurônios. Os dados utilizados nas RNAs são processados para que fiquem normalizados com os indicadores: MACD, Histograma MACD, OBV, IFR e Oscilador Estocástico. As RNAs possuem cinco saídas, representando (i) ótima oportunidade de compra (MA = Muito Alta), (ii) boa oportunidade de compra (A = Alta), (iii) sem oportunidade de compra/venda (N = Neutro), (iv) boa oportunidade de venda (B = Baixa) e (v) ótima oportunidade de venda (MB = Muito Baixa). As saídas do primeiro conjunto de RNAs são entradas para as próximas RNAs.

O treinamento dessas RNAs é feita por aprendizagem não supervisionada. O conjunto de dados recebido é analisado, algumas propriedades desses dados são determinadas e a RNA "aprende" a refletir sobre essa propriedade. A RNA utiliza padrões, regularidades e correlações para agrupar o conjunto de dados em classes. As propriedades adquiridas pela RNA sobre os dados são guardadas em arquivos após a aprendizagem. As regras de aprendizagem utilizadas pelas RNAs é a regra gradiente descendente, quando o erro de saída de um neurônio é obtido comparando o resultado por ele calculado com o resultado desejado. O erro atua como mecanismo de controle para melhorar a resposta da RNA. Os dados de entrada das RNAs devem ser normalizados, dado que os algoritmos de treino são sensíveis a intervalos e distribuições diferentes nas suas entradas. Assim, os valores de cada entrada devem ser escalonados em um intervalo [0, 1]. O detalhamento das RNAs para os indicadores é apresentado nas próximas seções.

A RNA utilizada para classificar o indicador IFR é apresentada na Figura 46. Ela recebe como entrada o valor desse indicador, suficiente para identificar início de sobrecomprado e de sobrevendido. Foram utilizados 80 valores classificados segundo os dados contidos na literatura para o treinamento

dessa RNA. Em razão de ser complexo computacionalmente, inicialmente 6 neurônios foram utilizados na camada intermediária. Após vários treinamentos, verificou-se que 3 neurônios são suficientes para classificar esse indicador, sendo a menor quantidade para não ter perda da eficácia na classificação.

A RNA utilizada para classificar o indicador Oscilador Estocástico é apresentada na Figura 47. Ela recebe como entrada o valor desse indicador, suficiente para identificar indício de sobrecomprado e de sobrevendido. Foram utilizadas 80 amostras classificadas de acordo com a região sobrecomprado e a região sobrevendido definidos na literatura para o treinamento dessa RNA. Em razão de ser complexo computacionalmente, inicialmente 6 neurônios foram utilizados na camada intermediária. Após vários treinamentos, verificou-se que 3 neurônios são suficientes para classificar esse indicador, sendo a menor quantidade para não ter perda da eficácia na classificação.




Figura 46 RNA para o indicador IFR




Figura 47 RNA para o indicador oscilador estocástico

A RNA utilizada para classificar o indicador MACD é apresentada na Figura 48. Ela recebe como entrada (i) a distância da linha MACD ao eixo zero, (ii) a diferença entre a linha MACD e a linha de sinal MACD, (iii) a angulação da linha MACD e (iv) a diferença entre a angulação da linha MACD e a linha de sinal MACD. A angulação das linhas é utilizada para identificar possível cruzamento. Somente o valor da linha MACD e o valor da linha de sinal MACD não são suficientes para interpretar o gráfico; por isso, o indicador MACD é decomposto nestes quatro dados de entrada. Foram utilizadas 1000 amostras classificadas segundo as definições contidas na literatura para o treinamento dessa RNA.

Para a interpretação do gráfico desse indicador, são necessárias muitas regras. Por causa disso, inicialmente grande quantidade de neurônios foi utilizada na camada intermediária. A partir dessa quantidade, vários treinamentos foram feitos, diminuindo e aumentando essa quantidade, até chegar a uma quantidade adequada e necessária para não ter perda da eficácia da classificação desse indicador. A quantidade inicial foi 20 neurônios e, após treinamentos, verificou-se que 12 neurônios são suficientes para classificar esse indicador, sendo a menor quantidade para não ter perda da eficácia na classificação.




Figura 48 RNA para o indicador MACD

A RNA utilizada para classificar o indicador Histograma MACD é apresentada na Figura 49. Ela recebe como entrada (i) a distância do indicador Histograma MACD ao eixo zero e (ii) a angulação do valor do Histograma MACD. Essa angulação é utilizada para identificar possível cruzamento no eixo zero. Somente o valor desse indicador não é suficiente para interpretar o gráfico; por isso, ele é decomposto nesses dois dados de entrada. Foram utilizadas 1000 amostras classificadas segundo as definições contidas na literatura para o treinamento dessa RNA.




Figura 49 RNA para o indicador histograma MACD

Para a interpretação desse indicador, é necessário analisar se (i) o valor do indicador está próximo de zero, (ii) o indicador atravessa o eixo 0 e (iii) uma tendência está perdendo ou ganhando força. Tendo em vista essa análise,

inicialmente grande quantidade de neurônios foi utilizada na camada intermediária. A partir dessa quantidade, vários treinamentos foram feitos, diminuindo e aumentando essa quantidade. A quantidade inicial foi 18 neurônios e, após treinamentos, verificou-se que 6 neurônios são suficientes para classificar esse indicador, sendo a menor quantidade para não ter perda da eficácia na classificação.

A RNA utilizada para classificar o indicador OBV é apresentada na Figura 50. Ela recebe como entrada a angulação do valor do indicador OBV. Essa angulação é para interpretar o movimento ascendente ou descendente no gráfico do indicador OBV. Foram utilizadas 100 amostras classificadas conforme as interpretações do indicador na literatura para o treinamento dessa RNA. Para a interpretação desse indicador, é necessário analisar se o indicador desenvolve trajetória ascendente ou descendente. Em razão disso, pequena quantidade de neurônios na camada intermediária foi utilizada no primeiro treinamento. A quantidade inicial foi 8 neurônios e, após treinamentos, verificou-se que 3 neurônios são suficientes para classificar esse indicador, sendo a menor quantidade para não ter perda da eficácia na classificação.




Figura 50 RNA para o indicador OBV

A RNA utilizada para classificar a velocidade e a mudança dos movimentos dos preços (variável Momento) é apresentada na Figura 51. Foram

utilizadas 500 amostras classificadas segundo a base de regras `Momento` para o treinamento dessa RNA (LIMA et al., 2010). Inicialmente, a quantidade utilizada foi 6 neurônios na camada intermediária e, após treinamentos, diminuindo e aumentando essa quantidade, verificou-se que 3 neurônios são suficientes para a classificação dessa variável, sendo a menor quantidade para não ter perda da eficácia na classificação.

A RNA utilizada para classificar a tendência na qual o preço do ativo financeiro se encontra (variável `Sinal`) é apresentada na Figura 52. Foram utilizadas 1200 amostras classificadas segundo a base de regras `Sinal` para o treinamento dessa RNA (LIMA et al., 2010). Inicialmente, a quantidade utilizada foi 30 neurônios na camada intermediária. Após vários treinamentos, diminuindo e aumentando essa quantidade, verificou-se que 6 neurônios são suficientes para classificar essa variável, sendo a menor quantidade para não ter perda da eficácia na classificação.




Figura 51 RNA para a variável `momento`




Figura 52 RNA para a variável `sinal`

A RNA utilizada para classificar a pressão da compra e de venda de um ativo financeiro (variável `Volume`) é ilustrada na Figura 53. Foram utilizadas 800 amostras classificadas segundo a base de regras `Volume` para o treinamento dessa RNA (LIMA et al., 2010). Inicialmente, a quantidade utilizada foi 6 neurônios na camada intermediária. Após vários treinamentos, diminuindo e aumentando essa quantidade, verificou-se que 3 neurônios são suficientes para a classificação essa variável, sendo a menor quantidade para não ter perda da eficácia na classificação.




Figura 53 RNA para a variável volume

A RNA utilizada para indicar uma tomada de decisão (indicador C&V) é apresentada na Figura 54. Ela recebe como entrada as saídas da RNA da variável Sinal, da variável Volume e da variável Momento e fornece ao investidor uma sugestão de compra ou de venda para um ativo financeiro. Foram utilizadas 3000 amostras classificadas segundo a base de regras C&V para o treinamento dessa RNA (LIMA et al., 2010). Em razão de ser complexo computacionalmente, inicialmente foram utilizados 60 neurônios na camada intermediária. Após vários treinamentos, verificou-se que 32 neurônios são suficientes para classificar este indicador, sendo a menor quantidade para não ter perda de eficácia na classificação.




Figura 54 RNA para o Indicador C&V

6.3.3 Modelagens híbridas

As duas modelagens apresentadas anteriormente possuem três etapas de análise. Na primeira etapa, os indicadores técnicos são analisados, agrupando-os em três conjuntos: i) IFR e Oscilador Estocástico; ii) MACD, Histograma MACD; e iii) OBV. Na segunda etapa, as saídas da primeira etapa são analisadas (variável Sinal, variável Volume e variável Momento). Na terceira etapa, as saídas da segunda etapa são analisadas resultando no indicador C&V que fornece subsídio ao investidor sobre a tomada de alguma decisão (compra ou venda) do ativo financeiro. Dessa forma, pode-se combinar as duas técnicas de inteligência computacional abordadas neste trabalho, Lógica *Fuzzy* e RNA, para modelar seis propostas híbridas.

Uma dessas modelagens é apresentada na Figura 55. Nessa modelagem, os indicadores técnicos são processados por RNAs, cujas saídas são utilizadas

como entrada para três máquinas de inferências. As saídas destas máquinas de inferências são conjuntos *fuzzy* da variável Sinal, da variável Volume e da variável Momento. Esses conjuntos *fuzzy* são utilizados como entrada em outra máquina de inferência, cuja saída é indicação de compra e de venda (indicador C&V).

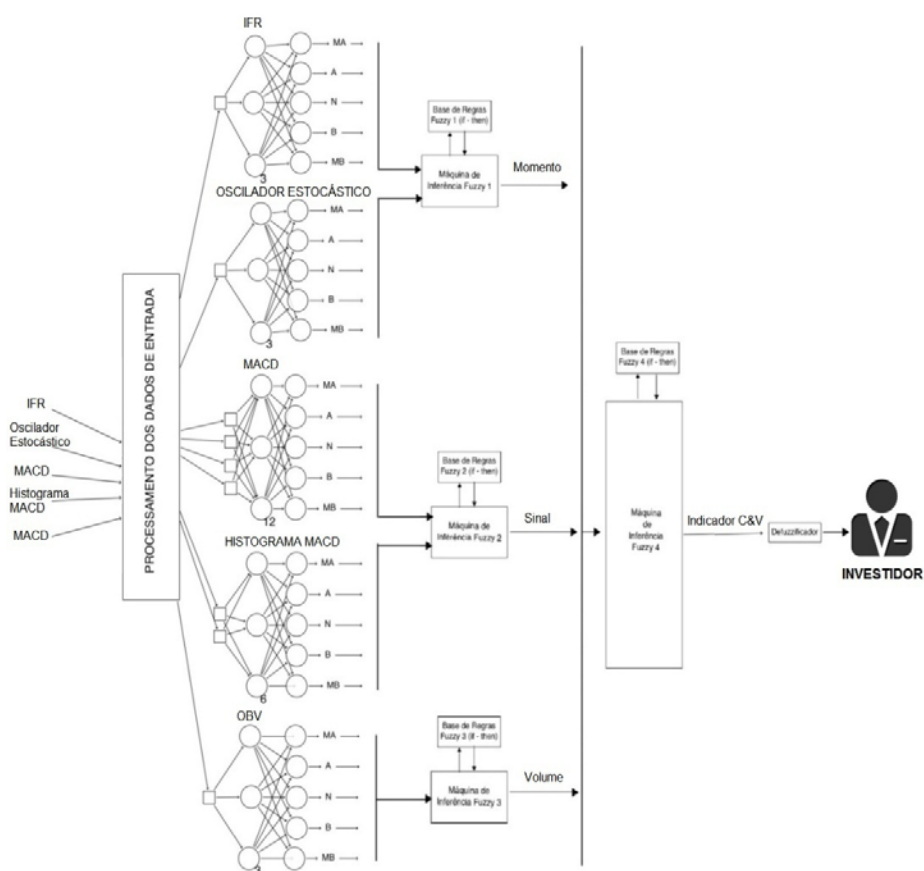


Figura 55 Proposta 1: modelagem híbrida utilizando RNA-*fuzzy-fuzzy*

A segunda proposta de modelagem híbrida é apresentada na Figura 56. Nessa modelagem, os indicadores técnicos são "fuzzificados" e processados e os

conjuntos *fuzzy* obtidos são utilizados como entradas para três RNAs. As saídas dessas RNAs são valores para a variável *Sinal*, a variável *Volume* e a variável *Momento*. Esses valores são utilizados como entrada em outra RNA, cuja saída é indicação de compra e de venda (indicador C&V).

A terceira proposta de modelagem híbrida é apresentada na Figura 56. Nessa modelagem, os indicadores técnicos são processados por RNAs, cujas saídas são utilizadas como entrada para três máquinas de inferências. As saídas dessas máquinas de inferências são conjuntos *fuzzy* para a variável *Sinal*, a variável *Volume* e a variável *Momento*. Esses conjuntos *fuzzy* são processados e utilizados como entrada em outra RNA, cuja saída é uma indicação de compra e de venda (indicador C&V).

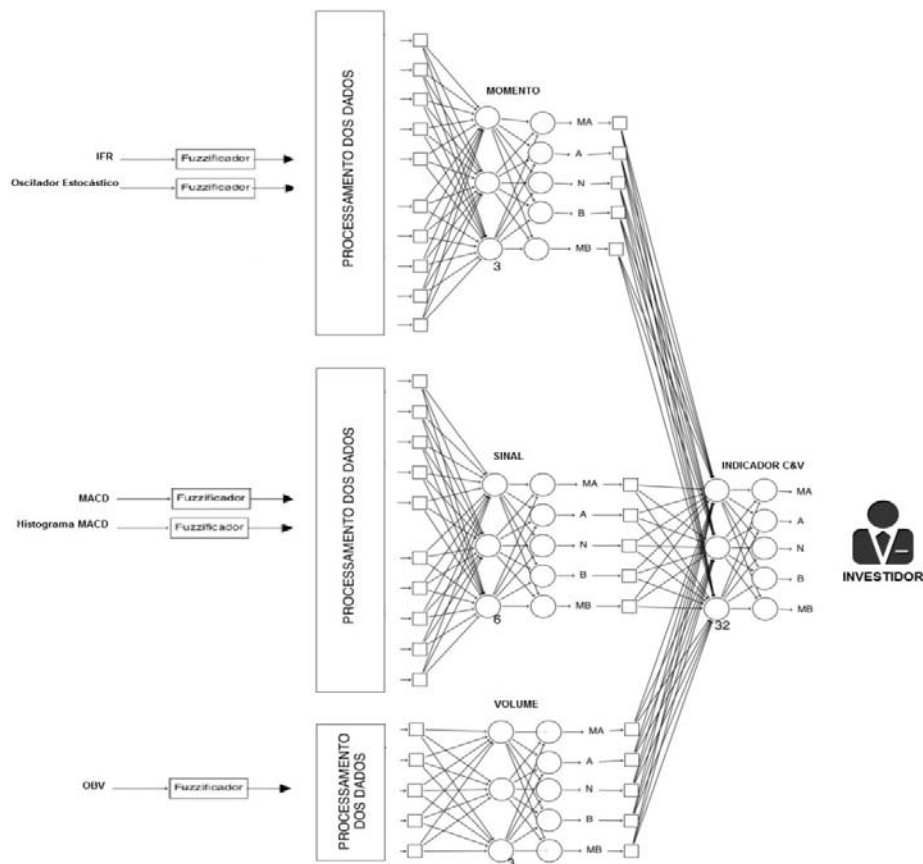


Figura 56 Proposta 2: modelagem híbrida utilizando *fuzzy*-RNA-RNA

A quarta proposta de modelagem híbrida é apresentada na Figura 57. Nessa modelagem, os indicadores técnicos são "fuzzificados" e processados e os conjuntos *fuzzy* obtidos são utilizados como entradas para três RNAs. As saídas destas RNAs são valores para a variável *Sinal*, a variável *Volume* e a variável *Momento*. Esses valores são processados e utilizados como entrada em outra máquina de inferência, cuja saída é indicação de compra e de venda (indicador C&V).

