



**FLÁVIO LOPES DE MORAIS**

**SISTEMA INTELIGENTE DE APOIO À TOMADA DE  
DECISÃO EM MERCADO DE AÇÕES: ABORDAGEM  
FUNDAMENTADA EM COMPORTAMENTO MULTITEMPORAL**

**LAVRAS – MG**

**2017**

**FLÁVIO LOPES DE MORAIS**

**SISTEMA INTELIGENTE DE APOIO À TOMADA DE DECISÃO EM MERCADO  
DE AÇÕES: ABORDAGEM FUNDAMENTADA EM COMPORTAMENTO  
MULTITEMPORAL**

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

Prof. Dr. Wilian Soares Lacerda  
Orientador

**LAVRAS – MG**

**2017**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo próprio autor.**

Morais, Flávio Lopes de.

Sistema Inteligente de Apoio à Tomada de Decisão em  
Mercado de Ações : Abordagem Fundamentada em Compor-  
tamento Multitemporal / Flávio Lopes de Moraes. – 2017.

155 p. : il.

Orientador: Wilian Soares Lacerda.

Dissertação (mestrado acadêmico) – Universidade Federal  
de Lavras, 2017.

Bibliografia.

1. Mercado de Ações. 2. Hipótese do Mercado Eficiente.  
3. Inteligência Computacional. I. Lacerda, Wilian Soares. II.  
Título.

**FLÁVIO LOPES DE MORAIS**

**SISTEMA INTELIGENTE DE APOIO À TOMADA DE DECISÃO EM MERCADO  
DE AÇÕES: ABORDAGEM FUNDAMENTADA EM COMPORTAMENTO  
MULTITEMPORAL**

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

APROVADA em 28 de Março de 2017.

Prof. Dr. Joel Yutaka Sugano UFLA

Prof. Dr. Paulo de Oliveira Lima Júnior CEFET - MG

Prof. Dr. Wilian Soares Lacerda  
Orientador

**LAVRAS – MG  
2017**

*Dedico esta conquista aos meus pais José Osmar e Maria Helena, minhas irmãs Mirene e Valéria, meus sobrinhos e afilhados Davi, Eliseu e Pedro Miguel, e em especial à minha querida esposa Claudiane.*

## **AGRADECIMENTOS**

Agradeço, em primeiro lugar a Deus, pelo dom da vida e por me guiar durante esta caminhada. À minha esposa Claudiane, pessoa com quem amo partilhar a vida, obrigado pelo carinho, paciência, e por sua capacidade de me confortar diante das adversidades. Aos meus pais, José Osmar e Maria Helena, e minhas irmãs, Mirene e Valéria, que com muito carinho e apoio, não mediram esforços para que eu chegasse até aqui.

Agradeço à Universidade Federal de Lavras, ao Departamento de Engenharia, e ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação, pela estrutura oferecida e oportunidade de realização do mestrado.

Agradeço ao orientador Dr. Wilian Soares Lacerda, pela confiança, conselhos e orientação, que foram de grande valia para a realização deste trabalho.

E a todos que, de algum modo, participaram desta conquista, os meus sinceros agradecimentos.

## RESUMO

Ações representam parte do capital próprio de uma corporação, e são negociadas majoritariamente em bolsas de valores por meio do processo denominado distribuição secundária. Diante da possibilidade de ganhos financeiros decorrentes da oscilação constante nos preços de ativos acionários, atividades especulativas constituem prática comum neste mercado, levando a um ambiente altamente competitivo. A Hipótese do Mercado Eficiente (HME) assume não ser possível a obtenção de retornos excessivos consistentemente, pois qualquer tipo de informação seria rapidamente refletida no preço do ativo. Neste trabalho foi proposto um modelo de sistema para atuação especulativa em mercado de ações, de forma a verificar a hipótese fraca da HME. Este modelo foi proposto com base em estudos bibliográficos e na revisão sistemática de literatura, conduzida como parte deste trabalho. A proposta tem como base o emprego de uma estratégia de seguimento de tendências baseada em múltiplos tempos gráficos, apoiada pela previsão de comportamento por algoritmos de inteligência computacional. O modelo proposto é fundamentado em características comportamentais do mercado acionário, originárias da escola de Análise Técnica e Teoria de *Dow*, e utiliza um conjunto de indicadores técnicos calculados a partir de dados provenientes da própria movimentação histórica do ativo. No intuito de verificar a viabilidade da proposta, foi desenvolvida uma versão do sistema para avaliação do desempenho sobre dados históricos de 30 ações da BM&FBovespa. Sobre esta base de dados, o sistema foi avaliado com dados fora da amostra no período fechado de 01/01/2010 a 31/08/2016. Para uma simulação mais condizente com a realidade, foram considerados os custos transacionais e *bid-ask spread*, além de restrições quanto ao tamanho do lote de negociação. Nas simulações, o sistema proposto conseguiu um desempenho financeiro acumulado (ROI - *Return On Investment*) médio, 20,32% superior à média do mercado. No entanto, ao considerar o resultado ROI sobre cada ativo avaliado, o desempenho do mercado foi superior ao do sistema em 53,33% dos casos, confirmando portanto a Hipótese do Mercado Eficiente. Outras medidas de desempenho indicam viabilidade da proposta, que mostrou-se menos arriscada e com maior propensão de resultados financeiros positivos. O sistema foi também comparado à uma estratégia baseada em cruzamento de médias móveis, conseguindo um ROI 79,97% superior à esta. Para o mesmo período considerado nas simulações, enquanto o desempenho IBOVESPA foi de -17,34%, o sistema conseguiu um ROI médio de 97,47%. Os resultados mostram ainda possibilidade de potencialização dos retornos financeiros alcançados pelo sistema, visto que nas simulações de operação o capital foi utilizado em média por apenas 25,55% do tempo total disponível. A proposta foi também comparada aos resultados do estado da arte sobre o índice *Shanghai Stock Exchange Composite*. Nesta última comparação, foi considerado o período fora da amostra de 2001 a 2013, onde o sistema proposto alcançou um ROI 35,94% superior.

**Palavras-chave:** Mercado de Ações. Hipótese do Mercado Eficiente. Seguimento de Tendência. Inteligência Computacional. Previsão de Comportamento.

## ABSTRACT

Stocks correspond to a share of equity in a corporation, and they are traded mostly on stock exchanges by the process denominated secondary distribution. With the possibility of financial gains due to the constant changes in stock prices, speculative activities are a common practice in this market, leading to a highly competitive environment. The Efficient Market Hypothesis (EMH) assumes that it is not possible to obtain consistently excessive returns, since any type of information would be quickly reflected in share prices. In this work, a system model for speculative activities in the stock market was proposed, in order to verify the weak form of EMH. This model was proposed based on bibliographic studies and in a systematic literature review, conducted as part of this work. The proposal is based on the use of a trend-following strategy, based on multiple graphical times, supported by behavior prediction by the computational intelligence algorithms. The proposed model is based on behavioral characteristics of the stock market, originating from the Technical Analysis school and Dow Theory, and uses a set of technical indicators calculated from the own historical stock activity. In order to verify the feasibility of the proposal, an evaluation version of the system was developed. This version was then evaluated over a historical data from 30 shares of BM&FBovespa. On this database, the system was evaluated with an out-of-sample data that covered the whole period from 01/01/2010 to 08/31/2016. To a more realistic simulation, we considered transaction costs and bid-ask spread, as well as restrictions on the shares lot size. In the simulations, the proposed system achieved an average cumulative financial performance (ROI - Return On Investment), 20.32% higher than the market average. However, when considering the individual ROI on each share, the market performance was superior to the system in 53.33% of the cases, confirming the Efficient Market Hypothesis. Other performance measures indicate feasibility of the proposal, which have shown to be less risky and more likely to have positive financial results. The system was also compared to a Moving Average Crossovers strategy, achieving a ROI of 79.97% higher. To the same considered period in the simulations, while the IBOVESPA performance was -17.34%, the system achieved an average ROI of 97.47%. The results also showed the possibility of increasing financial returns with the proposed system, since in the operation simulations the capital was used, on average, in 25.55% of the total available period. The proposal was also compared to the state of the art on the Shanghai Stock Exchange Composite Index, from 2001 to 2013. In this last comparison, the proposed system achieved an ROI 35.94% higher.

**Keywords:** Stock Market. Efficient Market Hypothesis. Trend Following. Computational Intelligence. Behavior Prediction.