A quinta proposta de modelagem híbrida é apresentada na Figura 58. Nessa modelagem, os indicadores técnicos são processados por RNAs, cuja saída é utilizada como entrada para outras três RNAs. As saídas dessas RNAs são valores para a variável *Sinal*, a variável *Volume* e a variável *Momento*. Esses valores são utilizados como entrada em uma máquina de inferência, cuja saída é indicação de compra e de venda (indicador C&V).




Figura 57 Proposta 3: modelagem híbrida utilizando RNA-fuzzy-RNA

A sexta proposta de modelagem híbrida é apresentada na Figura 60. Nessa modelagem, os indicadores técnicos são "fuzzificados" e os conjuntos *fuzzy* são utilizados como entradas para três máquinas de inferências. As saídas destas máquinas de inferências são conjuntos *fuzzy* para a variável Sinal, a variável Volume e a variável Momento. Esses conjuntos *fuzzy* de saída são utilizados como entrada em uma RNA, cuja saída é indicação de compra e de venda (indicador C&V).

6.4 Normalização dos dados

Os valores fornecidos como entrada de dados para as modelagens apresentadas precisam ser normalizados, sendo que cada indicador deve ser normalizado apropriadamente. Além dessa normalização, o indicador MACD, o indicador Histograma MACD e o indicador OBV precisam ser decomposto.

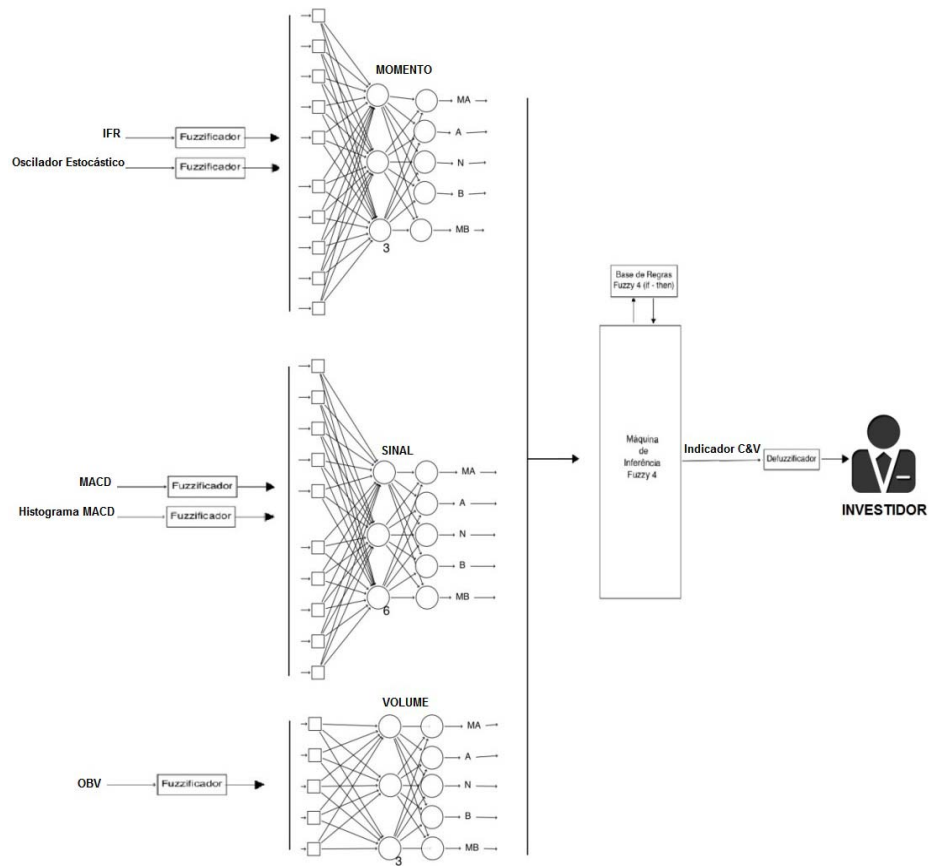


Figura 58 Proposta 4: modelagem híbrida utilizando fuzzy-RNA-fuzzy

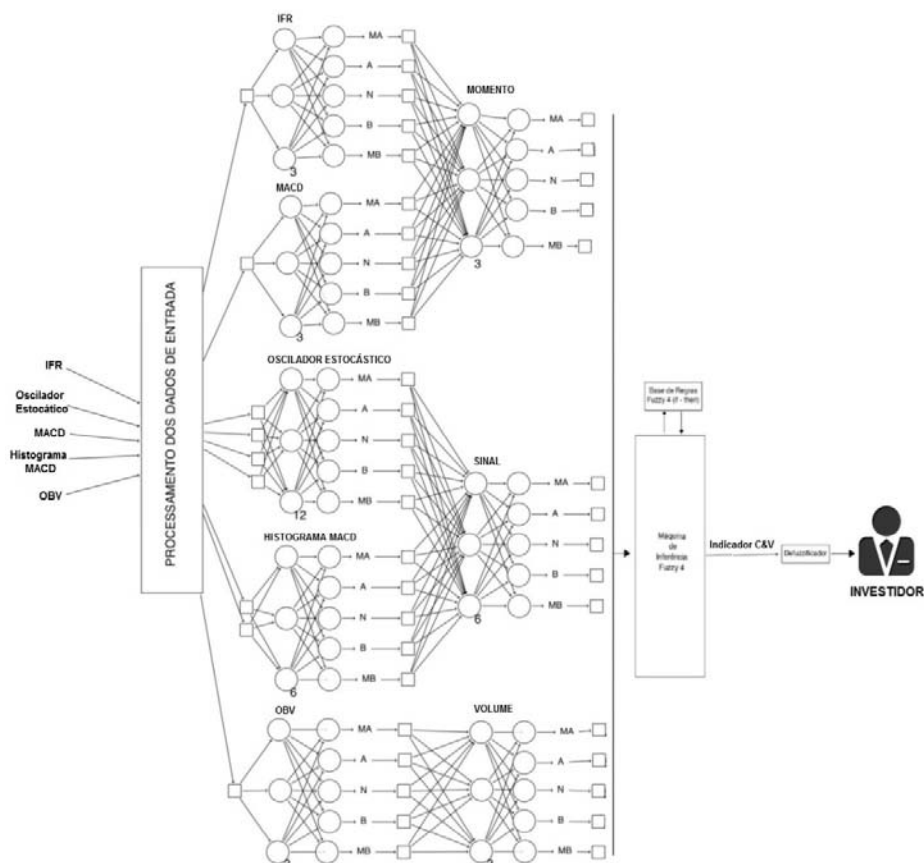


Figura 59 Proposta 5: modelagem híbrida utilizando RNA-RNA-fuzzy

A normalização é feita utilizando a Equação 29, sendo $(Z_t)_N$ o valor normalizado, Z_{\min} o menor valor do conjunto de valores a ser normalizado e Z_{\max} o maior valor do conjunto de valores a ser normalizado.

O coeficiente angular da regressão linear é obtido utilizando a Equação 30, sendo β o coeficiente angular (a inclinação da reta), x_{media} a média da sequência dos dias considerados no cálculo e y_{media} a média dos valores da

normalização do valor MACD. O ângulo da inclinação da reta é obtido calculando o arco tangente de β .

Nas próximas seções, a normalização e a decomposição dos valores de entrada para as modelagens apresentadas anteriormente são discutidas detalhadamente.

$$(Z_p)_N = \frac{Z_t - Z_{\min}}{Z_{\max} - Z_{\min}} \quad 29$$

$$\beta = \frac{\sum_{t=1}^n (x_t - x_{\text{media}}) \cdot (y_t - y_{\text{media}})}{\sum_{t=1}^n (x_t - x_{\text{media}})^2} \quad 30$$

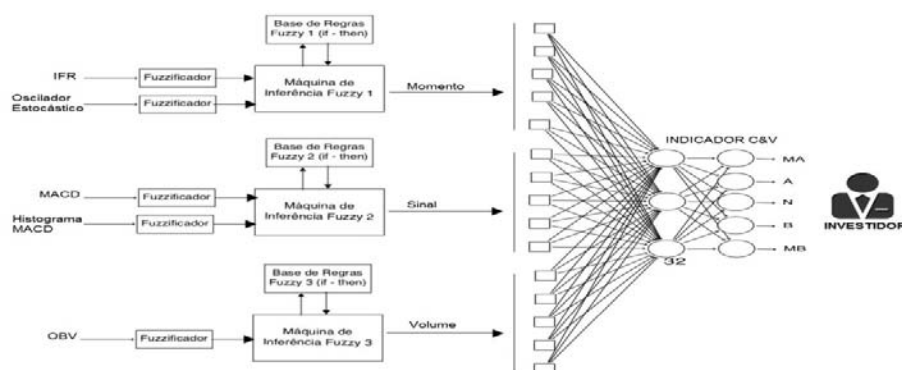


Figura 60 Proposta 6: modelagem híbrida utilizando fuzzy-fuzzy-RNA

6.4.1 Normalização dos valores na modelagem utilizando lógica fuzzy

Na modelagem utilizando lógica *fuzzy*, o indicador IFR e o indicador Oscilador Estocástico não precisam ser normalizados, pois o universo de discurso *fuzzy* de ambos tem o domínio no intervalo $[0; 100]$. O indicador MACD deve ser decomposto em quatro valores e normalizados: i) a distância do valor da linha MACD em relação ao eixo zero; ii) a diferença entre a linha MACD e a linha de sinal MACD; iii) o coeficiente angular da regressão linear

dos três últimos valores da linha MACD; e iv) a diferença entre o ângulo da regressão linear dos três últimos valores da linha MACD e o ângulo da regressão linear dos três últimos valores da linha de sinal MACD. O indicador Histograma MACD deve ser decomposto em dois valores e normalizados: i) a distância do histograma MACD ao eixo zero; e ii) o coeficiente angular da regressão linear dos três últimos valores do histograma MACD. O ângulo da regressão linear dos valores do indicador OBV deve ser normalizado.

6.4.1.1 Normalização da distância da linha MACD ao eixo zero

A distância da linha MACD ao eixo zero varia no intervalo $[-1; 1]$. Um passo a passo do cálculo desta distância é apresentado na Tabela 7. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda e a terceira colunas têm valores da linha MACD e da linha de sinal MACD do ativo BBAS3 no período especificado anteriormente, respectivamente. A quarta coluna possui somente valor zero, utilizado para que o valor zero esteja contido nos valores máximo e mínimo. A quinta e a sexta colunas possuem os valores de máximo e mínimo dos últimos sete dias, considerando os valores da linha MACD, da linha de sinal MACD e o zero, respectivamente. A sétima e a oitava colunas têm o valor normalizado da linha MACD (N_1) e a normalização do valor zero (N_2), conforme a Equação 29, respectivamente. A nona coluna (*Entrada*) possui o valor de $N_1 - N_2$. Os valores de máximo e mínimo, os valores normalizados e o valor na coluna *Entrada* não foram calculados nas seis primeiras linhas, pois são necessários dados de pelo menos sete dias.

Tabela 7 Tabela para calcular a distância da linha MACD ao eixo zero

Data	LinhaMacd	MacdSinal	Zero	Máximo	Mínimo	N ₁	N ₂	Entrada
30/11/11	-312,300	-216,041	0,00					
01/12/11	-185,500	-209,933	0,00					
02/12/11	-110,800	-190,106	0,00					
05/12/11	-107,000	-173,485	0,00					
06/12/11	-83,900	-155,568	0,00					
07/12/11	-113,700	-147,194	0,00					
08/12/11	-144,400	-146,636	0,00	0,000	-312,300	0,538	1,000	-0,462
09/12/11	-125,800	-142,468	0,00	0,000	-209,933	0,401	1,000	-0,599
12/12/11	-161,900	-146,355	0,00	0,000	-190,106	0,148	1,000	-0,852
13/12/11	-183,600	-153,804	0,00	0,000	-183,600	0,000	1,000	-1,000
14/12/11	-222,100	-167,463	0,00	0,000	-222,100	0,000	1,000	-1,000
15/12/11	-269,500	-187,870	0,00	0,000	-269,500	0,000	1,000	-1,000
16/12/11	-331,100	-216,516	0,00	0,000	-331,100	0,000	1,000	-1,000
19/12/11	-393,000	-251,813	0,00	0,000	-393,000	0,000	1,000	-1,000
20/12/11	-403,100	-282,070	0,00	0,000	-403,100	0,000	1,000	-1,000
21/12/11	-366,200	-298,896	0,00	0,000	-403,100	0,092	1,000	-0,908

6.4.1.2 Normalização da diferença entre a linha MACD e a linha de sinal MACD

A diferença entre a linha MACD e a linha de sinal MACD varia no intervalo $[-2; 2]$. Um passo a passo do cálculo desta diferença é apresentado na Tabela 8. A primeira coluna contém os dias no período de 30 de novembro de

2011 a 21 de dezembro de 2012. A segunda e a terceira colunas mostram valores da linha MACD e da linha sinal MACD do ativo BBAS3 no período especificado anteriormente, respectivamente. A quarta e a quinta colunas possuem os valores de máximo e mínimo dos últimos sete dias, considerando os valores da linha MACD e linha de sinal MACD, respectivamente. A sexta e a sétima colunas têm os valores normalizados da linha MACD (N_1) e da linha de sinal MACD (N_2), conforme a Equação 29, respectivamente. A oitava coluna (Entrada) possui o valor de $N_1 - N_2$. Os valores de máximo e mínimo, os valores normalizados e o valor na coluna Entrada não foram calculados nas seis primeiras linhas, pois são necessários dados de pelo menos sete dias.

Tabela 8 Tabela para calcular a diferença entre a linha MACD e a linha de sinal MACD

Data	LinhaMacd	MacdSinal	Máximo	Mínimo	N_1	N_2	Entrada
30/11/11	-312,300	-216,041					
01/12/11	-185,500	-209,933					
02/12/11	-110,800	-190,106					
05/12/11	-107,000	-173,485					
06/12/11	-83,900	-155,568					
07/12/11	-113,700	-147,194					
08/12/11	-144,400	-146,636	-83,900	-312,300	0,735	0,725	0,010
09/12/11	-125,800	-142,468	-83,900	-209,933	0,668	0,535	0,132
12/12/11	-161,900	-146,355	-83,900	-190,106	0,266	0,412	-0,146
13/12/11	-183,600	-153,804	-83,900	-183,600	0,000	0,299	-0,299
14/12/11	-222,100	-167,463	-83,900	-222,100	0,000	0,395	-0,395
15/12/11	-269,500	-187,870	-113,700	-269,500	0,000	0,524	-0,524
16/12/11	-331,100	-216,516	-125,800	-331,100	0,000	0,558	-0,558
19/12/11	-393,000	-251,813	-125,800	-393,000	0,000	0,528	-0,528

20/12/11	-403,100	-282,070	-146,355	-403,100	0,000	0,471	-0,471
21/12/11	-366,200	-298,896	-153,804	-403,100	0,148	0,418	-0,270

6.4.1.3 Normalização do ângulo da linha MACD

O valor do ângulo da linha MACD varia no intervalo $[-1,57; 1,57]$. Um passo a passo do cálculo deste ângulo é apresentado na Tabela 9. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda coluna tem os valores da linha MACD do ativo BBAS3 no período especificado anteriormente. A terceira coluna contém a sequência de dias (x), começando pelo número 1. A quarta coluna possui valores da normalização do valor MACD (y) utilizando os valores dos últimos sete dias, conforme ilustra a Equação 29. A quinta, a sexta, a sétima e a oitava colunas possuem valores para a Equação 30 para calcular o coeficiente angular dos valores dos três últimos dias, sendo que a quinta coluna (F_1) contém o valor de $x_t - x_{medta}$, a sexta coluna (F_2) contém o valor de $y_t - y_{medta}$, a sétima coluna (F_3) contém o valor de $(x_t - x_{medta}) * (y_t - y_{medta})$ e a oitava coluna (F_4) contém o valor de $(x_t - x_{medta})^2$. A nona coluna possui valores de β que corresponde ao coeficiente angular dos valores dos três últimos dias normalizados. A décima coluna (Entrada) contém o valor do arco tangente do coeficiente angular obtido (β).

Abaixo dos valores da linha MACD, há os valores de máximo (Max) e mínimo (Min) calculados e utilizados no cálculo da normalização do valor do indicador MACD (y). Abaixo dos valores da terceira e da quarta colunas, há os valores médios dessas colunas utilizados nos cálculos das colunas seguintes. Os valores das operações da quinta, da sexta, da sétima e da oitava colunas não

foram calculados nas quatro primeiras linhas, pois são necessários dados de pelo menos cinco dias. Além disso, os valores do coeficiente angular e arco tangente do coeficiente angular não foram calculados nas seis primeiras linhas, pois são necessários dados de pelo menos sete dias.

Tabela 9 Tabela para calcular o ângulo da linha MACD

Data	LinhaMacd	x	y	F ₁	F ₂	F ₃	F ₄	β	Entrada
30/11/11	-312,300	1	0,000						
01/12/11	-185,500	2	0,555						
02/12/11	-110,800	3	0,882						
05/12/11	-107,000	4	0,899						
06/12/11	-83,900	5	1,000	-1	0,132	-0,132	1		
07/12/11	-113,700	6	0,870	0	0,001	0,000	0		
08/12/11	-144,400	7	0,735	1	-0,133	-0,133	1	-0,1324	-0,1317
Max	-83,900	Média	Média						
Min	-312,300	6	0,86821						
01/12/11	-185,500	2	0,000						
02/12/11	-110,800	3	0,735						
05/12/11	-107,000	4	0,773						
06/12/11	-83,900	5	1,000						
07/12/11	-113,700	6	0,707	-1	0,140	-0,140	1		
08/12/11	-144,400	7	0,405	0	-0,162	0,000	0		
09/12/11	-125,800	8	0,588	1	0,021	0,021	1	-0,0595	-0,0595
Max	-83,900	Média	Média						
Min	-185,500	7	0,56627						
02/12/11	-110,800	3	0,655						
05/12/11	-107,000	4	0,704						
06/12/11	-83,900	5	1,000						
07/12/11	-113,700	6	0,618						
08/12/11	-144,400	7	0,224	-1	-0,005	0,005	1		
09/12/11	-125,800	8	0,463	0	0,234	0,000	0		
12/12/11	-161,900	9	0,000	1	-0,229	-0,229	1	-0,1122	-0,1117
Max	-83,900	Média	Média						

Min	-161,900	8	0,22906
-----	----------	---	---------

6.4.1.4 Normalização da diferença entre o ângulo da linha MACD e o da linha de sinal MACD

O valor da diferença entre o ângulo da linha MACD e o ângulo da linha de sinal MACD varia no intervalo $[-3,14; 3,14]$. Um passo a passo do cálculo desta diferença é apresentado na Tabela 10. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda e a terceira colunas possuem os valores da linha MACD e da linha de sinal MACD do ativo BBAS3 no período especificado anteriormente, respectivamente. A quarta coluna contém a sequência de dias (x), começando pelo número 1. A quinta e a sexta colunas possuem os valores normalizados da linha MACD (N_1) e da linha de sinal MACD (N_2), utilizando os valores dos últimos sete dias, conforme ilustra a Equação 29, respectivamente. A sétima coluna (Entrada) possui o valor de $N_1 - N_2$.

Abaixo dos valores da linha MACD e linha de sinal MACD, há os valores de máximo (Max) e mínimo (Min) calculados e utilizados no cálculo de N_1 e N_2 . Abaixo da quinta e sexta colunas, encontram-se os coeficientes angulares e os ângulos da regressão linear de cada linha, utilizando os três últimos valores, respectivamente.

Tabela 10 Tabela para calcular o valor da diferença entre o ângulo da linha MACD e o ângulo da linha de sinal MACD

Data	LinhaMacd	LinhaSinal	X	N ₁	N ₂	Entrada
30/11/11	-312,300	-216,041	1	0,000	0,000	
01/12/11	-185,500	-209,933	2	0,555	0,088	
02/12/11	-110,800	-190,106	3	0,882	0,374	
05/12/11	-107,000	-173,485	4	0,899	0,613	
06/12/11	-83,900	-155,568	5	1,000	0,871	
07/12/11	-113,700	-147,194	6	0,870	0,992	
08/12/11	-144,400	-146,636	7	0,735	1,000	
Max	-83,900	-146,636	Beta	-0,1324	0,0643	
Min	-312,300	-216,041	Ângulo	-0,1317	0,0643	-0,1959
01/12/11	-185,500	-209,933	2	0,000	0,000	
02/12/11	-110,800	-190,106	3	0,735	0,294	
05/12/11	-107,000	-173,485	4	0,773	0,540	
06/12/11	-83,900	-155,568	5	1,000	0,806	
07/12/11	-113,700	-147,194	6	0,707	0,930	
08/12/11	-144,400	-146,636	7	0,405	0,938	
09/12/11	-125,800	-142,468	8	0,588	1,000	
Max	-83,900	-142,468	Beta	-0,0595	0,0350	
Min	-185,500	-209,933	Ângulo	-0,0595	0,0350	-0,0945
02/12/11	-110,800	-190,106	3	0,655	0,000	
05/12/11	-107,000	-173,485	4	0,704	0,349	
06/12/11	-83,900	-155,568	5	1,000	0,725	
07/12/11	-113,700	-147,194	6	0,618	0,901	
08/12/11	-144,400	-146,636	7	0,224	0,913	
09/12/11	-125,800	-142,468	8	0,463	1,000	
12/12/11	-161,900	-146,355	9	0,000	0,918	
Max	-83,900	-142,468	Beta	-0,1122	0,0029	
Min	-161,900	-190,106	Ângulo	-0,1117	0,0029	-0,1147

6.4.1.5 Normalização da distância do histograma MACD ao eixo zero

O valor da distância do indicador Histograma MACD ao eixo zero varia no intervalo $[0; 1]$. Um passo a passo do cálculo desta distância é apresentado na Tabela 11. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda coluna possui os valores do indicador Histograma MACD do ativo BBAS3 no período especificado anteriormente. A terceira coluna contém somente o valor zero, utilizado para que o valor zero esteja nos valores máximo e mínimo. A quarta e a quinta colunas possuem os valores de máximo e mínimo dos últimos sete dias, respectivamente. A sexta e a sétima colunas possuem os valores normalizados do indicador Histograma MACD (N_1) e do valor zero (N_2), conforme ilustra a Equação 29, respectivamente. A oitava coluna contém o valor $N_1 - N_2$. A nona coluna tem o valor absoluto da diferença entre as duas normalizações ($N_1 - N_2$). Os valores da quarta, da quinta, da sexta, da sétima e da oitava coluna não foram calculados nas seis primeiras linhas, pois são necessários dados de pelo menos sete dias.

Tabela 11 Tabela para calcular a distância do valor do indicador histograma MACD ao eixo zero

Data	Histograma	Zero	Máximo	Mínimo	N_1	N_2	$N_1 - N_2$	Entrada
30/11/11	-96,259	0,000						
01/12/11	24,433	0,000						
02/12/11	79,306	0,000						
05/12/11	66,485	0,000						
06/12/11	71,668	0,000						
07/12/11	33,494	0,000						
08/12/11	2,236	0,000	79,306	-96,259	0,561	0,548	0,013	0,013
09/12/11	16,668	0,000	79,306	0,000	0,210	0,000	0,210	0,210
12/12/11	-15,545	0,000	79,306	-15,545	0,000	0,164	-0,164	0,164
13/12/11	-29,796	0,000	71,668	-29,796	0,000	0,294	-0,294	0,294
14/12/11	-54,637	0,000	71,668	-54,637	0,000	0,433	-0,433	0,433

15/12/11	-81,630	0,000	33,494	-81,630	0,000	0,709	-0,709	0,709
16/12/11	-114,584	0,000	16,668	-114,584	0,000	0,873	-0,873	0,873
19/12/11	-141,187	0,000	16,668	-141,187	0,000	0,894	-0,894	0,894
20/12/11	-121,030	0,000	0,000	-141,187	0,143	1,000	-0,857	0,857
21/12/11	-67,304	0,000	0,000	-141,187	0,523	1,000	-0,477	0,477

6.4.1.6 Normalização do ângulo do histograma MACD

O valor do ângulo do indicador Histograma MACD varia no intervalo $[-1,57; 1,57]$. Um passo a passo do cálculo deste ângulo é apresentado na Tabela 12. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda coluna possui os valores do indicador Histograma MACD do ativo BBAS3 no período especificado anteriormente. A terceira coluna contém a sequência de dias (x), começando pelo número 1. A quarta coluna possui os valores normalizados do histograma MACD (y), utilizando os valores dos últimos sete dias, conforme ilustra a Equação 29. A quinta, a sexta, a sétima e a oitava colunas possuem valores para a Equação 30, para calcular o coeficiente angular dos valores dos três últimos dias, sendo que a quinta coluna (F_1) contém o valor de $x_t - x_{medta}$, a sexta coluna (F_2) contém o valor de $y_t - y_{medta}$, a sétima coluna (F_3) contém o valor de $(x_t - x_{medta}) * (y_t - y_{medta})$ e a oitava coluna (F_4) contém o valor de $(x_t - x_{medta})^2$. A nona coluna possui valores de β que corresponde ao coeficiente angular dos valores dos três últimos dias normalizados. A décima coluna (Entrada) contém o valor do arco tangente do coeficiente angular obtido (β).

Abaixo dos valores do indicador Histograma MACD, há os valores de máximo (Max) e mínimo (Min) calculados e utilizados no cálculo da

normalização do indicador Histograma MACD (\bar{y}). Abaixo dos valores da terceira e da quarta colunas, há os valores médios dessas colunas utilizados nos cálculos das colunas seguintes. Os valores das operações da quinta, da sexta, da sétima e da oitava colunas não foram calculados nas quatro primeiras linhas, pois são necessários dados de pelo menos cinco dias. Além disso, os valores do coeficiente angular e arco tangente do coeficiente angular não foram calculados nas seis primeiras linhas pois são necessários dados de pelo menos sete dias.

Tabela 12 Tabela para calcular o ângulo do indicador histograma MACD

Data	Histograma	x	y	F ₁	F ₂	F ₃	F ₄	β	Entrada
30/11/11	-96,259	1	0,000						
01/12/11	24,433	2	0,687						
02/12/11	79,306	3	1,000						
05/12/11	66,485	4	0,927						
06/12/11	71,668	5	0,956	-1	0,204	-0,204	1		
07/12/11	33,494	6	0,739	0	-0,013	0,000	0		
08/12/11	2,236	7	0,561	1	-0,191	-0,191	1	-0,1977	-0,1952
Max	79,306	Média	Média						
Min	-96,259	6	0,75219						
01/12/11	24,433	2	0,288						
02/12/11	79,306	3	1,000						
05/12/11	66,485	4	0,834						
06/12/11	71,668	5	0,901						
07/12/11	33,494	6	0,406	-1	0,208	-0,208	1		
08/12/11	2,236	7	0,000	0	-0,198	0,000	0		
09/12/11	16,668	8	0,187	1	-0,010	-0,010	1	-0,1092	-0,1087
Max	79,306	Média	Média						
Min	2,236	7	0,19762						
02/12/11	79,306	3	1,000						
05/12/11	66,485	4	0,865						
06/12/11	71,668	5	0,919						
07/12/11	33,494	6	0,517						
08/12/11	2,236	7	0,187	-1	0,012	-0,012	1		
09/12/11	16,668	8	0,340	0	0,164	0,000	0		
12/12/11	-15,545	9	0,000	1	-0,176	-0,176	1	-0,0937	-0,0935

Max	79,306	Média	Média
Min	-15,545	8	0,17569

6.4.1.7 Normalização do ângulo do indicador OBV

O valor do ângulo do indicador OBV varia no intervalo $[-1,57; 1,57]$. Um passo a passo do cálculo deste ângulo é apresentado na Tabela 13. A primeira coluna contém os dias no período de 30 de novembro de 2011 a 21 de dezembro de 2012. A segunda coluna tem os valores do indicador OBV do ativo BBAS3 no período especificado anteriormente. A terceira coluna contém a sequência de dias (x), começando pelo número 1.

A quarta coluna contém os valores normalizados do indicador OBV (y) utilizando os valores dos últimos sete dias, conforme ilustra a Equação 29. A quinta, a sexta, a sétima e a oitava colunas possuem valores para a Equação 30, para calcular o coeficiente angular dos valores dos três últimos dias, sendo que a quinta coluna (F_1) contém o valor de $x_t - x_{medta}$, a sexta coluna (F_2) contém o valor de $y_t - y_{medta}$, a sétima coluna (F_3) contém o valor de $(x_t - x_{medta}) * (y_t - y_{medta})$ e a oitava coluna (F_4) contém o valor de $(x_t - x_{medta})^2$. A nona coluna possui valores de β que corresponde ao coeficiente angular dos valores dos três últimos dias normalizados. A décima coluna (Entrada) contém o valor do arco tangente do coeficiente angular obtido (β). Abaixo dos valores do indicador OBV, há os valores de máximo (Max) e mínimo (Min) calculados e utilizados no cálculo da normalização do indicador OBV (y). Abaixo dos valores da terceira e da quarta colunas, há os valores médios dessas colunas utilizados nos cálculos das colunas seguintes.

Tabela 13 Tabela para calcular o ângulo do indicador OBV

Data	OBV	x	Y	F ₁	F ₂	F ₃	F ₄	B	Entrada
30/11/11	15403963049	1	0,753						
01/12/11	15411692849	2	1,000						
02/12/11	15404500849	3	0,770						
05/12/11	15391649449	4	0,360						
06/12/11	15398053949	5	0,564	-1	0,286	-0,286	1		
07/12/11	15388894049	6	0,272	0	-0,007	0,000	0		
08/12/11	15380392949	7	0,000	1	-0,279	-0,279	1	-0,2821	-0,2750
Max	15411692849	Média	Média						
Min	15380392949	6	0,27862						
01/12/11	15411692849	2	1,000						
02/12/11	15404500849	3	0,770						
05/12/11	15391649449	4	0,360						
06/12/11	15398053949	5	0,564						
07/12/11	15388894049	6	0,272	-1	0,103	-0,103	1		
08/12/11	15380392949	7	0,000	0	-0,169	0,000	0		
09/12/11	15387759749	8	0,235	1	0,066	0,066	1	-0,0181	-0,0181
Max	15411692849	Média	Média						
Min	15380392949	7	0,16899						
02/12/11	15404500849	3	1,000						
05/12/11	15391649449	4	0,467						
06/12/11	15398053949	5	0,733						
07/12/11	15388894049	6	0,353						

08/12/11	15380392949	7	0,000	-1	-0,125	0,125	1		
09/12/11	15387759749	8	0,306	0	0,180	0,000	0		
12/12/11	15382088149	9	0,070	1	-0,055	-0,055	1	0,0352	0,0351
Max	15404500849	Média	Média						
Min	15380392949	8	0,1253						

Os valores das operações da quinta, da sexta, da sétima e da oitava colunas não foram calculados nas quatro primeiras linhas, pois são necessários dados de pelo menos cinco dias. Além disso, os valores do coeficiente angular e arco tangente do coeficiente angular não foram calculados nas seis primeiras linhas, pois são necessários dados de pelo menos sete dias.

6.4.2 Normalização dos valores na modelagem utilizando RNAs

Os valores de entrada para as RNAs devem ser normalizados no intervalo $[0, 1]$. A normalização desses valores consiste em adaptá-los da modelagem utilizando lógica *fuzzy* para o intervalo $[0, 1]$. As equações para realizar a normalização foram baseadas na Equação 29, porém alguns valores de máximo e mínimo são diferentes. Essas equações com os valores apropriados são apresentadas na Tabela 14. Vale ressaltar a não necessidade para a normalização da distância do indicador Histograma MACD ao eixo zero, pois esta distância encontra-se no intervalo $[0, 1]$.