## LISTA DE FIGURAS

Figura 2.1 – Hiperplano Ótimo e Margens de Separação Sobre um Problema de Classificação Binária. . . . .	40
Figura 2.2 – Exemplo de classificador SVM encontrado por uma função RBF. . . . .	41
Figura 2.3 – Estrutura básica de um neurônio artificial. . . . .	42
Figura 2.4 – Rede neural <i>feedforward</i> de camada única. . . . .	44
Figura 2.5 – Rede neural <i>feedforward</i> de múltiplas camadas. . . . .	44
Figura 2.6 – Rede neural recorrente sem camadas ocultas e sem auto-realimentação. . .	45
Figura 3.1 – Arquitetura geral do sistema proposto. . . . .	52
Figura 3.2 – Exemplo de média móvel simples de 12 períodos (SMA12) sobre o gráfico semanal da ação SUZB5 para o período de 01/01/2012 a 01/01/2014. . . .	61
Figura 4.1 – Gráfico semanal do ativo FIBR3, no período de 01/01/2003 a 31/08/2016. Espaçamentos maiores retilíneos entre pontos do gráfico exibem inconsistência nos dados. . . . .	81
Figura 4.2 – Gráfico semanal do ativo UGPA3, no período de 01/01/2006 a 31/08/2016. Espaçamentos maiores retilíneos entre pontos do gráfico exibem inconsistência nos dados. . . . .	82
Figura 4.3 – Gráfico semanal do ativo LREN3, no período de 01/01/2006 a 31/08/2016. Inconsistências devido à grande variação entre valores de fechamento subsequentes. . . . .	82
Figura 4.4 – Evolução do capital investido sobre o ativo RADL3, com a aplicação do sistema proposto. . . . .	87
Figura 4.5 – Retorno percentual alcançado ao final de cada operação efetuada pelo sistema sobre o ativo RADL3. . . . .	88
Figura 4.6 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema sobre o ativo RADL3. . . . .	88
Figura 4.7 – Desempenho financeiro do sistema, e resultado B&H sobre o ativo RADL3.	91
Figura 4.8 – Evolução do capital investido sobre o ativo USIM5, com a aplicação do sistema proposto e B&H. . . . .	92
Figura 4.9 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema, sobre o ativo USIM5. . . . .	92

Figura 4.10 – Retorno percentual resultante de cada operação efetuada pelo sistema sobre o ativo USIM5. . . . .	92
Figura 4.11 – Evolução do capital investido sobre o ativo SUZB5, com a aplicação do sistema proposto e B&H. . . . .	93
Figura 4.12 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema, sobre o ativo SUZB5. . . . .	93
Figura 4.13 – Retorno percentual resultante de cada operação efetuada pelo sistema sobre o ativo SUZB5. . . . .	94
Figura 4.14 – Evolução do capital investido sobre o ativo ITSA4, com a aplicação do sistema proposto e B&H. . . . .	94
Figura 4.15 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema sobre o ativo ITSA4. . . . .	95
Figura 4.16 – Percentual de retorno a cada operação efetuada pelo sistema sobre o ativo ITSA4. . . . .	95
Figura 4.17 – Evolução do capital investido sobre o ativo RADL3, com a utilização do sistema proposto, MM, e B&H. . . . .	98
Figura 4.18 – Evolução do capital investido sobre o ativo VALE3, com a utilização do sistema proposto, MM, e B&H. . . . .	99
Figura 4.19 – Evolução do capital investido sobre o ativo PETR4, com a utilização do sistema proposto, MM, e B&H. . . . .	99
Figura 4.20 – Retorno percentual de cada operação efetuada por Hu et al. (2015) sobre o índice <i>SSE-Composite (Composite Index)</i> . . . . .	104
Figura 4.21 – Retorno percentual de cada operação efetuada pelo sistema sobre o índice <i>SSE-Composite</i> . . . . .	104
Figura 4.22 – Comparativo de desempenho financeiro entre <i>eTrend</i> , DT, NN, <i>Composite Index</i> e <i>Industrials Index</i> , feito por Hu et al. (2015). . . . .	105
Figura 4.23 – Evolução do capital investido sobre o índice <i>SSE-Composite Index</i> , com a aplicação do sistema proposto e desempenho B&H. . . . .	105
Figura 4.24 – Operações efetuadas entre 01/01/2001 e 31/07/2013 pelo sistema sobre o índice <i>SSE-Composite</i> . . . . .	106
Figura 1 – Quantidade de publicações por tipo de algoritmo. . . . .	143
Figura 2 – Utilização anual dos algoritmos SVM e ANN. . . . .	146

Figura 3 – Quantidade total e percentual de publicações por tipo de dado. . . . . 147

## LISTA DE TABELAS

Tabela 3.1 – Relação de indicadores técnicos calculados pelo Módulo 2 da versão de avaliação. . . . .	58
Tabela 3.2 – Taxas consideradas na contabilização dos custos financeiros. . . . .	69
Tabela 3.3 – Lista de ações compostas pelo índice IBrX-50 em Agosto de 2016. . . . .	73
Tabela 4.1 – Relação de ativos desconsiderados nas simulações. . . . .	81
Tabela 4.2 – Desempenho <i>Hit Ratio</i> de SVM e ANN, nos tempos gráficos semanal e mensal, para o grupo de ativos considerados. . . . .	83
Tabela 4.3 – Relação com os 10 indicadores técnicos mais utilizados para previsões semanais. . . . .	84
Tabela 4.4 – Relação com os 10 indicadores técnicos mais utilizados para previsões mensais. . . . .	84
Tabela 4.5 – Indicadores técnicos utilizados para previsões semanais de ABEV3 em 2015.	85
Tabela 4.6 – Indicadores técnicos utilizados para previsões mensais de ABEV3 em 2015.	85
Tabela 4.7 – Desempenho das simulações de atuação do sistema entre 01/01/2010 e 31/08/2016, para o conjunto de ativos considerados. . . . .	86
Tabela 4.8 – Desempenho das ações utilizadas nas simulações com o sistema proposto. .	90
Tabela 4.9 – Desempenho alcançado nas simulações de operação em mercado com a utilização da estratégia de cruzamento de médias móveis. . . . .	97
Tabela 4.10 – Desempenhos médios alcançados com o sistema proposto, MM, B&H, e índice IBOVESPA. . . . .	100
Tabela 4.11 – Desempenho <i>Hit Ratio</i> dos algoritmos SVM e ANN sobre os tempos gráficos semanal e mensal do índice <i>SSE-Composite</i> . . . . .	101
Tabela 4.12 – Relação com os 10 indicadores técnicos mais utilizados nas previsões semanais do índice <i>SSE-Composite</i> . . . . .	102
Tabela 4.13 – Relação com os 10 indicadores técnicos mais utilizados nas previsões mensais do índice <i>SSE-Composite</i> . . . . .	102
Tabela 4.14 – Desempenho das simulações de operação sobre o índice <i>SSE-Composite</i> , com a utilização do sistema proposto, B&H, e Hu et al. (2015). . . . .	103

## LISTA DE QUADROS

Quadro A.1 – Trabalhos publicados em 2012. . . . .	152
Quadro A.2 – Trabalhos publicados em 2013. . . . .	153
Quadro A.3 – Trabalhos publicados em 2014. . . . .	153
Quadro A.4 – Trabalhos publicados em 2015. . . . .	154
Quadro A.5 – Trabalhos publicados em 2016. . . . .	155

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
1.1	Objetivos	15
1.2	Justificativas	16
1.3	Organização do Texto	17
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>18</b>
2.1	Mercado de Ações	18
2.1.1	Especulação	20
2.1.2	Venda a Descoberto	21
2.1.3	Estratégias de Negociação com Algoritmos Computacionais	22
2.1.4	Hipótese do Mercado Eficiente	23
2.1.5	Teoria de <i>Dow</i>	26
2.1.6	Análise Fundamentalista	29
2.1.7	Análise Técnica	30
2.1.7.1	Indicadores Técnicos	33
2.1.7.2	Evidências Empíricas	35
2.2	Classificação de Dados	38
2.2.1	Máquinas de Vetores de Suporte	39
2.2.2	Redes Neurais Artificiais	41
2.2.3	Pré-processamento	47
2.2.4	Seleção de Características	48
2.3	Estado da Arte	50
<b>3</b>	<b>METODOLOGIA</b>	<b>52</b>
3.1	Sistema Proposto	52
3.1.1	Módulo 1 - Coleta de Dados Primários	53
3.1.1.1	Proposta	53
3.1.1.2	Solução Desenvolvida para Avaliação	55
3.1.2	Módulo 2 - Cálculo de Indicadores Estatísticos	56
3.1.2.1	Proposta	56
3.1.2.2	Solução Desenvolvida para Avaliação	56
3.1.3	Módulo 3 - Detecção de Tendências	57
3.1.3.1	Proposta	57