Tabela 14 Equações de normalização

Valores Normalizados	Z_{min}	Z_{max}	Equação	Identificador
Indicador IFR	0	100	$(ifr)_x = \frac{ifr}{100}$	Equação 31

Indicador				
Oscilador Estocástico	0	100	$(est)_N = \frac{est_t}{100}$	Equação 32
Distância da linha MACD ao eixo zero	-1	1	$(lnhamacd)_N = \frac{lnhamacd_t + 1}{2}$	Equação 33
Diferença entre a linha MACD e a linha de sinal MACD	-2	2	$(difmacd)_N = \frac{difmacd_t + 2}{4}$	Equação 34
normalização do ângulo da linha MACD	-	1,57	$(alphamacd)_N = \frac{alphamacd_t + 1,57}{3,14}$	Equação 135
Diferença entre o ângulo da linha MACD e o ângulo da linha sinal MACD	-	3,14	$(difalphamacd)_N = \frac{difalphamacd_t + 3,14}{6,28}$	Equação 36
Ângulo do indicador Histograma MACD	-	1,57	$(alphahist)_N = \frac{alphahist_t + 1,57}{3,14}$	Equação 37
Ângulo do indicador OBV	-	1,57	$(alphaobv)_N = \frac{alphaobv_t + 1,57}{3,14}$	Equação 38

6.4.3 Normalização dos valores na modelagem utilizando RNAs

Os valores de entrada para as RNAs devem ser normalizados no intervalo [0, 1]. A normalização desses valores consiste em adaptá-los da modelagem utilizando lógica *fuzzy* para o intervalo [0, 1]. As equações para realizar a normalização foram baseadas na Equação 29, porém alguns valores de máximo e mínimo são diferentes. Essas equações com os valores apropriados são apresentadas na Tabela 14. Vale ressaltar a não necessidade para a

30/11/11	54,074	0,541	50,452	0,505	-0,742	0,129	-0,229	0,443
01/12/11	57,970	0,580	99,941	0,999	-0,498	0,251	0,066	0,516
02/12/11	61,825	0,618	83,445	0,834	-0,302	0,349	0,248	0,562
05/12/11	57,321	0,573	48,998	0,490	-0,292	0,354	0,251	0,563
06/12/11	59,031	0,590	60,680	0,607	-0,229	0,386	0,253	0,563
07/12/11	58,489	0,585	30,581	0,306	-0,310	0,345	0,118	0,530
08/12/11	60,461	0,605	25,241	0,252	-0,462	0,269	0,010	0,502
09/12/11	57,871	0,579	50,481	0,505	-0,599	0,200	0,132	0,533
12/12/11	18,447	0,184	18,447	0,184	-0,852	0,074	-0,146	0,463
13/12/11	21,360	0,214	21,360	0,214	-1,000	0,000	-0,299	0,425
14/12/11	6,794	0,068	6,794	0,068	-1,000	0,000	-0,395	0,401
15/12/11	0,000	0,000	0,000	0,000	-1,000	0,000	-0,524	0,369
16/12/11	0,000	0,000	0,000	0,000	-1,000	0,000	-0,558	0,360
19/12/11	0,000	0,000	0,000	0,000	-1,000	0,000	-0,528	0,368
20/12/11	15,693	0,157	15,693	0,157	-1,000	0,000	-0,471	0,382
21/12/11	39,168	0,392	39,168	0,392	-0,908	0,046	-0,270	0,433

Tabela 16 Exemplos de normalização

Data	Exemplos de Normalização							
	Ângulo da linha MACD para a modelagem RNA		Diferença entre o ângulo da linha MACD e o ângulo da linha de sinal MACD		Indicador Histograma MACD		Indicador OBV	
	alphamacd	alphamacd _n	difalphamacd	difalphamacd _n	alphahist	alphahist _n	alphaobv	alphaobv _n
30/11/11	0,035	0,511	0,160	0,525	0,341	0,609	0,257	0,582
01/12/11	0,464	0,648	0,504	0,580	0,388	0,624	0,464	0,648
02/12/11	0,375	0,619	0,298	0,547	0,286	0,591	0,014	0,505
05/12/11	0,150	0,548	-0,009	0,499	0,070	0,522	-0,464	0,352
06/12/11	0,047	0,515	-0,202	0,468	-0,015	0,495	-0,159	0,449

07/12/11	-0,012	0,496	-0,200	0,468	-0,065	0,479	-0,060	0,481
08/12/11	-0,132	0,458	-0,196	0,469	-0,195	0,438	-0,275	0,412
09/12/11	-0,059	0,481	-0,094	0,485	-0,109	0,465	-0,018	0,494
12/12/11	-0,112	0,464	-0,115	0,482	-0,093	0,470	0,035	0,511
13/12/11	-0,282	0,410	-0,101	0,484	-0,225	0,428	0,003	0,501
14/12/11	-0,214	0,432	0,185	0,529	-0,154	0,451	-0,078	0,475
15/12/11	-0,269	0,414	0,090	0,514	-0,221	0,429	-0,436	0,361
16/12/11	-0,259	0,417	0,060	0,510	-0,225	0,428	-0,265	0,416
19/12/11	-0,227	0,428	0,057	0,509	-0,186	0,441	-0,208	0,434
20/12/11	-0,148	0,453	0,089	0,514	-0,026	0,492	0,009	0,503
21/12/11	0,061	0,519	0,222	0,535	0,320	0,602	0,236	0,575

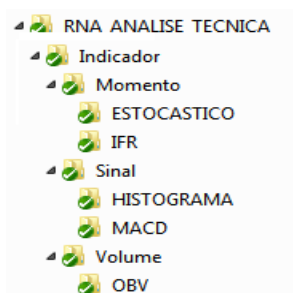


Figura 61 Estrutura de diretório no Scilab

Os seguintes diretórios e arquivos encontram-se no diretório RNA_ANALISE_TECNICA:

- a) `_arquivo.sce`: arquivo com funções para manipular arquivos de treinamento;

- b) `_carregar_rede_de_treinamento.sce`: arquivo com chamadas para a biblioteca ANN ToolBox do Scilab;
- c) `_dados.sce`: arquivo com funções para coletar os indicadores técnicos;
- d) `_treinamento.sce`: arquivo com funções para treinar as RNAs;
- e) `_util.sce`: arquivo com variáveis globais (taxa de aprendizagem, número de épocas etc.) e funções genéricas, por exemplo, a normalização de dados;
- f) `RNA_ANALISE_TECNICA.sce`: arquivo com funções para "carregar" (*upload*) as RNAs treinadas e armazenadas em outros subdiretórios;
- g) `Indicador`: diretório com arquivos responsáveis pelos cálculos e pelo treinamento da RNA para indicadores C&V.

Os arquivos de cada RNA estão nos demais subdiretórios que contêm:

- a) Um arquivo com a quantidade de entrada de dados na RNA;
- b) Arquivos com amostras de treinamento. A quantidade de arquivos depende da quantidade de dados de entrada. Por exemplo, se a RNA receber um dado de entrada, então se deve ter um arquivo de amostra, caso ela receba dois dados de entrada então se deve ter dois arquivos de amostra e assim sucessivamente;
- c) Cinco arquivos para classificação das amostras, cujo identificador começa com o CLASSE. Cada arquivo contém a classificação de cada amostra que indica a possibilidade de compra, neutralidade e venda de um ativo financeiro;

- d) Um arquivo que define a estrutura da RNA. Esse arquivo tem a quantidade de camadas e a quantidade de neurônios por camada. Seu identificador começa com a letra N;
- e) Um arquivo para o treinamento da rede. Esse arquivo é responsável por ler as amostras e suas respectivas classificações e iniciar o treinamento;
- f) Arquivos para armazenar os dados obtidos no treino. O aprendizado adquirido durante o treinamento é armazenado em arquivos. Esse armazenamento é feito para evitar a perda dos dados de treinamento e evitar que se faça o mesmo treinamento com os mesmos dados de entradas mais de uma vez. O identificador desses arquivos começa com a letra W;
- g) Um arquivo para carregar os dados obtidos feito em um treinamento. Os dados obtidos pelo treinamento devem estar em memória e a classificação dos dados não amostrais é realizada;

O conteúdo dos arquivos das RNAs é descrito na Tabela 17, indicando (i) o arquivo que contém a quantidade de entrada de dados, (ii) os arquivos que contêm as amostras de treinamento, (iii) a classificação das amostras, (iv) a definição da estrutura da RNA, (v) o treinamento, (vi) os dados obtidos da RNA treinada e (vii) a rotina para classificar os dados não amostrais.

Tabela 17 Descrição do conteúdo dos arquivos de cada RNA

RNA	Conteúdo do arquivo	Nome do arquivo
IFR	Quantidade de Entrada	IFR.txt
	Amostras	IFR_1.txt
	Classificações	CLASSE_IFR_MUITOALTO.txt, CLASSE_IFR_ALTO.txt,
		CLASSE_IFR_NEUTRO.txt, CLASSE_IFR_BAIXO.txt, CLASSE_IFR_MUITOBAIXO.txt,

	Estrutura RNA	N_IFR.txt W_IFR.txt
	Rede Treinada	W1_IFR_1.txt, ..., W1_IFR_6.txt W2_IFR_1.txt, ..., W2_IFR_6.txt
	Dados de Treinamento	treinamentoRede_IFR.sce
	Classificação	RNA_IFR.sce
Estocástico	Quantidade de Entrada	ESTOCASTICO.txt
	Amostras	ESTOCASTICO_1.txt CLASSE_ESTOCASTICO_MUITOALTO.txt, CLASSE_ESTOCASTICO_ALTO.txt,
	Classificações	CLASSE_ESTOCASTICO_NEUTRO.txt, CLASSE_ESTOCASTICO_BAIXO.txt, CLASSE_ESTOCASTICO_MUITOBAIXO.txt
	Estrutura RNA	RNA_ESTOCASTICO.txt W_ESTOCASTICO.txt
	Rede Treinada	W1_ESTOCASTICO_1.txt, ..., 1_ESTOCASTICO_6.txt W2_ESTOCASTICO_1.txt, ..., 2_ESTOCASTICO_6.txt
	Dados de Treinamento	treinamentoRede_ESTOCASTICO.sce
	Classificação	RNA_ESTOCASTICO.sce

“Tabela 17, continuação”

RNA	Conteúdo do arquivo	Nome do arquivo
Momento	Quantidade de Entrada	MOMENTO.txt
	Amostras	MOMENTO_1.txt, ..., MOMENTO_10.txt, CLASSE_MOMENTO_MUITOALTO.txt, CLASSE_MOMENTO_ALTO.txt,
	Classificações	CLASSE_MOMENTO_NEUTRO.txt, CLASSE_MOMENTO_BAIXO.txt, CLASSE_MOMENTO_MUITOBAIXO.txt
	Estrutura RNA	RNA_MOMENTO.txt W_MOMENTO.txt
	Rede Treinada	W1_MOMENTO_1.txt, ..., W1_MOMENTO_11.txt W2_MOMENTO_1.txt, ..., W2_MOMENTO_11.txt
	Dados de Treinamento	treinamentoRede_MOMENTO.sce
	Classificação	RNA_MOMENTO.sce

Histograma	Quantidade de Entrada	HISTOGRAMA.txt
	Amostras	HISTOGRAMA_1.txt e HISTOGRAMA_2.txt
	Classificações	CLASSE_HISTOGRAMA_MUITOALTO.txt, CLASSE_HISTOGRAMA_ALTO.txt, CLASSE_HISTOGRAMA_NEUTRO.txt, CLASSE_HISTOGRAMA_BAIXO.txt, CLASSE_HISTOGRAMA_MUITOBAIXO.txt
	Estrutura RNA	RNA_HISTOGRAMA.txt W_HISTOGRAMA.txt
	Rede Treinada	W1_HISTOGRAMA_1.txt, ..., W1_HISTOGRAMA_6.txt W2_HISTOGRAMA_1.txt, ..., W2_HISTOGRAMA_6.txt
	Dados de Treinamento	treinamentoRede_HISTOGRAMA.sce
	Classificação	RNA_HISTOGRAMA.sce
MACD	Quantidade de Entrada	MACD.txt
	Amostras	MACD_1.txt, ..., MACD_4.txt
	Classificações	CLASSE_MACD_MUITOALTO.txt, CLASSE_MACD_ALTO.txt, CLASSE_MACD_NEUTRO.txt, CLASSE_MACD_BAIXO.txt, CLASSE_MACD_MUITOBAIXO.txt
	Estrutura RNA	RNA_MACD.txt W_MACD.txt
	Rede Treinada	W1_MACD_1.txt, ..., W1_MACD_13.txt W2_MACD_1.txt, ..., W2_MACD_13.txt

“Tabela 17, continuação

RNA	Conteúdo do arquivo	Nome do arquivo
MACD	Dados de Treinamento	treinamentoRede_MACD.sce
	Classificação	RNA_MACD.sce
Sinal	Quantidade de Entrada	SINAL.txt
	Amostras	SINAL_1.txt, ..., SINAL_10.txt
	Classificações	CLASSE_SINAL_MUITOALTO.txt, CLASSE_SINAL_ALTO.txt, CLASSE_SINAL_NEUTRO.txt, CLASSE_SINAL_BAIXO.txt, CLASSE_SINAL_MUITOBAIXO.txt
	Estrutura RNA	RNA_SINAL.txt
	Rede Treinada	W_SINAL.txt W1_SINAL_1.txt, ..., W1_SINAL_11.txt

	Dados de Treinamento	W2_SINAL_1.txt, ..., W2_SINAL_11.txt
	Classificação	treinamentoRede_SINAL.sce
		RNA_SINAL.sce
OBV	Quantidade de Entrada	OBV.txt
	Amostras	OBV_1.txt
	Classificações	CLASSE_OBV_MUITOALTO.txt, CLASSE_OBV_ALTO.txt,
		CLASSE_OBV_NEUTRO.txt,
		CLASSE_OBV_BAIXO.txt e
		CLASSE_OBV_MUITOBAIXO.txt
Estrutura RNA	RNA_OBV.txt	
Rede Treinada	W_OBV.txt	
	W1_OBV_1.txt, ..., W1_OBV_6.txt	
	W2_OBV_1.txt, ..., W2_OBV_6.txt	
Dados de Treinamento	treinamentoRede_OBV.sce	
Classificação	RNA_OBV.sce	
Volume	Quantidade de Entrada	VOLUME.txt
	Amostras	VOLUME_1.txt, ..., VOLUME_5.txt
	Classificações	CLASSE_VOLUME_MUITOALTO.txt,
		CLASSE_VOLUME_ALTO.txt,
	CLASSE_VOLUME_NEUTRO.txt,	
	CLASSE_VOLUME_BAIXO.txt,	
	CLASSE_VOLUME_MUITOBAIXO.txt	

“Tabela 17, conclusão”

RNA	Conteúdo do arquivo	Nome do arquivo
VOLUME	Estrutura RNA	RNA_VOLUME.txt
	Rede Treinada	W_VOLUME.txt
		W1_VOLUME_1.txt, ..., W1_VOLUME_6.txt W2_VOLUME_1.txt, ..., W2_VOLUME_6.txt
	Dados de Treinamento	treinamentoRede_VOLUME.sce
Classificação	RNA_VOLUME.sce	
Indicador	Quantidade de Entrada	INDICADOR.txt
	Amostras	INDICADOR_1.txt, ... INDICADOR_15.txt

Classificações	CLASSE_INDICADOR_MUITOALTO.txt, CLASSE_INDICADOR_ALTO.txt, CLASSE_INDICADOR_NEUTRO.txt, CLASSE_INDICADOR_BAIXO.txt, CLASSE_INDICADOR_MUITOBAIXO.txt
Estrutura RNA	RNA_INDICADOR.txt
Rede Treinada	W_VOLUME.txt W1_VOLUME_1.txt,..., W1_VOLUME_33.txt W2_VOLUME_1.txt,..., W2_VOLUME_33.txt
Dados de Treinamento	treinamentoRede_INDICADOR.sce
Classificação	RNA_INDICADOR.sce

6.5.2 Cell Invest

O Cell Invest é um software desenvolvido para Web que congrega a implementação da modelagem utilizando RNAs e da modelagem utilizando lógica *fuzzy*. Esse sistema permite utilizar a saída da modelagem utilizando lógica *fuzzy* como entrada da modelagem utilizando RNAs e visa versa, permitindo o uso de ambas as modelagens para simular sistemas híbridos.

Para iniciar esse software, o usuário deve realizar sua autenticação no software por meio da tela de *login* (Figura 62). Essa tela possui uma barra de título contendo *links* (i) com o objetivo do trabalho e (ii) com lista dos autores que redireciona para o currículo *lattes*. O conteúdo dessa tela é um formulário com dois campos (usuário e senha) que, após o usuário se autenticar, tela principal do Cell Invest é apresentada.



Figura 62 Tela de *login*

A tela principal do Cell Invest é apresentada na Figura 63. Esse software possui uma barra de título e o conteúdo da aplicação é dividido em três seções: i) a primeira seção trata da modelagem utilizando lógica *fuzzy*; ii) a segunda seção trata da modelagem utilizando RNAs; e iii) a terceira seção trata da busca e normalização dos dados de entrada.



Figura 63 Tela principal do Cell Invest

A barra de título apresentada na Figura 64 possui: i) *link* com o objetivo do trabalho, ii) *link* para a implementação da modelagem utilizando lógica *fuzzy*, iii) *link* para a implementação da modelagem utilizando RNAs, iv) *link* com lista dos autores que redireciona para o currículo *lattes*; e v) *link* para *logout*.



Figura 64 Barra de título da aplicação *Web*

A seção *Lógica Fuzzy* (Figura 65) possui abas para (i) *Introdução*, (ii) *Sistema Fuzzy*, (iii) *Universo Fuzzy*, (iv) *Gráfico*, (v) *Consulta* e (vi) *Cadastro*. Na primeira aba, a modelagem utilizando lógica *fuzzy* é brevemente descrita. Na segunda aba, um formulário para efetuar cálculos utilizando os sistemas *fuzzy* cadastrados é disponibilizado. Na terceira aba, um formulário para realizar a "fuzzificação" de variáveis linguísticas de um *Universo Fuzzy* é apresentado. Na quarta aba, um gráfico do *Universo Fuzzy* especificado pelo usuário é exibido. Na quinta aba, é possível consultar os dados pertinentes à modelagem *fuzzy* cadastrados na aplicação. Na sexta aba, uma lista de formulários é exibida, a qual possibilita a inclusão de novos elementos *fuzzy* no *Cell Invest*.

O formulário para efetuar cálculos nos sistemas *fuzzy* é apresentado na Figura 65. No campo *Nome*, deve-se inserir o identificador (nome) do sistema *fuzzy* que se deseja efetuar o cálculo, por exemplo, *Sistema Fuzzy Indicador*. No campo *Entrada*, os dados de entrada do sistema *fuzzy* devem ser inseridos. Por exemplo, considerando o contexto de tomada de decisão em mercado de capitais, é necessário fornecer os seguintes dados de entrada: i) *IFR*; ii) *Oscilador Estocástico*; iii) valor normalizado da linha *MACD*; iv) diferença entre os valores da linha *MACD* e a linha de sinal *MACD*; v) ângulo da regressão linear dos três últimos valores da linha *MACD*; vi) diferença entre o ângulo da linha *MACD* e o ângulo da linha de sinal *MACD*; vii) valor normalizado do *Histograma MACD*; viii) ângulo da regressão linear dos três últimos valores do *Histograma MACD*; e ix) ângulo da regressão linear dos três últimos valores do indicador *OBV*.

Figura 65 Formulário para efetuar cálculos no sistema *fuzzy*

Nesse exemplo, são utilizados, os seguintes valores: 54,23; 53,04; 0,89; -0,53; -0,46; -0,13; 0,57; -0,43 e -0,37, respectivamente. No campo Conjunto *Fuzzy* de Saída, é exibido o conjunto *fuzzy* de saída do sistema *fuzzy*, no contexto mencionado, tem-se as saídas: i) Muito Baixo igual 0; ii) Baixo igual 0,86; iii) Neutro igual a zero; iv) Alto igual a zero; e v) Muito Alto igual a zero. No campo Defuzzyficação, a "defuzzyficação" do conjunto *fuzzy* de saída é exibida, no contexto mencionado, a "defuzzyficação" é igual a 35.

O formulário para "fuzzificar" uma variável linguística é apresentado na Figura 66. O identificador (nome) do Universo *fuzzy* que se deseja efetuar a "fuzzificação" deve ser inserido no campo Nome, por exemplo, Universo *Fuzzy* IFR. O valor que se deseja "fuzzificar" deve ser inserido no campo Entrada, neste exemplo, o valor 76 foi utilizado. O conjunto *fuzzy* de saída é exibido no campo Conjunto *Fuzzy* de Saída. Neste caso, tem-se a saída: i) Muito Baixo igual a 0,2; ii) Baixo igual a 0,8; iii) Neutro igual a zero; iv) Alto igual a zero; e v) Muito Alto igual a zero.

Fuzzy Logic - RNA Objetivo Lógica Fuzzy RNA Autores Logout

Lógica Fuzzy

Introdução Sistema Fuzzy **Uníversono Fuzzy** Gráfico Consulta Cadastro

Nome:
 Digite o nome do universo fuzzy

Entrada:
 Exemplo de entrada: 5.0

Conjunto Fuzzy de Saída:

Figura 66 Formulário para "fuzzificar" uma variável linguística

A visualização do gráfico do Universo *Fuzzy* do indicador IFR é apresentada na Figura 67. Na aba Gráfico, é possível visualizar os conjuntos *fuzzy* contidos no Universo *Fuzzy*, sendo ilustrado com diferentes cores para facilitar a interpretação do gráfico.

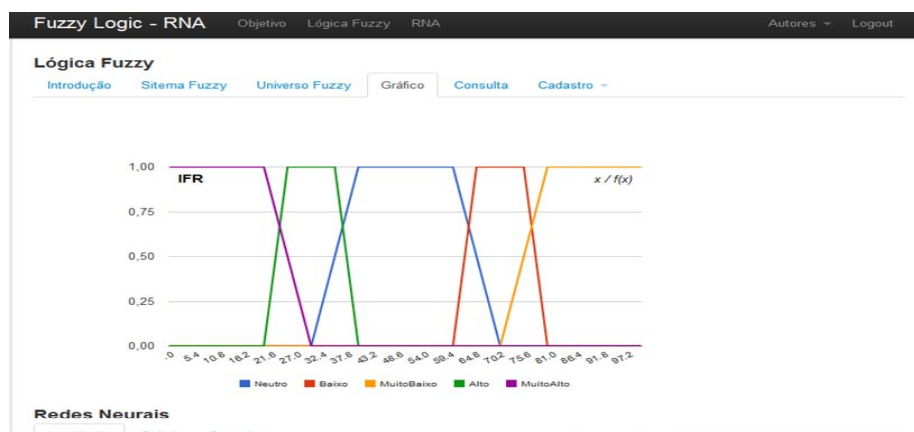


Figura 67 Visualização gráfica do universo *fuzzy* IFR

Uma visualização dos dados cadastrados de um Universo *Fuzzy* é apresentado na Figura 68. Nessa aba, é possível consultar os dados de cada elemento *fuzzy* cadastrado no software. Os dados são exibidos seguindo as definições da modelagem apresentada na Figura 44. O formulário para o cadastro de um novo Sistema *Fuzzy* é apresentado na Figura 69. O Sistema *Fuzzy* a ser cadastrado no formato JSON⁷ deve ser inserido no campo Sistema *Fuzzy*. Na aba Cadastro, também se pode realizar inserções de funções, conjuntos *fuzzy*, Universos *Fuzzy* e Máquinas de Inferência.

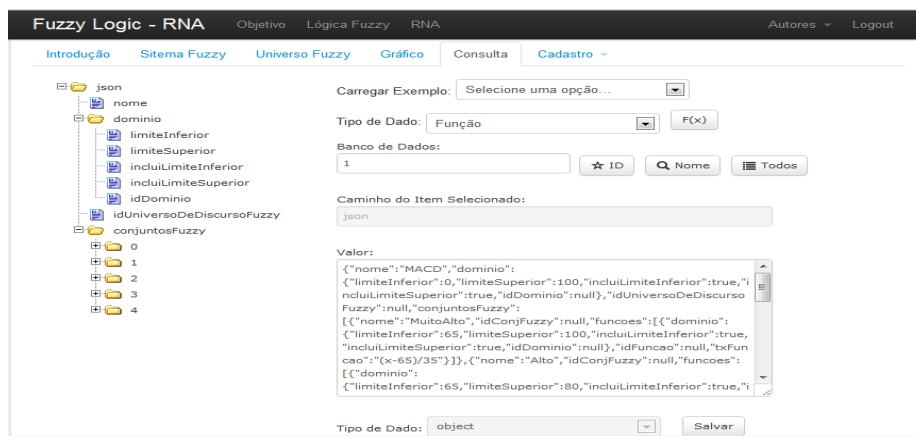


Figura 68 Consulta dos dados cadastrados de um determinado universo *fuzzy*

⁷ JSON, um acrônimo para "*JavaScript Object Notation*", é um formato leve para intercâmbio de dados computacionais. JSON é um subconjunto da notação de objeto de JavaScript, mas seu uso não requer Javascript exclusivamente.

Figura 69 Formulário para cadastro sistema *fuzzy*

A seção Redes Neurais do software Web possui três abas: i) Introdução; ii) Scilab; e iii) Consulta. Na primeira aba, definição breve do que é uma RNA. Na segunda aba, um formulário para efetuar cálculos utilizando o ambiente Scilab é disponibilizado. Na terceira aba, a estrutura de diretórios de cada RNA treinada é apresentada.

O formulário para efetuar cálculos no ambiente Scilab é apresentado na Figura 70. Com esse formulário, pode-se visualizar o conteúdo dos arquivos treinados pelo Scilab e editá-los, caso seja necessário. A visualização da estrutura de diretórios das RNAs utilizada no ambiente Scilab é apresentada na Figura 71. Na aba Consulta, pode-se ver cada RNA treinada e retreinar uma RNA, caso seja necessário.

Figura 70 Formulário para efetuar cálculos no ambiente Scilab

Figura 71 Visualização da estrutura de diretório das RNAs

A terceira seção da aplicação web trata da busca e normalização dos dados. Esta seção possui quatro abas: i) Introdução; ii) Dados de Entrada; iii) Indicadores; e iv) Gráficos. Na primeira aba, análise técnica é brevemente descrita. Na segunda aba, os dados normalizados dos indicadores técnicos são apresentados. Na terceira aba, é possível visualizar os gráficos de cada indicador técnico.

O conteúdo da aba Dados de Entrada é apresentado na Figura 72. Os dados normalizados de cada indicador técnico são apresentados no campo

Lógica *Fuzzy* / Redes Neurais. Abaixo deste campo, pode-se visualizar a definição de cada normalização. O conteúdo da aba Indicadores é apresentado na Figura 73. Nessa aba, uma tabela com dados dos últimos setes dias é exibida. Os dados exibidos na tabela são os valores reais de cada indicador.

Fuzzy Logic - RNA Objetivo Lógica Fuzzy RNA Autores Logout

Tipo de Dado: string Salvar

Análise Técnica
BBAS3

Introdução **Dados de Entrada** Indicadores Gráficos

Lógica Fuzzy / Redes Neurais
55.9354, 71.6392, 1, 0, 179177558569667, 0.2837467596025485, 0.09324236172449762, 0.15191428326499712, 0.20361687150190566, 0.04733485393977718

Índice de Força Relativa [0, 100]

IFR, EST, linhamacd, difmacd, alphamacd, difalphamacd, hist, alphahist, alphaobv
Os valores IFR e Estocástico devem ser normalizados entre 0 e 1, caso utilize as redes neurais

< > 1 9 < > Lógica Fuzzy Redes Neurais

Outros Valores
0.559354, 0.716392, 1, 0.9612136660883491, 0.2837467596025485, 0.1905043978780509, 0.15191428326499712, 0.20361687150190566, 0.04733485393977718

IFR, EST, linhamacd, linhasinal, alphalinhamacd, alphalinhasinal, hist, alphahist, alphaobv

!8080/FuzzyLogic/index.html# © Copyright 2011 - @igornbeiolima

Figura 72 Conteúdo da aba Dados de Entrada

Fuzzy Logic - RNA Objetivo Lógica Fuzzy RNA Autores Logout

Análise Técnica
BBAS3

Introdução **Dados de Entrada** **Indicadores** Gráficos

Data	R\$	IFR	Est	MLine	MSinal	Hist	OBV
13/02/12	26.2444	53.9843	26.3487	587.1	745.081	-157.981	15440372849
14/02/12	27.3185	58.0764	99.289	605.3	717.1248	-111.8248	15451084649
15/02/12	27.8455	57.4781	100	654.7	704.6398	-49.9398	15466264649
16/02/12	28.6014	59.3007	100	746.3	712.9718	33.3282	15477444649
17/02/12	27.8455	55.9354	71.6392	749.3	720.2374	29.0626	15469776849

© Copyright 2011 - @igornbeiolima

Figura 73 Conteúdo da aba Indicadores

A lista para a visualização gráfica dos indicadores técnicos é apresentada na Figura 74. Essa lista é exibida ao selecionar a aba Gráficos e, ao selecionar um elemento da lista, o gráfico do indicador selecionado é exibido.




Figura 74 Lista para a visualização gráfica dos indicadores técnicos

6.6 Análise dos resultados

Nesta seção, um passo a passo da tomada de decisão para o ativo financeiro BBAS3 (Banco do Brasil) em 17 de fevereiro de 2012 é apresentado como exemplo para a modelagem utilizando lógica *fuzzy* e para a modelagem utilizando RNAs. Este ativo financeiro foi escolhido aleatoriamente dentre 70 ativos financeiros contidos no Índice iBovespa na data corrente, sendo o dia escolhido a data de realização da análise.

O gráfico do indicador IFR do ativo financeiro BBAS3 é apresentado na Figura 75. Esse indicador encontra-se em uma zona de neutralidade, pois seu valor é inferior a 70 e superior a 30. O gráfico do indicador Oscilador

Estocástico do ativo financeiro BBAS3 é apresentado na Figura 76. Esse indicador encontra-se em uma zona de neutralidade, pois seu valor é inferior a 80 e superior a 20.




Figura 75 Gráfico do indicador IFR do ativo financeiro BBAS3

O gráfico do indicador MACD do ativo financeiro BBAS3 é apresentado na Figura 77. Visualmente, este gráfico indica tendência de alta, pois a linha MACD está acima do eixo zero e está em ascensão, enquanto que a linha de sinal MACD encontra-se abaixo da linha MACD e em declínio.



Figura 76 Gráfico do indicador oscilador estocástico do ativo financeiro BBAS3




Figura 77 Gráfico do indicador MACD do ativo financeiro BBAS3

O gráfico do indicador Histograma MACD do ativo financeiro BBAS3 é apresentado na Figura 78. Visualmente, esse gráfico indica que as linhas do indicador MACD estão se distanciando, mantendo-se aproximadamente a mesma distância no dia 17/02/2012. Nota-se que esse indicador está próximo do eixo zero, o que indica o cruzamento entre as linhas.




Figura 78 Gráfico do indicador histograma MACD do ativo financeiro BBAS3

O gráfico do indicador OBV do ativo financeiro BBAS3 é apresentado na Figura 79. Nota-se que esse indicador teve ascensão expressiva nos últimos dias, porém no último dia houve volume negativo significativo.

Os resultados obtidos em cada passo com a modelagem utilizando lógica *fuzzy* são discutidos na Seção 6.6.1. Os resultados obtidos em cada passo com a modelagem utilizando RNAs são discutidos na Seção 6.6.2. A sequência de passos apresentada foi aplicada em 70 ativos durante o período de 19/12/2008 a 10/02/2012, totalizando análise com 54.081 dados. A lista dos ativos financeiros analisados é apresentada na Tabela 18. No fim de cada seção, há uma estatística com a análise obtida com os 70 ativos.




Figura 79 Gráfico do indicador OBV do ativo financeiro BBAS3

6.6.1 Resultados obtidos com o sistema modelado utilizando lógica *fuzzy*

Nesta seção, é analisado passo a passo cada gráfico da Seção 6.6 com a modelagem utilizando a lógica *fuzzy*. Os dados de entrada são apresentados na Tabela 19. Os valores são resultantes da utilização das equações apresentadas na Seção 6.4.

O resultado da análise do indicador IFR do exemplo dado é apresentado na Figura 80. De acordo com a análise *fuzzy*, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 100% Neutro, 0% Alto e 0% Muito Alto. Conforme a análise visual da Figura 75 feita na Seção 6.6, este resultado condiz

com a interpretação visual. O resultado da análise do indicador Oscilador Estocástico do exemplo dado é apresentado na Figura 81. De acordo com a análise *fuzzy*, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 100% Neutro, 0% Alto e 0% Muito Alto. Conforme a análise visual da Figura 76 feita na Seção 6.6 este resultado condiz com a interpretação visual.