3.1.3.2	<b>Solução Desenvolvida para Avaliação</b>	59
3.1.4	<b>Módulo 4 - Remoção de Ruídos</b>	60
3.1.4.1	<b>Proposta</b>	60
3.1.4.2	<b>Solução Desenvolvida para Avaliação</b>	60
3.1.5	<b>Módulo 5 - Seleção de Características</b>	61
3.1.5.1	<b>Proposta</b>	61
3.1.5.2	<b>Solução Desenvolvida para Avaliação</b>	61
3.1.6	<b>Módulo 6 - Previsão</b>	62
3.1.6.1	<b>Proposta</b>	62
3.1.6.2	<b>Solução Desenvolvida para Avaliação</b>	63
3.1.6.3	<b>Configuração do Algoritmo ANN</b>	64
3.1.6.4	<b>Configuração do Algoritmo SVM</b>	65
3.1.6.5	<b>Metodologia Utilizada para Treinamento e Teste dos Classificadores</b>	65
3.1.7	<b>Módulo 7 - Emissão de Sinais e Atuação</b>	66
3.1.7.1	<b>Proposta</b>	66
3.1.7.2	<b>Solução Desenvolvida para Avaliação</b>	68
3.2	<b>Configuração do Ambiente de Avaliação</b>	69
3.2.1	<b>Custos Financeiros Operacionais</b>	69
3.2.2	<i>Bid-Ask Spread</i>	70
3.2.3	<b>Período e Quantidades</b>	71
3.2.4	<b>Base de Dados</b>	71
3.3	<b>Comparativos</b>	72
3.3.1	<b>Eficiência do Mercado Segundo a HME</b>	72
3.3.2	<b>Cruzamento de Médias Móveis</b>	74
3.3.3	<b>Estado da Arte</b>	75
3.4	<b>Métricas de Avaliação</b>	76
3.4.1	<b>Desempenho Preditivo</b>	76
3.4.2	<b>Desempenho Financeiro</b>	76
4	<b>RESULTADOS E DISCUSSÕES</b>	80
4.1	<b>Previsão de Comportamento</b>	80
4.2	<b>Simulações com Dados Históricos e Comparações</b>	86
4.2.1	<b>Comparação com <i>Buy-and-Hold</i> Simples</b>	90

<b>4.2.2</b>	<b>Comparação com Médias Móveis</b>	<b>97</b>
<b>4.2.3</b>	<b>Desempenhos Médios</b>	<b>100</b>
<b>4.3</b>	<b>Comparação com Estado da Arte</b>	<b>101</b>
<b>5</b>	<b>CONCLUSÃO</b>	<b>107</b>
<b>5.1</b>	<b>Contribuições</b>	<b>108</b>
<b>5.2</b>	<b>Propostas para Continuidade da Pesquisa</b>	<b>109</b>
	<b>APÊNDICE A – Revisão Sistemática da Literatura</b>	<b>138</b>
<b>A.1</b>	<b>Resumo</b>	<b>138</b>
<b>A.2</b>	<b>Introdução</b>	<b>138</b>
<b>A.3</b>	<b>Metodologia</b>	<b>138</b>
<b>A.4</b>	<b>Desenvolvimento</b>	<b>141</b>
<b>A.5</b>	<b>Resultados e Discussão</b>	<b>142</b>
<b>A.5.1</b>	<b>Questões Metodológicas</b>	<b>150</b>
<b>A.6</b>	<b>Relação de Trabalhos Publicados</b>	<b>152</b>



## 1 INTRODUÇÃO

A bolsa de valores consiste em um ambiente onde ampla variedade de produtos e serviços (ações, títulos de renda fixa, moedas, etc.) são negociados (BM&FBOVESPA, 2017). Em operação no Brasil existe atualmente a Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBovespa), com ações de mais de 340 empresas cadastradas. Uma ação corresponde a parte do capital próprio de uma empresa (TEWELES; BRADLEY, 1998), e são geralmente negociadas em bolsas de valores por meio do processo denominado distribuição secundária.

A variação nos preços de ativos negociados em bolsas de valores atrai inúmeros tipos de participantes, que buscam a todo instante identificar e explorar oportunidades, gerando um ambiente altamente competitivo. Mas como já indicado por Copeland e Weston (1988), a própria atuação conjunta de investidores na tentativa de tirar proveito de algum comportamento previsto, pode precipitar o movimento esperado, inviabilizando os resultados. Esta afirmação de Copeland e Weston (1988) alinha-se à Hipótese do Mercado Eficiente (HME) (FAMA, 1970), onde é assumido não ser possível a obtenção de lucros excessivos consistentes superiores à média do mercado, pois qualquer tipo de informação seria rapidamente refletida no preço do ativo.

Claramente opostas à HME, os métodos de análise e previsão acionária mais conhecidos, a Análise Técnica (AT) (EDWARDS; MAGEE; BASSETTI, 2007) e a Análise Fundamentalista (AF) (MURPHY, 1999), são amplamente utilizados (ROMEU; SERAJUDDIN, 2001). Enquanto a AF acredita na existência de um valor intrínseco da ação, determinado por fatores econômicos subjacentes, a AT baseia-se em fatores comportamentais e psicológicos, que seriam refletidos em gráficos e indicadores técnicos. Evidências empíricas favoráveis, e também contrárias, às análises técnica e fundamentalista são encontradas na literatura.

Conceitos relativos à análise técnica indicam uma possível ineficiência do mercado em refletir instantaneamente as informações disponíveis, sendo esta uma possível causa para o surgimento de movimentos de tendência nos preços. A teoria de *Dow* (RHEA, 1932) já afirmava que o mercado era eficiente em refletir rapidamente qualquer tipo de informação, afirmando também ser perceptível que os preços moviam-se em tendências, guiadas principalmente pela atuação de grandes investidores a partir de previsões quanto às perspectivas econômicas do ambiente.

Mesmo com fortes evidências empíricas favoráveis à validade da hipótese fraca da HME, de acordo com Agrawal, Chourasia e Mittra (2013), conceitos relativos à AT são ainda larga-

mente utilizados por grande número de participantes do mercado. Livros especializados em análise técnica (MURPHY, 1999; ACHELIS, 2000; ROMEU; SERAJUDDIN, 2001; EDWARDS; MAGEE; BASSETTI, 2007; PRING, 2014) apresentam conceitos e técnicas aparentemente viáveis quanto ao emprego de tais estratégias, relacionadas principalmente ao seguimento de tendências (TF - *Trend-Following*) — estratégia de negociação onde busca-se atuar na mesma direção da tendência vigente (EDWARDS; MAGEE; BASSETTI, 2007).

A hipótese fraca da HME afirma não ser possível a construção de regras de negociação, a partir de informações públicas acerca da movimentação do próprio ativo, capazes de gerar retorno financeiro consistente superior à média do próprio desempenho do mercado. Embora contestada por diversos trabalhos, estudos bibliográficos mostram que a HME, ao menos em suas hipóteses fraca e semi-forte, tem prevalecido. No trabalho de Park e Irwin (2007), por exemplo, comenta-se sobre a recorrência de problemas metodológicos em publicações relacionadas ao tema da pesquisa, relativos a, por exemplo, contabilização inadequada de custos transacionais, dentre outros. Da mesma forma, na Revisão Sistemática da Literatura (SLR - *Systematic Literature Review*) (KITCHENHAM, 2004) conduzida como parte desta pesquisa (Apêndice A), constatou-se que diversos trabalhos apresentam problemas metodológicos variados, dentre os quais encontra-se a falta, ou inadequada, contabilização de custos operacionais.

Diante das evidências quanto à validade da HME, e levando-se em conta conceitos e alegações contrárias a tais evidências, a seguinte questão de pesquisa foi definida: um sistema fundamentado em AT e teoria de *Dow* é capaz de superar a HME em sua hipótese fraca? No intuito de responder a esta questão, em seguida são apresentados os objetivos deste trabalho.

## 1.1 Objetivos

Objetivou-se neste trabalho propor um modelo de sistema para atuação especulativa em mercado de ações, de forma a verificar a hipótese fraca da HME. O modelo proposto emprega uma estratégia de seguimento de tendências baseada em múltiplos tempos gráficos, apoiada por técnicas de previsão por algoritmo de Inteligência Computacional (IC). A proposta possui foco na atuação de médio e longo prazo, e utiliza dados provenientes da própria movimentação histórica do ativo. O modelo proposto é fundamentado em características comportamentais do mercado acionário, originárias da escola de Análise Técnica (AT) e Teoria de *Dow*. Para alcance do objetivo geral, foram definidos os seguintes objetivos específicos:

- verificar, por meio da técnica SLR, o estado da arte quanto ao emprego de algoritmos computacionais para previsão de comportamento de ativos do mercado acionário;
- propor um modelo de sistema para atuação em mercado acionário;
- desenvolver uma versão de avaliação da proposta;
- construir um ambiente de testes para realização dos experimentos;
- avaliar o desempenho do sistema, segundo critérios da HME;
- comparar os resultados preditivos entre os algoritmos de IC empregados;
- comparar o desempenho do sistema a uma estratégia de negociação baseada em cruzamento de médias móveis;
- comparar o desempenho do sistema ao estado da arte.

## 1.2 Justificativas

Diante da dificuldade envolvida na previsão de comportamento do mercado acionário, estratégias de seguimento de tendência (TF - *Trend-Following*) são amplamente aceitas devido a seu princípio simples de funcionamento (HU et al., 2015). Este tipo de estratégia é amplamente empregada nos mercados de câmbio (JAMES et al., 2003) e *commodity* (SZAKMARY; SHEN; SHARMA, 2010), com histórico de sucesso para este último, mesmo após contabilização de taxas transacionais (SZAKMARY; SHEN; SHARMA, 2010). É afirmado por Hu et al. (2015) que, apesar de algumas evidências promissoras quanto à estratégia TF no mercado acionário, poucos trabalhos investigam a aplicação de técnicas de Inteligência Computacional (IC) no suporte a este tipo de estratégia. Esta carência mencionada por Hu et al. (2015), foi também observada pela SLR (Apêndice A) conduzida como parte desta pesquisa. Considerando a importância da análise de múltiplos tempos gráficos, apontada tanto pela AT, quanto teoria de *Dow*, foi observado por meio da SLR e estudos bibliográficos, certa lacuna de pesquisa quanto ao emprego de múltiplos tempos gráficos no desenvolvimento de estratégias TF, apoiadas por algoritmos de inteligência computacional.