O resultado da análise da Máquina de Inferência Momento, utilizando os conjuntos *fuzzy* de saída IFR e Oscilador Estocástico, é apresentado na Figura 82. De acordo com a análise *fuzzy*, tem-se que a variável Momento é 0% Muito Baixo, 0% Baixo, 100% Neutro, 0% Alto e 0% Muito Alto. O resultado da análise do indicador MACD do exemplo dado é apresentado na Figura 83. De acordo com a análise *fuzzy*, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 0% Neutro, 0% Alto e 62% Muito Alto. Conforme a análise visual da Figura 77 feita na Seção 6.6, este resultado condiz com a interpretação visual.

Tabela 18 Ativos utilizados na análise dos resultados

Nº	Ativo	Razão Social	Quantidade de dados	Período Inicial
1	ALL3	All America Latina Logística S.A.	780	19/12/2008
2	AMBV4	Cia. Bebidas das Américas - AMBEV	780	19/12/2008
3	BBAS3	Bco Brasil S.A.	780	19/12/2008
4	BBDC4	Bco Bradesco S.A.	780	19/12/2008
5	BISA3	Brookfield Incorporações S.A.	780	19/12/2008
6	BRAP4	Bradespar S.A.	780	19/12/2008
7	BRFS3	BRF - Brasil Foods S.A.	780	19/12/2008
8	BRKM5	Braskem S.A.	780	19/12/2008
9	BRML3	BR Malls Participações S.A.	780	19/12/2008
10	BRT04	Brasil Telecom S.A.	780	19/12/2008
11	BTOW3	B2W - Companhia Global do Varejo	780	19/12/2008
12	BVMF3	BMFBovespa S.A. Bolsa Valores Merc Fut	780	19/12/2008
13	CCRO3	CCR S.A.	780	19/12/2008
14	CESP6	CESP - Cia Energética de São Paulo	780	19/12/2008
15	CIEL3	Cielo S.A.	654	26/06/2009
16	CMIG4	Cia. Energética de Minas Gerais - CEMIG	780	19/12/2008
17	CPFE3	CPFL Energia S.A.	780	19/12/2008
18	CPLE6	Cia. Paranaense de Energia - COPEL	780	19/12/2008
19	CRUZ3	Souza Cruz S.A.	780	19/12/2008
20	CSAN3	COSAN S.A. Industrial e Comércio	780	19/12/2008
21	CSNA3	Cia Siderúrgica Nacional	780	19/12/2008
22	CYRE3	Cyrela Brazil Realty S.A. Empreend e Part	780	19/12/2008
23	DASA3	Diagnósticos da America S.A.	780	19/12/2008
24	DTEX3	Duratex S.A.	583	07/10/2009
25	ELET3	Centrais Elet Bras S.A. - Eletrobras	780	19/12/2008
26	ELET6	Centrais Elet Bras S.A. - Eletrobras	780	19/12/2008
27	ELPL4	Eletropaulo Metrop. Elet. São Paulo S.A.	780	19/12/2008
28	EMBR3	Embraer S.A.	780	19/12/2008
29	FIBR3	Fibria Celulose S.A.	780	19/12/2008
30	GFGA3	Gafisa S.A.	780	19/12/2008
31	GGBR4	Gerdau S.A.	780	19/12/2008
32	GOAU4	Metalúrgica Gerdau S.A.	780	19/12/2008
33	GOLL4	Gol Linhas Aéreas Inteligentes S.A.	780	19/12/2008
34	HGTX3	Cia. Hering	780	19/12/2008
35	HYPE3	Hypermarcas S.A.	780	19/12/2008
36	ITSA4	Itaúsa Investimentos Itaú S.A.	780	19/12/2008
37	ITUB4	Itaú Unibanco Holding S.A.	780	19/12/2008
38	JBSS3	JBS S.A.	780	19/12/2008
39	KLBN4	Klabin S.A.	780	19/12/2008
40	LAME4	Lojas Americanas S.A.	780	19/12/2008
41	LIGT3	Light S.A.	780	19/12/2008
42	LLXL3	LLX Logística S.A.	780	19/12/2008
43	LREN3	Lojas Renner S.A.	780	19/12/2008
44	MMXM3	MMX Mineração e Metálicos S.A.	780	19/12/2008
45	MRFG3	Marfrig Alimentos S/A	780	19/12/2008
46	MRVE3	MRV Engenharia e Participações S.A.	780	19/12/2008
47	NATU3	Natura Cosméticos S.A.	780	19/12/2008
48	OGXP3	OGX Petróleo e Gas Participações S.A.	780	19/12/2008
49	PCAR4	Cia Brasileira de Distribuição	780	19/12/2008
50	PDGR3	PDG Realty S.A. Empreend e Participações	780	19/12/2008
51	PETR3	Petróleo Brasileiro S.A. Petrobras	780	19/12/2008
52	PETR4	Petróleo Brasileiro S.A. Petrobras	780	19/12/2008

53 RDCD3 Redecard S.A. 780 19/12/2008
 “Tabela 18, conclusão”

Nº	Ativo	Razão Social	Quantidade de dados	Período Inicial
54	RENT3	Localiza Rent a Car S.A.	780	19/12/2008
55	RSID3	Rossi Residencial S.A.	780	19/12/2008
56	SANB11	Bco Santander (Brasil) S.A.	584	06/10/2009
57	SBSP3	Cia. Saneamento Básico Est São Paulo	780	19/12/2008
58	TAMM4	TAM S.A.	780	19/12/2008
59	TIMP3	TIM Participações S.A.	780	19/12/2008
60	TMAR5	Telemar Norte Leste S.A.	780	19/12/2008
61	TNLP3	Tele Norte Leste Participações S.A.	780	19/12/2008
62	TNLP4	Tele Norte Leste Participações S.A.	780	19/12/2008
63	TRPL4	CTEEP - Cia Transmissão Energia Elétrica Paulista	780	19/12/2008
64	UGPA3	Ultrapar Participações S.A.	780	19/12/2008
65	USIM3	Usinas Sid de Minas Gerais S.A. - USIMINAS	780	19/12/2008
66	USIM5	Usinas Sid de Minas Gerais S.A. - USIMINAS	780	19/12/2008
67	VAGR3	Vanguarda Agro S.A.	780	19/12/2008
68	VALE3	Vale S.A.	780	19/12/2008
69	VALE5	Vale S.A.	780	19/12/2008
70	VIVT4	Telefônica Brasil S.A.	780	19/12/2008

Tabela 19 Dados de entrada de exemplo para a modelagem utilizando lógica *fuzzy*

Entrada	Valores
IFR	55,935400
Oscilador Estocástico	71,639200
Distância da linha MACD ao eixo zero	1,000000
Diferença entre a linha MACD e a linha de Sinal MACD	0,179178
Ângulo da linha MACD	0,283747
Diferença entre os ângulos da linha MACD e a linha de Sinal MACD	0,093242
Distância do indicador histograma MACD ao eixo zero	0,151914
Ângulo do indicador histograma MACD	0,203617
Ângulo do indicador OBV	0,047335




Figura 80 Resultado do exemplo do conjunto *fuzzy* IFR




Figura 81 Resultado do exemplo do conjunto *fuzzy* oscilador estocástico




Figura 82 Resultado do exemplo da máquina de inferência momento

O resultado da análise do indicador Histograma MACD do exemplo dado é apresentado na Figura 82. De acordo com a análise *fuzzy*, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 0% Neutro, 93% Alto e 48% Muito Alto. Conforme a análise visual da Figura 78 feita na Seção 6.6, este resultado condiz com a interpretação visual.




Figura 83 Resultado do exemplo do conjunto *fuzzy* MACD




Figura 84 Resultado do exemplo do conjunto *fuzzy* Histograma MACD

O resultado da análise da Máquina de Inferência Sinal, utilizando os conjuntos *fuzzy* de saída MACD e Histograma MACD, é apresentado na Figura 85. De acordo com a análise *fuzzy*, tem-se que a variável Sinal é 0% Muito Baixo, 0% Baixo, 0% Neutro, 0% Alto e 62% Muito Alto.




Figura 85 Resultado do exemplo da máquina de inferência sinal

O resultado da análise do indicador OBV do exemplo dado é apresentado na Figura 86. De acordo com a análise *fuzzy*, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 75% Neutro, 0% Alto e 0% Muito Alto. Conforme a análise visual da Figura 79 feita na Seção 6.6, este resultado condiz com a interpretação visual.

O resultado da análise da Máquina de Inferência Volume, utilizando os conjuntos *fuzzy* de saída OBV, é apresentado na Figura 87. De acordo com a análise *fuzzy*, tem-se que a variável Volume é 0% Muito Baixo, 0% Baixo, 75% Neutro, 0% Alto e 0% Muito Alto.




Figura 86 Resultado do exemplo do conjunto *fuzzy* OBV




Figura 87 Resultado do exemplo da máquina de inferência volume

O resultado da análise da Máquina de Inferência C&V, utilizando as saídas das variáveis das Máquinas de Inferências Momento, Sinal e Volume (segunda etapa), é apresentado na Figura 88. De acordo com a análise *fuzzy*, tem-se que o indicador C&V é 0% Muito Baixo, 0% Baixo, 75% Neutro, 0% Alto e 0% Muito Alto.




Figura 88 Resultado do exemplo da máquina de inferência C&V

O passo a passo foi feito com os 70 ativos financeiros selecionados. O resultado obtido foi separado em três grupos: i) oscilação igual ou maior a zero; ii) oscilação igual ou maior a 0,5%; e iii) oscilação igual ou maior a 1%. Caso o resultado sugira uma ordem de compra, a previsão é a ocorrência de oscilação

positiva no dia seguinte. Por outro lado, caso o resultado sugira uma ordem de venda, a previsão é a ocorrência de oscilação negativa no dia seguinte.

A estatística obtida com a análise dos 70 ativos financeiros é apresentada na Figura 89. Esta estatística mostra que, ao ter um sinal de compra/venda, houve probabilidade de alta/queda de 92% no dia seguinte. As variações maiores que 0,5% e 1% tiveram probabilidade de acerto de 84% e de 75%, respectivamente.




Figura 89 Estatística obtida com a modelagem utilizando lógica *fuzzy*

6.6.2 Resultados obtidos com o sistema modelado utilizando RNAs

Nesta seção, é analisado passo a passo cada gráfico da Seção 6.6 com a modelagem utilizando RNAs. Os dados de entrada do exemplo são apresentados na Tabela 20. Os valores são resultantes da utilização das equações apresentadas na Seção 6.4.

O resultado da análise do indicador IFR do exemplo dado é apresentado na Figura 90. De acordo com a análise RNA, tem-se que esse indicador é 0% Muito Baixo, 4% Baixo, 97% Neutro, 5% Alto e 0% Muito Alto. Conforme a análise visual da Figura 75 feita na Seção 6.6, este resultado condiz com a interpretação visual.

Tabela 20 Dados de entrada de exemplo para a modelagem utilizando RNAs

Entrada	Valores
IFR	0,559354
Oscilador Estocástico	0,716392
Distância da linha MACD ao eixo zero	1,000000
Diferença entre a linha MACD e a linha de Sinal MACD	0,544795
Ângulo da linha MACD	0,590365
Diferença entre os ângulos da linha MACD e a linha de Sinal MACD	0,514847
Distância do indicador histograma MACD ao eixo zero	0,151914
Ângulo do indicador histograma MACD	0,564846
Ângulo do indicador OBV	0,515075




Figura 90 Resultado do exemplo da camada de saída da RNA do indicador IFR

O resultado da análise do indicador Oscilador Estocástico do exemplo dado é apresentado na Figura 91. De acordo com a análise RNA, tem-se que esse indicador é 1% Muito Baixo, 6% Baixo, 84% Neutro, 3% Alto e 0% Muito Alto. Conforme a análise visual da Figura 76 feita na Seção 6.6, este resultado condiz com a interpretação visual.




Figura 91 Resultado do exemplo da camada de saída da RNA do indicador oscilador estocástico

O resultado da análise da camada de saída da RNA Momento, utilizando as saídas das RNAs IFR e Oscilador Estocástico, é apresentado na Figura 92. De acordo com a análise RNA, tem-se que a variável Momento é 0% Muito Baixo, 2% Baixo, 93% Neutro, 2% Alto e 0% Muito Alto.




Figura 92 Resultado do exemplo da camada de saída da RNA da variável momento

O resultado da análise do indicador MACD do exemplo dado é apresentado na Figura 93. De acordo com a análise RNA, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 28% Neutro, 24% Alto e 6% Muito Alto. Conforme a análise visual da Figura 77 feita na Seção 6.6, este resultado condiz com a interpretação visual.

O resultado da análise do indicador Histograma MACD do exemplo dado é apresentado na Figura 94. De acordo com a análise RNA, tem-se que esse indicador é 0% Muito Baixo, 0% Baixo, 15% Neutro, 51% Alto e 14% Muito Alto. Conforme a análise visual da Figura 78 feita na Seção 6.6 este resultado condiz com a interpretação visual.




Figura 93 Resultado do exemplo da camada de saída da RNA do indicador MACD




Figura 94 Resultado do exemplo da camada de saída da RNA do indicador histograma MACD

O resultado da análise da camada de saída da RNA Sinal, utilizando as saídas das RNAs MACD e Histograma MACD, é apresentado na Figura 95. De acordo com a análise *fuzzy*, tem-se que a variável Sinal é 0% Muito Baixo, 0% Baixo, 0% Neutro, 24% Alto e 0% Muito Alto.




Figura 95 Resultado do exemplo da camada de saída da RNA da variável sinal

O resultado da análise do indicador OBV do exemplo dado é apresentado na Figura 96. De acordo com a análise RNA, tem-se que esse indicador é 1% Muito Baixo, 22% Baixo, 16% Neutro, 31% Alto e 2% Muito Alto. Conforme a análise visual da Figura 79 feita na Seção 6.6, este resultado condiz com a interpretação visual.

O resultado da análise da camada de saída da RNA Volume, utilizando as saídas da RNA OBV, é apresentado na Figura 97. De acordo com a análise RNA, tem-se que a variável Volume é 0% Muito Baixo, 0% Baixo, 33% Neutro, 3% Alto e 0% Muito Alto.




Figura 96 Resultado do exemplo da camada de saída da RNA do indicador OBV




Figura 97 Resultado do exemplo da camada de saída da RNA da variável volume

O resultado da análise da camada de saída da RNA do indicador C&V, utilizando as saídas das RNAs das variáveis Momento, Sinal e Volume (segunda etapa), é apresentado na Figura 98. De acordo com a análise RNA, tem-se que o indicador C&V é 0% Muito Baixo, 0% Baixo, 28% Neutro, 2% Alto e 0% Muito Alto.




Figura 98 Resultado do exemplo da camada de saída da RNA indicador C&V

O passo a passo foi feito com os 70 ativos financeiros selecionados. O resultado obtido foi separado em três grupos: i) oscilação igual ou maior a zero; ii) oscilação igual ou maior a 0,5%; e iii) oscilação igual ou maior a 1%. Caso o resultado sugira uma ordem de compra, a previsão é a ocorrência de oscilação

positiva no dia seguinte. Por outro lado, caso o resultado sugira uma ordem de venda, a previsão é a ocorrência de oscilação negativa no dia seguinte.

A estatística obtida com a análise dos 70 ativos financeiro é apresentada na Figura 99. Esta estatística mostra que o sistema utilizando RNA ao indicar um sinal de compra/venda teve uma probabilidade de alta/queda de 95% no dia seguinte. As variações maiores que 0,5% e 1% tiveram probabilidade de acerto de 92% e de 89%, respectivamente.




Figura 99 Estatística obtida com a modelagem utilizando RNA

6.6.3 Resultados obtidos com os sistemas híbridos

O passo a passo para analisar os resultados das modelagens utilizando lógica *fuzzy* e RNA foi usado para obter os resultados de cada sistema híbrido. Os dados de entrada para os sistemas *Fuzzy-RNA-RNA*, *Fuzzy-RNA-Fuzzy* e *Fuzzy-Fuzzy-RNA* foram os mesmos utilizados na Seção 6.6. Enquanto os dados de entrada para os sistemas *RNA-Fuzzy-Fuzzy*, *RNA-Fuzzy-RNA* e *RNA-RNA-Fuzzy* foram os mesmos utilizados na Seção 6.6.2.