Atsalakis e Valavanis (2009) afirmam que o mercado acionário é um sistema sem memória (*memoryless*), ou seja, cotações históricas não definem o preço seguinte, alinhando-se

ao conceito de padrão de comportamento aleatório (*random walk*), definido pela HME. Embora a previsão confiável do preço absoluto de ativos, desempenhada por algoritmos de IC, seja improvável, evidências empíricas mostram certa capacidade quanto à previsão de tendências (ATSALAKIS; VALAVANIS, 2009). Tais evidências alinham-se aos conceitos da análise técnica e teoria de *Dow*, quanto aos padrões de comportamento deste mercado.

### **1.3 Organização do Texto**

O restante deste trabalho está organizado da seguinte maneira: o Capítulo 2 apresenta o referencial teórico sobre o mercado de ações, algoritmos de classificação, e estado da arte; no Capítulo 3 é apresentada a metodologia, com o detalhamento do sistema proposto e versão desenvolvida para avaliação, configuração dos experimentos, parâmetros de referência adotadas na comparação dos resultados, e métricas de avaliação; no Capítulo 4 são apresentados os resultados e feita a discussão sobre o desempenho do sistema desenvolvido, bem como dos parâmetros de referência adotados; no Capítulo 5 são feitas as conclusões; e a revisão sistemática da literatura, desempenhada como parte deste trabalho, é apresentada no Apêndice A.

## 2 REFERENCIAL TEÓRICO

Neste capítulo são descritos conceitos relativos ao mercado de ações, estratégias de negociação com algoritmos, Hipótese do Mercado Eficiente, teoria de *Dow*, tipos de análise Fundamentalista e Técnica, algoritmos para classificação de dados, e técnicas para seleção de características. Ao final do capítulo é apresentado o estado da arte tomado como referência.

### 2.1 Mercado de Ações

Ações são ativos financeiros que representam parte do capital próprio de uma corporação (TEWELES; BRADLEY, 1998; BM&FBOVESPA, 2017). Uma ação constitui a menor fração do capital da empresa emissora, e são conversíveis em dinheiro por meio da negociação em Bolsa de Valores ou Mercado de Balcão (BM&FBOVESPA, 2017). No Brasil, as ações podem ser de dois tipos: (i) ordinárias, as quais proporcionam participação nos resultados da empresa e conferem ao acionista direito de voto em assembleias; e (ii) preferenciais, que garantem ao acionista prioridade no recebimento dos dividendos, e no reembolso de capital, em caso de dissolução da sociedade (BM&FBOVESPA, 2017).

A negociação de ações é feita por meio de distribuição primária ou secundária. O processo de negociação inicial das ações, onde a empresa emissora vende suas ações aos investidores, é chamado mercado primário, ou distribuição primária (TEWELES; BRADLEY, 1998; BM&FBOVESPA, 2017). Qualquer negociação subsequente à oferta primária de ações é denominada distribuição secundária (TEWELES; BRADLEY, 1998; BM&FBOVESPA, 2017). Desta maneira, pode-se dizer que qualquer negociação de ações feita em Bolsa de Valores são, por natureza, provenientes de distribuição secundária (TEWELES; BRADLEY, 1998). Isto significa que, quando um investidor compra ações de determinada empresa, o dinheiro vai para o investidor detentor das ações, e não para a empresa.

O processo de abertura de capital, com a emissão de ações por parte das empresas, constitui importante instrumento para levantamento de capital para estas corporações (TEWELES; BRADLEY, 1998; BM&FBOVESPA, 2017). A emissão de novas ações pode ser feita por meio de financiamento de projetos de expansão, o que provê aumento do capital próprio empresarial, com admissão de novos sócios (BM&FBOVESPA, 2017).

No Brasil, ações podem ser negociadas em Bolsa de Valores ou em Mercado de Balcão. O termo Mercado de Balcão refere-se a qualquer tipo de negociação de títulos e valores mobiliários, efetuada fora da Bolsa de Valores, sob fiscalização da Comissão de Valores Mo-

biliários (CVM) (BM&FBOVESPA, 2017; BUSSOLA, 2017). Bolsas de valores são instituições que administram mercados, organizados e regulamentados, de títulos, valores mobiliários (ações de empresas, moedas, etc.) e contratos derivativos, negociados a preços controlados pela força resultante entre oferta e demanda (BM&FBOVESPA, 2017; WEBFINANCE, 2017). Fundada em 1890, a Bolsa de Valores, Mercadorias e Futuros de São Paulo (BM&FBovespa) (BM&FBOVESPA, 2017), é a única em operação atualmente no Brasil, e constava em janeiro de 2017 com 349 empresas cadastradas<sup>1</sup>. Bolsas de valores estão presentes em várias partes do mundo, a exemplo da bolsa de Amsterdam (*Euronext Amsterdam*), fundada em 1602, e a bolsa de Nova Iorque (NYSE - *New York Stock Exchange*), fundada em 1792.

A liquidez das ações — facilidade de conversão do ativo financeiro em dinheiro (HILLIER et al., 2014) — constitui um fator importante para atração de investidores. Diante disto, muitas empresas contratam pessoas jurídicas, denominadas formadores de mercado (*market-maker*)<sup>2</sup>, para realização de compras e vendas de suas ações, no intuito de manter a liquidez (BM&FBOVESPA, 2017). A BM&FBovespa também permite a atuação de formadores de mercado independentes. A formação de mercado é comumente desempenhada com a utilização de robôs de alta frequência (HFT - *High-Frequency Trading*) (ALDRIDGE, 2010).

Durante o funcionamento do mercado (pregão), é comum observar uma variação constante nos preços das ações. É importante destacar que o preço divulgado constitui apenas um histórico, referente ao valor das últimas negociações efetuadas naquele patamar. Não se pode garantir que novos negócios serão feitos no preço divulgado, pois a variação e direção dos preços depende do equilíbrio entre compradores e vendedores. O impasse entre estas duas partes resulta em um *bid-ask spread*, que diz respeito à diferença entre o maior preço em que um comprador esteja disposto a pagar (*bid*) e o menor preço em que um vendedor esteja disposto a vender (*ask*) (TEWELES; BRADLEY, 1998; ALDRIDGE, 2010). Percebe-se então que o preço não é ajustado pelo resultado simples entre oferta e demanda, mas quando uma das partes, ou ambas, se reposiciona. Desta forma, a cotação tende a ser alterada a todo instante, na direção em que os negócios fluírem.

---

<sup>1</sup> BM&FBOVESPA. **Valor de mercado das empresas listadas.** 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/servicos/market-data/consultas/mercado-a-vista/valor-de-mercado-das-empresas-listadas/bolsa-de-valores/](http://www.bmfbovespa.com.br/pt_br/servicos/market-data/consultas/mercado-a-vista/valor-de-mercado-das-empresas-listadas/bolsa-de-valores/)>. Acessado em 4 de março de 2017.

<sup>2</sup> BM&FBOVESPA. **Sobre o formador de mercado.** 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/servicos/formador-de-mercado/como-funciona/](http://www.bmfbovespa.com.br/pt_br/servicos/formador-de-mercado/como-funciona/)>. Acessado em 4 de março de 2017.

Como pode ser notado, a movimentação do mercado é resultante do processo de tomada de decisão das partes envolvidas. Além dos fatores inerentes ao próprio comportamento humano, é necessário considerar a volatilidade adicional resultante da atuação de robôs, como por exemplo os robôs de alta frequência *High-Frequency Trading* (HFT) (ALDRIDGE, 2010). De acordo com Gregoriou (2015), embora tragam maior liquidez e contribuam para um menor *bid-ask spread*, HFTs influenciam no aumento da volatilidade e trazem maior risco de manipulação ao mercado.

Pode-se dizer que o universo de fatores capazes de influenciar a formação do preço de uma ação é indeterminado. Por exemplo, de acordo com DeFusco et al. (2011), o preço da ação de uma empresa com participação pública pode ser influenciado por: fatores macroeconômicos; níveis de gastos governamentais; ciclos econômicos; etc. Além de questões inerentes à própria empresa, tais como: lucratividade; dívidas; políticas de distribuição de dividendos; governança corporativa; etc. Inúmeros fatores, associados a questões psicológicas dos investidores, e atuação de robôs, tornam a precificação acionária algo muito imprevisível.

Independentemente das oscilações constantes no preço, é notável que ações possuem certo valor intrínseco, pois representam parte do capital próprio de uma empresa. O seu detentor possui direitos, dentre os quais estão: (i) participação nos lucros em forma de dividendos ou juros sobre capital próprio; (ii) preferência para subscrição de ações; (iii) participar do acervo da companhia, em caso de liquidação; dentre outros. O Brasil regulamenta este mercado através da lei 6404/76<sup>3</sup>, denominada lei das Sociedades Anônimas. Além dos direitos garantidos ao investidor, há também que se levar em consideração a possibilidade de crescimento e aumento dos lucros da empresa, o que geralmente resulta em maior procura por suas ações e consequente valorização.

### 2.1.1 Especulação

No contexto financeiro, o termo "especulação", de acordo com o dicionário Oxford (2017), diz respeito aos tipos de investimento onde haja expectativa de lucro, mas com risco de prejuízo. Segundo esta definição, quase todos os investimentos, mesmo aqueles de baixo risco, são considerados especulativos. Como relatado por Szado (2011), não há uma definição precisa quanto aos termos "especulação" ou "especulação excessiva", podendo variar muito en-

<sup>3</sup> **LEI No 6.404, DE 15 DE DEZEMBRO DE 1976.** Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/leis/L6404compilada.htm](http://www.planalto.gov.br/ccivil_03/leis/L6404compilada.htm)>. Acessado em 4 de março de 2017.

tre as fontes de pesquisa. No presente trabalho, e levando-se em consideração o investimento em ações, é considerada atividade de especulação qualquer tipo de negociação sobre ativos do mercado acionário, a exceção do emprego de *Buy-and-Hold* (B&H) — estratégia de investimento de longo prazo onde a ação é mantida por tempo indeterminado (DEVI; SUNDAR; ALLI, 2013).

Diante da possibilidade de ganhos a partir da oscilação constante nos preços das ações, a especulação financeira consiste em uma prática comum e antiga no mercado acionário, como já relatado por Nelson (1912) e Hamilton (1922). É considerado que a especulação excessiva pode resultar em flutuações não condizentes com a realidade (CFTC, 2017), podendo levar a bolhas especulativas (HILLIER et al., 2014), mas no geral, a atuação deste tipo de participante é de grande importância, pois contribui para o aumento da liquidez (BEKAERT; HARVEY, 2000; HILLIER et al., 2014). E como apontado por Keynes (1923) e Hicks (1946), especuladores exercem importante papel no compartilhamento do risco com investidores *Hedge*, que buscam proteção frente à volatilidade do mercado. E ainda como sugerido por Grossman e Stiglitz (1980) e Grossman (1995), atividades especulativas aumentam a velocidade com que o preço se ajusta às informações, ou seja, contribuem para o aumento da eficiência do mercado.

### **2.1.2 Venda a Descoberto**

Venda a Descoberto (SL - *Short Sell*) consiste em um mecanismo que possibilita ao especulador a venda de ativos que não possui (ASNESS; FABOZZI, 2004; REILLY; BROWN, 2011). Para que isto seja possível, é necessário que as ações tenham sido anteriormente alugadas de outro investidor (ASNESS; FABOZZI, 2004) — no Brasil, o aluguel não é necessário para operações de SL iniciadas e finalizadas em um mesmo dia (DT - *Day Trade*) (XPI, 2017). O encerramento de uma operação de SL ocorre na compra da mesma quantidade de ações vendidas inicialmente. A diferença de preço, sem considerar taxas, entre os valores de venda e compra, constituirá o lucro ou prejuízo do investidor. Após o encerramento da operação de SL, as ações podem ser devolvidas ao doador, que receberá também os valores referentes à taxa de aluguel negociada (XPI, 2017). Operações de venda a descoberto possibilitam ao especulador a obtenção de lucros, mesmo com a desvalorização do ativo. Este tipo de operação é comum no contexto do mercado acionário, como já relatado por Nelson (1912).

Como mencionado por Asness e Fabozzi (2004), este tipo de atuação possui papel importante no mercado acionário. Investidores mais atentos conseguem identificar ativos super-



valorizados, e a sua atuação contrária ao movimento principal contribui para a eficiência do mercado, tornando o ambiente mais seguro para todos os participantes (ASNESS; FABOZZI, 2004). Sem operações de SL, a única maneira de expressar sentimento negativo seria não comprando ativos, e desta maneira os preços se mostrariam enviesados a olhares otimistas (ASNESS; FABOZZI, 2004).

### 2.1.3 Estratégias de Negociação com Algoritmos Computacionais

Um algoritmo pode ser definido como um conjunto finito de regras a serem seguidas para solução de um problema (PRESS, 2016). Já um algoritmo computacional diz respeito ao conjunto de regras desempenhadas por um computador, para solução de um problema qualquer. De acordo com a abordagem de Aldridge (2010), algoritmos computacionais que implementam estratégias de negociação de ativos em mercado acionário podem ser agrupados nas duas categorias a seguir:

- algoritmos de alta-frequência (HFT - *High-Frequency Trading*): são, segundo a NASDAQ (2016), algoritmos proprietários que podem operar de duas maneiras distintas: (i) através da segmentação de grandes ordens de compra ou venda em ordens menores, a fim de obter o melhor preço possível; (ii) ou em busca de pequenas oportunidades de lucro nas constantes movimentações de ativos no mercado. Este último tipo depende diretamente da baixa latência de comunicação com a bolsa de valores, sendo comum a execução de várias ordens com intervalo de poucos microssegundos (LEWIS, 2014). Ainda de acordo com Aldridge (2010), HFT trata-se de uma metodologia de operação fundamentada em análise quantitativa, incorporada em sistemas computacionais de processamento de dados, os quais efetuam decisões de operações em altas velocidades e com alta frequência, sem no entanto manter posições em aberto de uma dia para o outro. Desta maneira, pode-se afirmar que os algoritmos de alta-frequência mais rápidos, e com menor latência de comunicação, possuem maior chance de sucesso;
- algoritmos de baixa-frequência (LFT - *Low-Frequency Trading*): não foi encontrada uma definição formal para LFT, sendo portanto qualquer tipo de operação com algoritmo, que não seja do tipo HFT. Diferem-se dos algoritmos de alta-frequência principalmente pela elevada rotatividade de capital em curto espaço de tempo promovidos pelos HFTs, quando comparados com os LFTs (ALDRIDGE, 2010). Ainda de acordo com Aldridge (2010),

algoritmos HFTs são caracterizados por um maior número de negócios, e ganho reduzido por operação, enquanto algoritmos de baixa-frequência buscam maior retorno por operação, mas em número reduzido de atuações. Outro ponto de contraste entre HFT e LFT é quanto à regularidade no espaçamento de dados históricos de negociação. Algoritmos de negociação em alta-frequência trabalham com *tick-data*, que são informações de cotações que podem chegar de forma aleatória em espaços de tempo muito curtos (ALDRIDGE, 2010). Já os dados de negociação empregados por algoritmos LFT são regulares e sequenciais (ALDRIDGE, 2010).

Tanto algoritmos HFT quanto LFT, além de informações de movimentação do próprio mercado (análise técnica), podem utilizar outras fontes de informação, como por exemplo: dados fundamentalistas; de outros mercados; notícias; etc.

Algoritmos de negociação em alta-frequência possuem natureza autônoma (ALDRIDGE, 2010), ou seja, realizam operações diretamente no mercado, sem interferência humana. Já algoritmos de negociação em baixa-frequência podem operar de forma autônoma, ou apenas auxiliando no processo de tomada de decisão do investidor, através da identificação de oportunidades.

#### **2.1.4 Hipótese do Mercado Eficiente**

A Hipótese do Mercado Eficiente (HME) diz respeito à eficiência do mercado em refletir nos preços das ações, quaisquer tipos de informações relevantes, tais como: notícias; padrões de movimentação histórica; previsões de comportamento; relatórios econômicos; expectativa de crescimento da empresa e distribuição de dividendos; dentre outros (FAMA, 1965; FAMA, 1970). Se há eficiência de mercado, então qualquer estratégia baseada em informações históricas não conseguirá um retorno financeiro líquido consistente superior a uma simples estratégia *Buy-And-Hold* (FAMA, 1970). É ainda afirmado por Fama (1970), que o comportamento dos preços segue um modelo aleatório (*random walk*), ou seja, a cotação subsequente é aleatória em relação ao histórico, portanto imprevisível. É afirmado por Copeland e Weston (1988), que se o mercado mostrar-se eficiente, o preço da ação constituirá um sinal efetivo e suficiente para alocação de capital por parte dos investidores. Para Asness e Fabozzi (2004), eficiência de mercado seria o resultado do sentimento coletivo, em algum ponto entre otimismo e pessimismo. Fama (1970) define a noção de eficiência de mercado em três hipóteses:

- fraca: nesta hipótese, é considerado não ser possível auferir lucros excessivos consistentes a partir de regras de negociação baseadas em qualquer tipo de movimentação histórica do mercado. Ou seja, isoladamente, dados históricos são inúteis para o investidor;
- semi-forte: esta hipótese assume não ser possível auferir lucros excessivos consistentes a partir de qualquer tipo de informação de conhecimento público. Esta hipótese inclui, além do histórico de cotações e retornos do ativo, qualquer informação óbvia disponibilizada publicamente, tais como: relatórios anuais da empresa, anúncios de desdobramento acionário, etc.;
- forte: esta hipótese assume que nenhum investidor conseguirá auferir lucro excessivo consistente a partir de qualquer tipo de informação, seja ela de conhecimento público ou não.