O passo a passo foi feito com os 70 ativos financeiros selecionados. O resultado obtido foi separado em três grupos: i) oscilação igual ou maior a zero; ii) oscilação igual ou maior a 0,5%; e iii) oscilação igual ou maior a 1%. Caso o resultado sugira uma ordem de compra, a previsão é a ocorrência de oscilação

positiva no dia seguinte. Por outro lado, caso o resultado sugira uma ordem de venda, a previsão é a ocorrência de oscilação negativa no dia seguinte.

A estatística obtida com a análise dos 70 ativos financeiros para cada sistema híbrida é apresentada na Figura 100. Esta estatística mostra que o sistema híbrido *Fuzzy-RNA-RNA* obteve os melhores resultados. Esta modelagem híbrida ao indicar um sinal de compra/venda teve uma probabilidade de alta/queda de 94% no dia seguinte. As variações maiores que 0,5% e 1% tiveram uma probabilidade de acerto de 92% e de 89%, respectivamente.

6.7 Considerações finais

A análise feita separadamente de cada indicador mostra que as modelagens interpretaram os gráficos conforme está descrito na literatura. Os indicadores IFR, Oscilador Estocástico, MACD, Histograma MACD e OBV, quando analisados separadamente, não mostraram diferença significativa entre as modelagens propostas. Diferenças significativas entre as modelagens ocorrem na saída das variáveis Momento, Sinal, Volume e Indicador C&V.

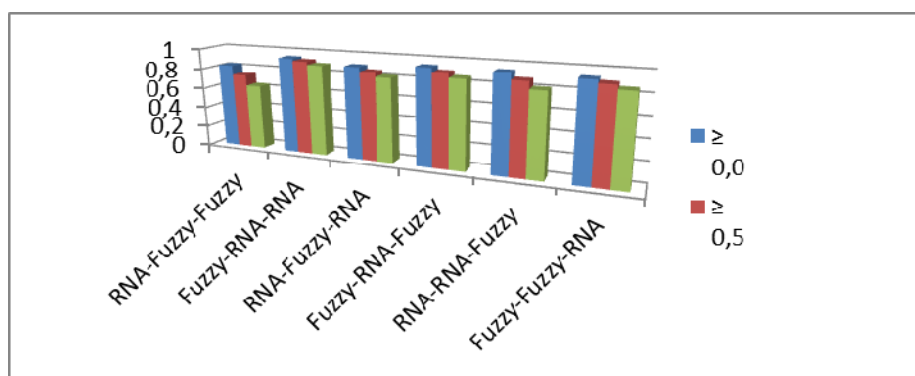


Figura 100 Estatística obtida com as modelagens híbridas

Vale ressaltar que as regras que define cada combinação entre os indicadores são ajustáveis. Isso implica que cada investidor pode ajustar sua regra, com base na sua credibilidade em um indicador técnico, podendo ter resultados melhores ou inferiores às regras definidas neste trabalho.

Uma síntese dos resultados obtidos é apresentada na Tabela 21. De acordo com os resultados, a modelagem RNA apresentou maior índice de acertos.

Tabela 21 Síntese dos resultados entre as modelagens

Modelagem	≥ 0,0	≥ 0,5	≥ 1,0
Lógica <i>Fuzzy</i>	0,92	0,84	0,75
Redes Neurais Artificiais	0,95	0,92	0,89
Proposta 1 - Modelagem RNA- <i>Fuzzy-Fuzzy</i>	0,83	0,74	0,64
Proposta 2 - Modelagem <i>Fuzzy</i> -RNA-RNA	0,94	0,92	0,89
Proposta 3 - Modelagem RNA- <i>Fuzzy</i> -RNA	0,90	0,86	0,82
Proposta 4 - Modelagem <i>Fuzzy</i> -RNA- <i>Fuzzy</i>	0,94	0,90	0,86
Proposta 5 - Modelagem RNA-RNA- <i>Fuzzy</i>	0,94	0,88	0,81
Proposta 6 - Modelagem <i>Fuzzy-Fuzzy</i> -RNA	0,93	0,90	0,86

7 CONSIDERAÇÕES FINAIS

Inicialmente, foi feita uma contextualização teórica sobre duas técnicas de inteligência computacional (RNA e lógica *fuzzy*) e previsão do mercado financeiro, o que permitiu o embasamento conceitual para o desenvolvimento deste trabalho. Com esta contextualização, foram desenvolvidas modelagens utilizando essas técnicas para a tomada de decisão no mercado de capitais, possibilitando ao investidor maior ganho em liquidez nas negociações. Esta contextualização teórica se mostrou muito importante ao longo do projeto por garantir que os conceitos utilizados possam ser evoluídos de modo consistente em trabalhos futuros.

Este capítulo está organizado da seguinte forma. Conclusões são apresentadas na Seção 7.1. Contribuições são mostradas na Seção 7.2. Limitações são discutidas na Seção 7.3. Trabalhos futuros são sugeridos na Seção 7.4.

7.1 Conclusões

Neste trabalho, buscou-se modelar e desenvolver um sistema de tomada de decisão para o mercado financeiro, utilizando lógica *fuzzy* e RNA; tendo como dados de entrada cinco indicadores técnicos. Os resultados das modelagens mostraram que o sistema de decisão baseado em RNA e lógica *fuzzy* foi capaz de propor sugestões razoáveis de compra e de venda.

Na modelagem utilizando RNAs, obtiveram-se melhores resultados em comparação às demais modelagens. A modelagem híbrida RNA-RNA-RNA obteve a melhor previsão, enquanto que a modelagem híbrida RNA-*Fuzzy-Fuzzy* teve a pior decisão. O que traz indícios que a modelagem utilizando lógica *fuzzy*

necessita reajustes nos conjuntos *fuzzy*. A utilização dessas técnicas computacionais encoraja a tomada de decisão, porém deve-se buscar continuamente a aprimoramento da precisão do movimento do mercado financeiro.

A análise dos resultados foi baseada em 70 ativos durante o período de 19/12/2008 a 10/02/2012. Na análise realizada, não foi considerado a questão do humor, por exemplo, a influência de notícias e rumores que acontece no mercado. No entanto, o resultado da análise realizado ofereceu previsão razoável.

Com a avaliação dos resultados, pôde-se comprovar que o objetivo de mostrar a importância da qualidade de uma modelagem utilizando lógica *fuzzy* e de uma modelagem utilizando RNAs foi alcançado. Além disso, pôde-se mostrar que a metodologia aplicada é adequada para a criação de modelos de tomada de decisão e o trabalho conseguiu cumprir outro objetivo específico: um estudo comparativo de desempenho entre diferentes técnicas de inteligência computacional.

7.2 Contribuições

Este trabalho contribui para o desenvolvimento de modelagens utilizando duas técnicas de inteligência computacional: lógica *fuzzy* e RNAs para prever o movimento do mercado financeiro. Do ponto de vista operacional, este trabalho sinaliza direções para o desenvolvimento de aplicações de tomada de decisões para o mercado financeiro utilizando diferentes técnicas de inteligência computacional e diferentes indicadores, dentre eles fundamentalista, financeiro e técnico. Considera-se que este trabalho pôde contribuir para mostrar a viabilidade da aplicação de técnicas de inteligência computacional na previsão de preços futuros.

O presente trabalho traz como contribuição acadêmica a elaboração de uma análise que, conduzido com o rigor do método científico, obteve dados que mostraram a aplicabilidade da lógica *fuzzy* e da RNA na tomada de decisão. A combinação de técnicas de inteligência computacional (lógica *fuzzy* e RNA) é de suma importância como trabalho científico, pois permite vislumbrar novas possibilidades de desenvolvimento e refinamento de modelos utilizando técnicas de inteligência computacional.

7.3 Limitações

As principais limitações deste trabalho são decorrentes da utilização de apenas indicadores técnicos e por propor modelagens de tomada de decisão de curtíssimo prazo (a previsão do dia corrente somente é válida para o dia seguinte). Além disso, há outras limitações, tais como, (i) não foram analisados diferentes algoritmos de treinamento e diversas configurações possíveis para uma RNA, (ii) a utilização dos setes minutos iniciais do pregão eletrônico, os quais podem ser complicadores de uma previsão por sofrer oscilações bruscas e (iii) o critério da escolha do especialista *fuzzy*, o qual foi considerado o conhecimento de um único especialista.

Porém, a análise mais detalhada das possíveis configurações e algoritmos de treinamento estão fora do escopo deste trabalho. Outras técnicas de inteligência computacional relacionadas aos temas de estudo foram encontradas, porém foram excluídas da pesquisa: um caso de particular importância é a técnica que utiliza algoritmo genético.

7.4 Trabalhos Futuros

Durante o desenvolvimento deste trabalho e após sua conclusão, foram identificadas várias possibilidades de ampliação da proposta inicial. Alguns pontos poderiam ser modificados e/ou estendidos, o que proporcionaria melhor desempenho ao conjunto de técnicas propostas para a modelagem utilizando lógica *fuzzy* e RNA.

Contudo, a fim de garantir o atendimento dos objetivos inicialmente propostos, alguns indicadores técnicos não foram utilizados. Acredita-se que outros trabalhos poderão ser desenvolvidos em continuidade a este, no intuito de promover melhorias nas modelagens utilizadas, as quais podem ser aperfeiçoadas, por exemplo:

- a) outras RNAs podem ser utilizadas;
- b) outras máquinas de inferências podem ser utilizadas;
- c) implantação das técnicas propostas em ambiente real de negociação;
- d) sistema especialista mais abrangente com mais indicadores técnicos nos dados de entrada. Por exemplo, Bollinger Band, TRIX, SAR Parabolic e Swing Gann;
- e) acréscimo de indicadores fundamentalista, tais como, VPA (Valor Patrimonial da Ação), P/L (Relação Preço/Lucro) e DY (*Dividend Yield*), de indicadores financeiros, por exemplo, Taxa SELIC e Taxa de Câmbio, e de análise de notícias (por exemplo, humor) nas modelagens para auxiliar a tomada de decisão;
- f) otimização para sugerir uma carteira de ativo financeiro em determinado período;
- g) uso das modelagens propostas para identificar quais os ativos financeiros mais influenciados por notícias e rumores do mercado;

- h) desenvolver uma modelagem em algoritmo genético e combinar com as propostas RNA e lógica *fuzzy*;
- i) automatizar as modelagens híbridas;
- j) implementar técnicas de análise de tendência, por exemplo, tendência semanal.

REFERÊNCIAS

ALTUNKAYNAK, A.; ÖZGER, M.; ÇAKMAKCI, M. Water consumption prediction of istanbul city by using fuzzy logic approach. **Water Resources Management**, Oxford, v. 19, n. 5, p. 641-654, 2005.

AMBRÓSIO, P. E. **Redes neurais artificiais no apoio ao diagnóstico diferencial de lesões intersticiais pulmonares**. 2002. 85 p. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, São Paulo, 2002.

ATSALAKIS, G. S.; VALAVANIS, K. P. Forecasting stock market short-term trends using a neuro-fuzzy based methodology. **Expert Systems with Applications**, New York, v. 36, n. 7, p. 10696-10707, Sept. 2009. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417409001948>>. Acesso em: 10 abr. 2012.

BARBOSA, G. R.; ALMEIDA, A. T. Sistemas de apoio a decisão sob o enfoque de profissionais de ti e de decisores. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 12., 2002, Curitiba. **Anais...** Curitiba: UFPR, 2002. p. 1-8.

BARRETO, J. M. Introdução às redes neuronais artificiais. In: ENCONTRO DA ESCOLA REGIONAL DE INFORMÁTICA DA SBC, REGIONAL SUL, 5., 2002, Campo Grande. **Anais...** Campo Grande: SBC, 2002. p. 41-71.

BARROS, L. C. **Teoria fuzzy x biomatemática**. Campinas: IMECC/UNICAMP, 2002. 52 p. Apostila. Disponível em: <<http://www.ime.usp.br/~tonelli/verao-fuzzy/laecio/minicurso3.pdf>>. Acesso em: 12 abr. 2012.

BAUER, D. P. **Aplicação de redes neurais artificiais na determinação do preço de ações**. 2008. 46 p. Monografia (Graduação em Ciência da Computação) - Centro Universitário FEEVALE, Novo Hamburgo, 2008.

BOCANEGRA, C. W. R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. 2002. 97 p. Dissertação (Mestrado em Engenharia Civil) - Universidade de São Paulo, São Paulo, 2002.

BOTELHO, T. G. **Uma nova proposta para implementação computacional do princípio de extensão de Zadeh**. 2002. 77 p. Dissertação (Mestrado em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2002.

BRAGA, A. de P. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2007. 238 p.

BRÍO, B. M.; MOLINA, A. S. **Redes neuronales y sistemas barrosos**. 3. ed. Madrid: Rama, 2006. 442 p.

BRUM, C. A. H. **Aprenda a investir em ações e a operar na bolsa via Internet**. 3. ed. Rio de Janeiro: Ciência Moderna, 2006. 212 p.

CAMBOIM, W. L. L. **Aplicações de técnicas de controle Fuzzy para sistemas de abastecimento de água**. 2008. 106 p. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Federal da Paraíba, João Pessoa, 2008.

CAMPOS FILHO, P. **Método para apoio à decisão na verificação da sustentabilidade de uma unidade de conservação, usando lógica Fuzzy**. 2004. 210 p. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2004.

CAO, L.; TAY, F. E. H. Financial forecasting using support vector machines. **Neural Computing & Applications**, London, v. 10, n. 2, p. 184-192, 2001.

CICHINI, F. A. L.; CASTRO, R.; FLAUZINO, R. A. Uma abordagem baseada em sistemas de inferência Fuzzy para estimação de cotações de ações. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 27., 2007, Foz do Iguaçu. **Anais...** Foz do Iguaçu: UFPR, 2007. p. 1-10.

CORTEZ, P. A. R. **Modelos inspirados na natureza para a previsão de séries temporais**. 2002. 188 p. Tese (Doutorado em Informática) - Universidade do Minho, Minho, 2002.

COSTA, A. J. Perception of disability in a public health perspective: a model based on Fuzzy logic. **International Journal of Medical Informatics**, Clare, v. 73, n. 7/8, p. 647-656, 2004.

COSTA, P. T. da. **Uma análise do consumo de energia em transportes nas cidades portuguesas utilizando redes neuronais artificiais**. 2003. 133 p. Dissertação (Mestrado em Engenharia Municipal) - Universidade do Minho, Minho, 2003.

COTTRELL, G. W. **A connectionist approach to word sense disambiguation**. Rochester: University of Rochester, 1985. 220 p.

DIAS, A. H. et al. Teoria Fuzzy aplicada à automação da condução racional da aeração de grãos de milho. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 5., 2005, Londrina. **Anais...** Londrina: SBIAGRO, 2005. Disponível em: <http://www.sbiagro.org.br/pdf/v_congresso/Trabalho107.pdf>. Acesso em: 9 abr. 2012.

DURÃES, R. L. **Validação de modelos baseados em RNA utilizando análise estatísticas de dados e lógica Fuzzy**. 2009. 123 p. Dissertação (Mestrado em Modelagem Matemática e Computacional) - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2009.

EDMAR, M. **Extração de conhecimento de redes neurais artificiais**. 1999. 104 p. Dissertação (Mestrado em Ciências) - Universidade de São Paulo, São Paulo, 1999.

ELDER, A. **Como se transformar em um operador e investidor de sucesso**. Rio de Janeiro: Campus, 2004. 310 p.

ELMASRI, R.; NAVATHE, S. B. **Sistemas de banco de dados**. 6th ed. New York: A. Wesley, 2011. 808 p.

ESFAHANIPOUR, A.; AGHAMIRI, W. Adapted Neuro-Fuzzy inference system on indirect approach TSK Fuzzy rule base for stock market analysis. **Expert Systems with Applications**, New York, v. 37, n. 7, p. 4742-4748, July 2010. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417409009622>>. Acesso em: 8 abr. 2012.

FALAS, T. Neural networks in empirical accounting research: an alternative to statistical models. **Neural Network World**, Praha, v. 5, n. 4, p. 419-432, Dec. 1995.