A eficiência perfeita do mercado acionário, de acordo com Fama (1970) e Fama (1991), é esperada em um ambiente igualitário, onde: (i) não existam custos financeiros transacionais; (ii) todas as informações sejam gratuitas e disponíveis a todos os envolvidos; e (iii) todos concordem em mesmo grau de relevância quanto às informações existentes. Embora este ambiente igualitário seja o ideal para uma perfeita eficiência de mercado, Fama (1970) afirma que, no geral, o mercado acionário mostra-se eficiente mesmo na ausência destas condições.

Fama (1970) não encontra evidências empíricas suficientemente fortes contra as hipóteses "fraca" e "semi-forte", e apenas evidências limitadas contra a hipótese "forte". Ou seja, o mercado mostra-se muito eficiente quanto às informações óbvias de conhecimento público. Ainda de acordo com Fama (1970), devido às evidências limitadas contra a hipótese "forte", o acesso privilegiado às informações não constitui um fenômeno que se prevaleça no mercado. As pesquisas e evidências apresentadas por Fama (1970) são muitas vezes contestadas, como por exemplo, Copeland e Weston (1988) afirmam que a hipótese "forte" é improvável, pois evidências empíricas revelam que *insiders* — pessoas com acesso privilegiado a informações estratégicas — muitas vezes conseguem retornos anormais. Mas como já relatado por Hamilton (1922), alinhando-se às conclusões de Fama (1970), a obtenção de vantagem financeira por *insiders* não constitui regra, pois nem sempre é possível antever a reação do mercado frente às novas informações.

A atuação de robôs HFT têm aparentemente mostrado ineficiência do mercado quanto à hipótese "forte", ao menos no mercado norte americano. Lewis (2014) cita evidências que apon-

tam para a atuação de robôs HFT, chegando a representar mais de 50% das transações diárias do mercado norte americano a partir de meados de 2006. Muitos destes robôs, segundo Lewis (2014), conseguem lucros elevados, e sem risco, por meio de práticas ilícitas denominadas *front running*.

Outra questão relevante é quanto ao meio de obtenção de informações para a realização de análises e previsões, podendo ser por meio público, onde não há custo, ou por meio privado, com algum custo. Cornell e Roll (1981) afirmam que, na média, indivíduos que se utilizam de informações pagas devem conseguir um retorno superior àqueles que não utilizam, mas apenas na forma de lucro bruto, o lucro líquido de ambos tende a ser o mesmo. Copeland e Weston (1988) apresentam evidências empíricas que vão de encontro a esta afirmação. Desta forma, estes autores afirmam que o mercado é eficiente quanto à existência de informações disponíveis à comunidade, sejam estas gratuitas ou não.

A hipótese do mercado eficiente é alvo de inúmeras contestações. Vários autores publicaram trabalhos com evidências empíricas contra à HME, sendo o foco principal da crítica o tempo de reação do mercado às informações. De acordo com Jegadeesh e Titman (1993), se os preços das ações refletirem de forma precipitada ou tardia o valor das informações, então estratégias de investimento baseadas no histórico de retorno podem ser rentáveis. Foi relatado por Jegadeesh e Titman (1993) algumas evidências empíricas com resultados positivos na utilização de estratégias baseadas no seguimento de tendência a curto prazo. Ainda de acordo com Jegadeesh e Titman (1993), as evidências indicam um certo atraso da cotação em relação a algumas informações específicas. Já Michaely, Thaler e Womack (1995) indicam casos em que o mercado se mostrou lento ao assimilar informações quanto ao pagamento de dividendos por parte das empresas.

Fama (1998) afirma que, no mercado acionário, retornos financeiros anormais tendem a ser nulos, mas que eventualmente pode-se observar ocasiões onde informações foram sub ou sobre-estimadas, causando distorções momentâneas nos preços. Ocasões de sub ou sobrevalorização ocorrem aleatoriamente, e em proporções semelhantes, o que inviabilizaria a utilização de estratégias baseadas em eventos desta natureza (FAMA, 1998).

Diversos economistas e estatísticos consideram que a movimentação do mercado acionário é parcialmente previsível (MALKIEL, 2003), podendo proporcionar o emprego de estratégias de investimento economicamente viáveis. Ainda de acordo com Malkiel (2003), uma nova

geração de economistas enfatizam a importância de fatores psicológicos e comportamentais na determinação dos movimentos deste mercado.

### 2.1.5 Teoria de Dow

No final do século 19 e início do século 20, Charles Henry Dow publicou no jornal de *wall street* (*The Wall Street Journal*) vários editoriais que rerepresentavam o seu ponto de vista em relação ao comportamento do mercado acionário, nunca chegando a escrever um livro sobre o assunto. Após sua morte em 1902, suas ideias passaram a ser estudadas e refinadas por Samuel Armstrong Nelson e William Peter Hamilton, que publicaram respectivamente os livros *The ABC of stock speculation* (1912) e *The Stock Market Barometer* (1922). Além do seu livro, Hamilton publicou diversos editoriais no jornal de *wall street*, que ajudaram a compreender melhor as publicações de Dow. Em 1932 Robert Rhea publicou o livro *The Dow Theory*, que através das análises do conteúdo disponível até aquele momento, definiu pela primeira vez de forma clara a teoria de Dow. Segundo Rhea (1932), a teoria de Dow é composta por 6 princípios:

- o mercado possui três movimentos: Dow mostra que existem simultaneamente três movimentos, ou tendências, em progresso no mercado acionário. O maior e mais importante é o movimento primário (ou principal), que pode durar de um a vários anos. O movimento primário pode ser ascendente (*bull market*) ou descendente (*bear market*). No curso do movimento primário ocorrem os movimentos secundários, representados por movimentações acentuadas, contrárias à tendência principal (recebem o nome de rali quando a tendência principal é de baixa, e de correção em caso contrário), podendo durar de 10 dias a 3 meses. Dow identificou que os movimentos secundários, na maioria dos casos, retrocedem de 33% a 66% do movimento principal desde o seu início ou desde o último movimento secundário (RHEA, 1932; EDWARDS; MAGEE; BASSETTI, 2007). Simultaneamente aos movimentos primários e secundários ocorrem os movimentos terciários, que para Dow são as oscilações ocorridas de um dia para o outro. O movimento terciário pode durar alguns dias ou até 3 semanas, e são pequenos movimentos que ocorrem contra a tendência primária ou secundária. Dow afirma que a tendência terciária é a única passível de algum tipo de manipulação, o que seria improvável para as tendências primária e secundárias. Edwards, Magee e Bassetti (2007) afirmam que nas condições atuais de mercado, seria improvável manipulação em qualquer uma das tendências;
- a tendência primária é composta por três fases distintas:

1. **acumulação:** período em que os investidores com maior percepção iniciam as operações de compra ou venda, indo contra a opinião geral sobre o estado do mercado. Durante este estágio os preços não oscilam muito, os grandes investidores absorvem aos poucos a demanda generalizada. Como este estágio consiste na reversão da tendência principal anterior, pode ser difícil distingui-lo de um movimento secundário. Quando a tendência em formação é de alta (*bull market*), esta fase ocorre meio a um forte ambiente de pessimismo, normalmente muito elevado no final de uma longa tendência de baixa. Já quando a tendência em formação é de baixa (*bear market*), a primeira fase ocorre meio à enorme euforia e otimismo do público em geral, com notícias positivas e percepção otimista generalizada quanto à economia e ao mercado. Enquanto o público em geral compra avidamente, grandes investidores mais atentos realizam lucros e iniciam operações de venda a descoberto;
2. **participação:** esta fase ocorre quando analistas técnicos e seguidores de tendências percebem a formação de uma nova tendência primária e iniciam sua participação no mercado, dando mais força ao movimento. Esta é normalmente a fase mais longa e com maior alteração nos preços. Quando a tendência primária em formação é de alta, os preços das ações sobem, coincidindo com a melhoria geral do ambiente econômico e aumento no desempenho das empresas. À medida em que o mercado melhora e as ações aumentam de preço, mais investidores entram no mercado, elevando ainda mais as cotações. Já nos casos onde a tendência principal é de baixa, nesta fase já ocorre a percepção de deterioração do ambiente econômico em geral, sem perspectivas claras de recuperação. Os preços caem à medida em que os investidores se desfazem de suas ações, e efetuam operações de venda a descoberto;
3. **distribuição:** quando a tendência primária é de alta, esta fase é marcada pelo excesso, euforia e grande participação do público, movido pela percepção de prosperidade e veiculação de notícias positivas. O mercado acionário parece próspero a todos. É uma fase marcada pela elevada especulação e forte movimento ascendente nos preços. Investidores mais atentos percebem a possível saturação da tendência primária. Porém, na percepção do público em geral, o mercado continuará se valorizando indefinidamente. Cada vez mais, as pessoas se mostram interes-

sadas em participar, inflando o mercado até um ponto em que a manutenção dos preços se torna insustentável. O efeito da supervalorização acionária decorrente da procura excessiva é referenciado como "exuberância irracional" (SHILLER, 2015). Em mercados com tendência primária em queda, esta fase é marcada pelo pânico generalizado, acompanhado por fortes oscilações dos ativos. Frente às consecutivas quedas nos preços, acompanhadas pela veiculação de notícias negativas sobre a situação e rumos da economia, a grande massa, em pânico, se desfaz de suas ações, deteriorando cada vez mais os preços. A fase continua até o ponto em que o público em geral já se encontra fora do mercado, a maioria em grande prejuízo pois compraram na euforia da tendência principal anterior. No momento em que tudo parece ruim, com o mercado acionário desvalorizado e um ambiente econômico negativo, os grandes investidores iniciam suas compras. Dando início à fase de acumulação. O ciclo é então reiniciado;

- o mercado reflete tudo: de acordo com Rhea (1932), a teoria de *Dow* assume que o mercado reflete imediatamente qualquer nova informação relevante. Esta afirmação está de acordo com a HME proposta alguns anos depois por Fama (1970). Ainda de acordo com Hamilton (1922), *Dow* assume também que o mercado representa tudo a cerca de todos os participantes, como o conhecimento, expectativas, crenças, previsões, etc. Enfim, a cotação representa todos os possíveis fatores disponíveis até aquele momento, inclusive perspectivas futuras;
- os índices devem se confirmar: na época em que a teoria foi desenvolvida, os índices *Dow Jones Industrial Average* (DJIA) e *Dow Jones Transportation Average* (DJTA) reuniam as mais importantes empresas dos setores industrial e transporte respectivamente. *Dow* observou que a indústria precisava transportar a sua matéria prima e seus produtos acabados, normalmente por meio de trilhos (HAMILTON, 1922; RHEA, 1932). Portanto, uma tendência não poderia acometer o setor industrial sem antes ser iniciada no setor de transportes (HAMILTON, 1922; RHEA, 1932). Pois antes mesmo de vender os produtos, a indústria precisava transportar a sua matéria prima, logo o setor de transportes iniciava o crescimento, ou retração, antes do setor industrial. *Dow* concluiu que, para uma tendência ser considerada verdadeira ela deveria ser confirmada em ambos os índices (HAMILTON, 1922; RHEA, 1932);

- as tendências são confirmadas pelo volume: de acordo com a teoria, embora os movimentos nos preços sejam suficientes para identificar uma tendência, o aumento do volume de ativos negociados auxilia na confirmação (RHEA, 1932; EDWARDS; MAGEE; BASSETTI, 2007). É esperado que o volume mantenha-se elevado enquanto os preços se movem em direção à tendência principal, e que diminua caso contrário. Segundo Reilly e Brown (2011), analistas técnicos consideram o aumento do volume, juntamente com a movimentação do mercado, um sinal de força do movimento;
- a tendência principal existe até que sinais definitivos provem o contrário: a teoria de *Dow* afirma que durante o curso de uma tendência primária, diversos movimentos contrários podem ocorrer, mas que em algum momento a tendência principal será retomada (RHEA, 1932). Portanto, a tendência primária estará em andamento até que uma nova tendência contrária seja claramente identificada;

### 2.1.6 Análise Fundamentalista

A Análise Fundamentalista (AF) tem como base de estudos fatores econômicos que possam influenciar o desempenho empresarial (MURPHY, 1999; REILLY; BROWN, 2011). Neste tipo de análise, quaisquer fatores internos e externos à empresa podem ser levados em conta, desde perspectivas de desenvolvimento próprio da companhia, a questões de desempenho industrial do setor ou país de atuação (MURPHY, 1999; REILLY; BROWN, 2011). Desta maneira, a análise fundamentalista busca definir, tendo como base fatores econômicos subjacentes, o valor intrínseco, ou justo, de uma ação, bem como o seu potencial de desempenho futuro.

Para a AF, o cálculo do valor intrínseco pode envolver diversos fatores, tais como: patrimônio líquido, taxa de crescimento da empresa, taxa de valorização acionária, perspectivas da distribuição de lucros, perspectiva de aumento do lucro, taxa de endividamento, fluxo de caixa, capacidade de crescimento do setor de atuação, perspectivas futuras quanto ao mercado econômico, variáveis de risco, dentre outros.

Pode-se identificar dois tipos de perfis de atuação neste tipo de análise:

- investidores *Buy-and-Hold*: adquirem ações de companhias consideradas promissoras, segundo suas análises. Geralmente só desfazem destas ações no momento em que a empresa deixa de atender a seus requisitos e expectativas. Momentos de crise financeira podem ser vistas como oportunidade para aquisição de mais ações, pois estas podem se tornar baratas em relação ao valor intrínseco calculado;



- especuladores: buscam a obtenção de lucro a partir da discrepância entre o preço de cotação e o valor intrínseco. As estratégias são construídas com base na diferença entre o valor intrínseco e a cotação no mercado, levando sempre em conta perspectivas futuras (NELSON, 1912; REILLY; BROWN, 2011). Se uma ação está subvalorizada, compra e aguarda até que a cotação alcance algum ponto de saturação. E caso o ativo mostre-se supervalorizado, podem atuar por meio de venda a descoberto.

Para Reilly e Brown (2011), discrepâncias entre cotação e valor intrínseco são ocasionais, sendo ligeiramente corrigidas pela intensa atuação de investidores. Ainda de acordo com Reilly e Brown (2011), somente conseguirá retorno financeiro significativo, a fração de investidores capazes de identificar tais divergências mais rapidamente.

Como já relatado por Nelson (1912), grandes investidores conseguem retornos anormais a longo prazo, através da identificação de oportunidades por meio da previsão precisa do comportamento futuro do mercado, tendo como base a abordagem fundamentalista. Neste sentido, Nelson (1912) ainda afirma que, independentemente das flutuações de curto prazo provenientes de especulação e manipulações, no longo prazo, são os investidores fundamentalistas quem determinam a direção do mercado.

De acordo com os conceitos da análise fundamentalista, pode-se concluir que:

- como os grandes investidores apoiam suas decisões em questões econômicas, tanto da empresa, quanto do ambiente, é esperado que no longo prazo o mercado acionário movimente-se de acordo com o desempenho econômico do ambiente;
- a empresa detém parcela de influência sobre a cotação das suas ações no mercado. Esta influência pode ser expressa pela própria capacidade de crescimento e lucratividade.

### **2.1.7 Análise Técnica**

No contexto do mercado de ações, Análise Técnica (AT) é um termo utilizado para definir a forma de análise onde assume-se que dados históricos provenientes da própria atividade do mercado, constituem a melhor fonte de informação para deduzir comportamento futuro (ROMEU; SERAJUDDIN, 2001; EDWARDS; MAGEE; BASSETTI, 2007; REILLY; BROWN, 2011). A análise técnica não considera nenhuma informação além daquelas geradas pelos próprios ativos (valores de cotação e volume), contrastando radicalmente com a análise fundamentalista. A ideia geral da AT consiste na construção de um conjunto de sinais sistemáticos,

capazes de apontar ao especulador os momentos propícios para entrada e saída de operações financeiras (ROMEU; SERAJUDDIN, 2001).

Alguns analistas técnicos afirmam ser inútil assimilar um valor intrínseco a uma ação, pois existem casos históricos onde, embora a empresa tenha mantido um desempenho estável, o preço da sua ação sofreu grande variação (EDWARDS; MAGEE; BASSETTI, 2007). Para a AT, o valor real de uma ação consiste na sua cotação atual, determinada única e exclusivamente pelas relações entre oferta e demanda, refletidas pelas transações realizadas na bolsa de valores (EDWARDS; MAGEE; BASSETTI, 2007). Ainda de acordo com Edwards, Magee e Bassetti (2007), além da influência resultante da atuação de fundamentalistas, as relações que determinam a formação do preço são resultado da atuação de inúmeros outros investidores sensíveis a fatores como: esperança, medo, humor, suposições, necessidades, etc. Pode-se assumir ainda que devido a própria natureza humana, muitos investidores cometam erros em detrimento de atitudes ilógicas, ou sejam influenciados por fatores irrelevantes (ROMEU; SERAJUDDIN, 2001).

A julgar pela quantidade de fatores envolvidos no processo de tomada de decisão, e quantidade de participantes, é natural esperar um comportamento caótico na movimentação do mercado. No entanto, Edwards, Magee e Bassetti (2007) afirmam ser perceptível através do histórico, que os preços se movimentem em tendências, e que a tendência se mantém até que algo modifique o balanceamento entre oferta e demanda. Ou seja, embora o mercado mostre-se volátil e caótico no curto prazo, é possível observar a existência de uma tendência principal, assim como relatado na teoria de *Dow*.