FARIA, E. L. et al. **Previsão do mercado de ações brasileiro utilizando redes neurais artificiais, CBPF e PUC RJ**. Rio de Janeiro: CBPF, 2008. 21 p. Disponível em: <http://cbpfindex.cbpf.br/publication_pdfs/NT00208.2011_01_04_11_01_14.pdf>. Acesso em: 8 abr. 2012.

FREEMAN, W. T. **Steerable filters and local analysis of image structure**. 1992. 133 p. Thesis (Ph.D. in Philosophy) - Massachusetts Institute of Technology, Cambridge, 1992.

GHIASSI, M.; SAIDANE, H.; ZIMBRA, D. K. A dynamic artificial neural network model for forecasting time series events. **International Journal of Forecasting**, Amsterdam, v. 21, n. 2, p. 341-362, June 2005. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231204003327>>. Acesso em: 6 abr. 2012.

GOMIDE, F. A. C.; GUDWIN, R. R.; TANSCHKEIT, R. Conceitos fundamentais da teoria de conjuntos Fuzzy, lógica Fuzzy e aplicações. In: INTERNATIONAL FUZZY SYSTEMS ASSOCIATION WORLD CONGRESS/TUTORIALS, 6., 1995, Alberta. **Proceedings...** Alberta: IFSA, 1995. p. 1-38.

GONZALEZ, I. M. S.; GONZALEZ, L. S. G. Redes neurais na previsão de séries temporais financeiras. **Revista Científica da UNIRB**, Salvador, ano 3, n. 1, p. 27-41, 2011.

HAGEL III, J.; SINGER, M. **Net worth**. Boston: Harvard Business School, 1999. 256 p.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The elements of statistical learning: data mining, inference, and prediction**. Chicago: Springer-Verlag, 2001. 533 p.

HAYKIN, S. S. **Kalman filtering and neural networks**. New York: Wiley-Interscience, 2001. 304 p.

_____. **Neural networks: a comprehensive foundation**. 2nd ed. New York: Prentice Hall, 1998. 842 p.

_____. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2000. 900 p.

HINTON, G. E.; SEJNOWSKI, T. J. Learning and relearning in Boltzmann machines. In: _____. **Parallel distributed processing: explorations in the microstructure of cognition**. Cambridge: MIT, 1986. p. 282-317.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **National Academy of Sciences of the United States of America**, Washington, v. 79, n. 8, p. 2554-2558, Dec. 1982.

INFOMONEY. Disponível em: <<http://web.infomoney.com.br/>>. Acesso em: 1 jun. 2010.

JUNG, C. F. **Metodologia aplicada a projetos de pesquisa: sistemas de informação & ciência da computação**. Taquara: [s.n.], 2009. 154 p. Disponível em: <<http://www.jung.pro.br/moodle/mod/resource/view.php?id=102>>. Acesso em: 1 jun. 2010.

KIM, K.; HAN, I. Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. **Expert Systems with Applications**, New York, v. 19, n. 2, p. 125-132, Apr. 2000.

KUMAR, P. R.; RAVI, V. Bankruptcy prediction in banks and firms via statistical and intelligent techniques: a review. **European Journal of Operational Research**, Amsterdam, v. 180, n. 1, p. 1-28, 2007. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0377221706008769>>. Acesso em: 10 abr. 2012.

KWON, O.; GOLDEN, B.; WASIL, E. Estimating the length of the optimal tsp tour: an empirical study using regression and neural networks. **Computers & Operations Research**, New York, v. 22, n. 10, p. 1039-1046, Oct. 1995.

LAMBERT-TORRES, G.; SILVA, L. E. B.; ROSSI, R. A representação de dados através de proposições condicionais difusas. **Revista Ciências Exatas**, Taubaté, v. 5, n. 8, p. 7-14, ago. 2002.

LEWIS, E. L. Fuzzy dimensional analysis. In: INTERNATIONAL SYMPOSIUM ON UNCERTAINTY MODELLING AND ANALYSIS, 3., 1995, Lisboa. **Proceedings...** Lisboa: UTL, 1995. p. 674-678.

LIMA, I. R. et al. CellInvest: um sistema especialista móvel para auxiliar na tomada de decisões em mercado de capitais. In: CONGRESSO BRASILEIRO DE SISTEMAS FUZZY, 1., 2010, Sorocaba. **Anais...** Sorocaba: CBSF, 2010. p. 455-463.

LIMA, P. L. **Ferramenta computacional Fuzzy para aplicações do princípio de extensão de Zadeh em funções aritméticas**. 2011. 93 p. Dissertação

(Mestrado em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2011.

LOPES, W. A.; JAFELICE, R. S. M.; BARROS, L. C. Modelagem Fuzzy de diagnóstico médico e monitoramento do tratamento da pneumonia. **Biomatemática**, Campinas, v. 15, p. 77-96, 2005.

MAGALHÃES, A. N. **Representação da propagação de erros de medidas através de proposições condicionais difusas**. 2009. 70 p. Dissertação (Mestrado em Ciências em Engenharia de Energia) - Universidade Federal de Itajubá, Itajubá, 2009.

MASSAD, E.; ORTEGA, N. R. S.; STRUCHINER, C. J. Fuzzy epidemics. **Artificial Intelligence in Medicine**, Amsterdam, v. 29, n. 3, p. 241-259, June 2003.

MATLAB® Fuzzy logic toolbox 2: user's guide. Disponível em: <<http://www.mathworks.com>>. Acesso em: 15 fev. 2012.

MATSURA, E. **Comprar ou vender**: como investir na bolsa utilizando análise gráfica. 6. ed. São Paulo: Saraiva, 2007. 124 p.

MEISSNER, G. The RSI revisited. **Futures**, Cedar Falls, n. 30, p. 34-36, 2001.

MELLAGI FILHO, A.; ISHIKAWA, S. **Mercado financeiro e de capitais**. São Paulo: Atlas, 2000. 335 p.

MELO, M. N. **Mapeamento difuso no auxílio da redução dos impactos ambientais em uma usina hidrelétrica**. 2009. 91 p. Dissertação (Mestrado em Ciências em Engenharia de Energia) - Universidade Federal de Itajubá, Itajubá, 2009.

MENDEL, J. M. Fuzzy sets for words: a new beginning. In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 12., 2003, Los Angeles. **Proceedings...** Los Angeles: IEEE, 2003. p. 37-42.

MENEZES, L. M.; NIKOLAEV, N. Y. Forecasting with genetically programmed polynomial neural networks. **International Journal of Forecasting**, Amsterdam, v. 22, n. 2, p. 249-265, June 2006. Disponível em: <<http://www.sciencedirect.com.ez26.periodicos.capes.gov.br/science/article/pii/S0169207005000610>>. Acesso em: 15 abr. 2012.

NASCIMENTO, F. B. et al. **Software de auxílio à tomada de decisão para o investidor do mercado acionário**. 2007. 114 p. Monografia (Graduação em Engenharia de Computação) - Universidade de São Paulo, São Paulo, 2007.

OCAMPO-DUQUE, W. et al. Assessing water quality in rivers with Fuzzy inference systems: a case study. **Environment International**, New York, v. 32, n. 6, p. 733-742, June 2006.

ONLINE TRADING CONCEPTS. Disponível em:
<<http://www.onlinetradingconcepts.com/>>. Acesso em: 2 jun. 2010.

ORTEGA, N. R. S. **Aplicação da teoria de conjuntos Fuzzy a problemas da biomedicina**. 2001. 152 p. Tese (Doutorado em Ciências) - Universidade de São Paulo, São Paulo, 2001.

OTTAVIANO, I. M. L. d'; FEITOSA, H. A. Sobre a história da lógica, a lógica clássica e o surgimento das lógicas não-clássicas. In: SEMINÁRIO NACIONAL DE HISTÓRIA DA MATEMÁTICA, 5., 2003, Aracaju. **Anais...** Aracaju: SBHMAT, 2003. 1 CD-ROM.

PARRACHO, P. M. V. A. **PATTERN: identificação de padrões em mercados bolsistas**. 2010. 99 p. Dissertação (Mestrado em Engenharia Informática e de Computadores) - Universidade Técnica de Lisboa, Lisboa, 2010.

PEDRONETTE, D. C. G.; GUILHERME, I. R. Apoio à tomada de decisões no mercado financeiro utilizando redes neurais. In: SIMPÓSIO INTERNACIONAL DE INICIAÇÃO CIENTÍFICA DA UNIVERSIDADE DE SÃO PAULO, 12., 2004, São Paulo. **Anais...** São Paulo: USP, 2004. 1 CD-ROM.

PEREIRA, A. A. **Avaliação da qualidade da água: proposta de novo índice alicerçado na lógica Fuzzy**. 2010. 170 p. Tese (Doutorado em Ciências da Saúde) - Universidade de Brasília, Brasília, 2010.

PINHEIRO, J. L. **Mercado de capitais**. 6. ed. São Paulo: Atlas, 2012. 560 p.

PORTELINHA, M. **Redes neuronais artificiais para a previsão da qualidade em carnes**. 2006. 135 p. Dissertação (Mestrado em Sistemas de Informação) - Universidade do Minho, Minho, 2006.

PREMINGER, A.; FRANCK, R. Forecasting exchange rates: a robust regression approach. **International Journal of Forecasting**, New York, v. 23, n. 1, p. 71-84, Jan. 2007. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0169207006000549>>.
Acesso em: 20 abr. 2012.

PYLE, D. **Data preparation for data mining**. New York: M. Kaufmann, 1999. 540 p.

RADU, C.; WILKERSON, R. Using Fuzzy set theory. **IEEE Potentials**, New York, v. 14, n. 5, p. 33-35, 1996.

RAGHAVENDRA, S.; PARASCHIV, D.; VASILIU, L. **A framework for testing algorithmic trading strategies**. Galway: University of Ireland, 2008. (Working Paper, 139). Disponível em:
<http://aran.library.nuigalway.ie/xmlui/bitstream/handle/10379/325/paper_0139.pdf?sequence=1>. Acesso em: 15 abr. 2012.

RAUBER, T. W. **Redes neurais artificiais**. Vitória: UFES, 2005. Disponível em:
<http://www.riopomba.ifsudestemg.edu.br/dcc/dcc/materiais/1926024727_reconhecimento-de-caracter2.pdf>. Acesso em: 13 abr. 2012.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. São Paulo: Manole, 2002. 550 p.

RODRÍGUEZ-GONZÁLEZ, A. et al. CAST: using neural networks to improve trading systems based on technical analysis by means of the RSI financial indicator. **Expert Systems with Applications**, New York, v. 38, n. 9, p. 11489-11500, Sept. 2011.

ROH, T. H. Forecasting the volatility of stock price index. **Expert Systems with Applications**, New York, v. 33, n. 4, p. 916-922, Apr. 2007. Disponível em:
<<http://www.sciencedirect.com.ez26.periodicos.capes.gov.br/science/article/pii/S0957417406002223>>. Acesso em: 20 abr. 2012.

RUHOFF, A. L. et al. Lógica Fuzzy e zoneamento ambiental da Bacia do Arroio Grande. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, São Paulo. **Anais...** São Paulo: INPA, 2005. p. 2355-2362.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by backpropagation errors. **Nature**, London, v. 323, p. 533-536, 1986.

RUMELHART, D. E.; MCCLELLAND, J. L. **Parallel distributed processing: exploration the microstructure of cognition**. Cambridge: Bradford Book, 1986. 567 p.

RUSSEL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. New Jersey: Prentice-Hall, 1995. 960 p.

_____. **Inteligência artificial**. 2. ed. Rio de Janeiro: Campus, 2003. 1040 p.

SANDRI, S.; CORREA, C. Lógica nebulosa. In: ENCONTRO DA ESCOLA DE REDES NEURAIAS, 5., 1999, Campo Grande. **Anais...** Campo Grande: Instituto Tecnológico da Aeronáutica, 1999. p. c073-c090.

SANTOS, F. C. B. **Desenvolvimento e análise de um índice de sustentabilidade energética utilizando lógica Fuzzy**. 2010. 137 p. Dissertação (Mestrado em Ciências) - Instituto de Pesquisas Energéticas e Nucleares, São Paulo, 2010.

SARLE, W. Stopped training and other remedies for overfitting. In: SYMPOSIUM INTERFACE OF COMPUTER SCIENCE AND STATISTICS, 27., 1995, Cary. **Proceedings...** Cary: SAS Institute, 1995. p. 352-360.

SETIONO, R. Techniques for extracting classification and regression rules from artificial neural networks. In: _____. **Computational intelligence: the experts speak**. Piscataway: Wiley-IEEE, 2002. p. 99-113.

SHAW, I. S.; SIMÕES, M. G. **Controle e modelagem Fuzzy**. São Paulo: E. Blücher, 1999. 165 p.

SILVA, M. A. O. **Estudo de técnicas de controle aplicada ao sistema pêndulo invertido**. 2009. 51 p. Monografia (Graduação em Engenharia de Controle e Automação) - Universidade Federal de Ouro Preto, Ouro Preto, 2009.

STOCKCHARTS. **ChartSchool**. Disponível em: <http://stockcharts.com/school/doku.php?id=chart_school>. Acesso em: 15 jun. 2010.

SUBRAMANIAN, V.; HUNG, M. S.; HU, M. Y. An experimental evaluation of neural networks for classification. **Computers & Operations Research**, New York, v. 20, n. 7, p. 769-782, July 1993.

THÉ, M. A. L. **Raciocínio baseado em casos: uma abordagem Fuzzy para diagnóstico nutricional**. 2001. 170 p. Tese (Doutorado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 2001.

THIELE, H. On concept of qualitative Fuzzy set. In: IEEE INTERNATIONAL SYMPOSIUM ON MULTIPLE-VALUED LOGIC, 29., 1999, Dortmund. **Proceedings...** Dortmund: University of Dortmund, 1999. p. 282-287.

THOMAZ, C. E.; VELLASCO, M. M. B. R. Análise de tendências de mercado por redes neurais artificiais. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 7., 2005, São Bernardo do Campo. **Anais...** São Bernardo do Campo: FEI, 2005. p. 1-5. Disponível em: <<http://fei.edu.br/~cet/cbrn05.pdf>>. Acesso em: 20 abr. 2012.

VIDOTTO, R. S.; MIGLIATO, A. L. T.; ZAMBON, A. C. O moving average convergence-divergence como ferramenta para a decisão de investimentos no mercado de ações. **Revista de Administração Contemporânea**, Curitiba, v. 13, n. 12, p. 291-309, dez. 2009.

VIEIRA, F. H. T.; LING, L. L. Modelagem Fuzzy utilizando funções de base ortonormais aplicada à predição adaptativa de tráfego de redes. **Learning and Nonlinear Models**, Fortaleza, v. 4, n. 2, p. 93-111, Feb. 2006.

WASSERMAN, P. D. **Advanced methods in neural computing**. New York: V. N. Reinhold, 1993. 255 p.

WEBER, L.; KLEIN, P. A. T. **Aplicação da lógica Fuzzy em software e hardware**. 2. ed. Santa Maria: ULBRA, 2003. 110 p.

YU, T. H.; HUARNG, K. A bivariate fuzzy time series model to forecast the TAIEX. **Expert Systems with Applications**, New York, v. 34, n. 4, p. 2945-2952, Apr. 2008. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417407001893>>. Acesso em: 18 abr. 2012.

ZADEH, L. A. Fuzzy sets. **Information and Control**, New York, v. 8, p. 338-353, 1965.

ZANETTI JUNIOR, L. A.; ALMEIDA, F. C. Exploração do uso de redes neurais na previsão do comportamento de ativos financeiros. In: SEMINÁRIOS EM ADMINISTRAÇÃO, 3., 1998, São Paulo. **Anais...** São Paulo: USP, 1998. Disponível em:

<<http://www.ead.fea.usp.br/semead/3semead/pdf/Finan%E7as/Art061.PDF>>.
Acesso em: 15 abr. 2012.

ZHANG, Y.; WAN, X. Statistical Fuzzy interval neural networks for currency exchange rate time series prediction. **Applied Soft Computing**, New York, v. 7, n. 4, p. 1149-1156, Aug. 2007. Disponível em:
<<http://www.sciencedirect.com/science/article/pii/S1568494606000068>>.
Acesso em: 20 abr. 2012.