A análise técnica possui forte embasamento nos conceitos da teoria de *Dow*, como por exemplo, são premissas da AT:

- o mercado apresenta um comportamento cíclico (ROMEU; SERAJUDDIN, 2001; AGRAWAL; CHOURASIA; MITTRA, 2013);
- os preços movem-se em tendências, definidas pelas atitudes dos investidores, em resposta a diferentes forças (REILLY; BROWN, 2011; AGRAWAL; CHOURASIA; MITTRA, 2013; EDWARDS; MAGEE; BASSETTI, 2007);
- devido a características psicológicas, investidores reagem de forma previsível às oscilações do mercado (AGRAWAL; CHOURASIA; MITTRA, 2013; ROMEU; SERAJUDDIN, 2001);

- o volume de negociações acompanha a intensidade da tendência (EDWARDS; MAGEE; BASSETTI, 2007);
- a tendência uma vez estabelecida, tende a continuar forte (EDWARDS; MAGEE; BASSETTI, 2007).

A análise técnica assume que nem todos os participantes possuem acesso às mesmas informações o tempo todo, e que diferentes investidores podem reagir de formas distintas a uma mesma informação (ROMEU; SERAJUDDIN, 2001). Desta forma, os preços se moveriam em tendência à medida em que as informações são dissipadas pelas diferentes classes de investidores. Ainda de acordo com Romeu e Serajuddin (2001), o objetivo do analista técnico é detectar o surgimento de tendências, para então segui-las.

A análise técnica compreende um grande número de formas de operação e interpretação, a maioria baseada em gráficos compostos por indicadores estatísticos, gerados a partir de dados provenientes da própria movimentação do mercado.

Aproximadamente 90% dos principais negociadores de ações (*traders*) se apoiam nos conceitos da análise técnica (AGRAWAL; CHOURASIA; MITTRA, 2013). Embora amplamente utilizada, a AT recebe críticas pela elevada subjetividade, pois diferentes investidores podem interpretar um mesmo gráfico ou indicador, de maneiras distintas, chegando a conclusões divergentes (AGRAWAL; CHOURASIA; MITTRA, 2013). Os movimentos previstos pela AT não são garantidos, podendo falhar sem qualquer motivo aparente (ROMEU; SERAJUDDIN, 2001). Ainda assim é reconhecido que os elementos da análise técnica oferecem boa base de apoio à tomada de decisão, tanto pela análise visual quanto pela utilização de indicadores técnicos estatísticos. A observação do volume e da movimentação dos preços são suficientes para dar ao investidor um senso de direção do mercado, pois, de acordo com Romeu e Serajuddin (2001), estes são ótimos indicadores sobre a situação das condições de equilíbrio entre oferta e demanda.

De acordo com Murphy (1999), as análises técnica e fundamentalista buscam o mesmo objetivo: determinar a direção provável dos preços futuros. Estas estratégias apenas abordam o problema de perspectivas distintas. Enquanto fundamentalistas estudam as causas e motivos dos movimentos do mercado, analistas técnicos buscam o efeito. Para estes últimos, as razões que levaram aos efeitos são irrelevantes.

### 2.1.7.1 Indicadores Técnicos

Indicadores técnicos consistem em cálculos matemáticos efetuados a partir dos dados de movimentação histórica do próprio mercado (MURPHY, 1999; EDWARDS; MAGEE; BASSETTI, 2007). Para estes cálculos, são utilizados os valores de movimentação básicos: "abertura", "máxima", "mínima", "fechamento", e "volume" de ativos negociados. Estes indicadores produzem dados numéricos que podem ser analisados visualmente, sendo geralmente plotados junto aos gráficos de cotações históricas (MURPHY, 1999).

A média móvel (MM) é uma técnica utilizada para exibição de valores médios de cotação, dentro de um período estabelecido (ROMEU; SERAJUDDIN, 2001). É um indicador técnico antigo, mas ainda amplamente utilizado para análise de movimentos do mercado (EDWARDS; MAGEE; BASSETTI, 2007). Tal indicador auxilia na identificação de tendências, e demonstra capacidade de suavização de ruídos derivados da volatilidade (ROMEU; SERAJUDDIN, 2001). Existem diversos tipos de médias móveis, de acordo com Murphy (1999) e Edwards, Magee e Bassetti (2007), as mais utilizadas são:

- média móvel simples (SMA - *Simple Moving Average*): este é o tipo de média móvel mais comum e geralmente a mais utilizada por analistas técnicos (EDWARDS; MAGEE; BASSETTI, 2007). Uma SMA é calculada através da média aritmética das  $n$  últimas cotações do ativo (MURPHY, 1999; ROMEU; SERAJUDDIN, 2001);
- média móvel ponderada (WMA - *Weighted Moving Average*): neste tipo de média, cada valor é multiplicado por um fator de ponderação (ROMEU; SERAJUDDIN, 2001). É geralmente calculada de forma que os valores mais recentes tenham mais influência sobre o resultado (ROMEU; SERAJUDDIN, 2001; EDWARDS; MAGEE; BASSETTI, 2007);
- média móvel exponencial (EMA - *Exponential Moving Average*): este tipo de média é uma forma de WMA, pois atribui maior peso aos valores recentes (MURPHY, 1999; EDWARDS; MAGEE; BASSETTI, 2007). A diferença entre WMA e EMA, é que esta última utiliza um valor de diferença exponencial entre os fatores de ponderação (EDWARDS; MAGEE; BASSETTI, 2007).

Médias ponderadas potencializam os efeitos de variações recentes, o que as tornam mais sensíveis que médias móveis simples (EDWARDS; MAGEE; BASSETTI, 2007). Esta característica deve ser observada com cautela, pois, de acordo com Murphy (1999), médias móveis mais lentas apresentam maior confiabilidade quanto à identificação de tendências.

Como afirmado por Romeu e Serajuddin (2001), estratégias com médias móveis funcionam muito bem somente quando o ativo possui tendência principal de alta ou baixa. Para mercados em movimentação lateral, no entanto, estratégias baseadas em médias móveis tendem a falhar (ROMEU; SERAJUDDIN, 2001).

Diversos outros indicadores podem ser calculados a partir dos dados de movimentação do ativo. Basicamente, os indicadores técnicos pode ser dos seguintes tipos:

- momento: indicadores que buscam captar mudanças entre otimismo e pessimismo dos participantes do mercado, refletidas nas alterações de preços (ROMEU; SERAJUDDIN, 2001). Estes indicadores acompanham a taxa de variação dos preços e contribuem para a identificação da velocidade de mudança da informação em análise, auxiliando na identificação de áreas de saturação de venda ou compra (WILLIAMS, 1984). Desta forma, este tipo de indicador pode auxiliar na identificação do surgimento, continuidade, ou encerramento da tendência (ROMEU; SERAJUDDIN, 2001). Os indicadores de grande popularidade, que se enquadram unicamente nesta categoria são: *Rate of Change* (ROC) (APPEL; HITSCHLER, 1990), *Momentum* (WILDER, 1978), *Williams' %R* (WILLIAMS, 1979), e *Parabolic Stop And Reverse* (SAR) (WILDER, 1978);
- osciladores: são indicadores que flutuam, ou oscilam, sobre linhas fixas, indicando se o ativo encontra-se em estágio "sobrecomprado" (*overbought*) — supervalorizado — ou "sobrevendido" (*oversold*) — subvalorizado — (ROMEU; SERAJUDDIN, 2001). Grande quantidade de indicadores se enquadram nesta categoria, como por exemplo: *Relative Strength Index* (RSI) (WILDER, 1978), *Stochastic* (ACHELIS, 2000), *Moving Average Convergence/Divergence* (MACD) (ACHELIS, 2000), *Triple Exponential Average* (TRIX) (CHANDE; KROLL, 1994), *Aroon* (THOMSETT, 2010), dentre outros. Diversos osciladores, como os listados no exemplo, são também indicadores de momento, sendo portanto muitas vezes referenciados também como osciladores de momento;
- volatilidade: a volatilidade é dada pelo grau de oscilação no preço da ação. Alta volatilidade indica elevada variação no preço, o que naturalmente gera mais oportunidades de lucro, a um risco elevado. Basicamente, indicadores de volatilidade auxiliam na identificação de áreas com maior flutuação dos preços, provendo ao investidor meios para identificação de possível comportamento futuro. Alguns exemplos de indicadores nesta categoria estão: *Bollinger Bands* (BOLLINGER, 2001), *True Range* (TR) (CHANDE;

KROLL, 1994), *Average True Range* (ATR) (WILDER, 1978), *Variance* (TRADINGSO-LUTIONS, 2017), e *Standard Deviation* (STOCKCHARTS, 2017c);

Os indicadores mencionados acima são alguns dos mais tradicionais, não necessariamente os melhores. De acordo com Edwards, Magee e Bassetti (2007), é necessário cautela na utilização destes recursos, pois o excesso de informação técnica criada pela utilização de indicadores pode confundir a análise, impactando negativamente no resultado.

Indicadores técnicos, ou análise técnica estatística, têm sido utilizados na tentativa de prever tendências de mercado e descobrir oportunidades de negócios (EDWARDS; MAGEE; BASSETTI, 2007). Mas ainda de acordo com Edwards, Magee e Bassetti (2007), a utilização deste recurso para previsão do mercado acionário resulta em uma tarefa de alta complexidade, pois este mercado possui padrão de comportamento guiado, dentre outros fatores, principalmente por emoções humanas.

#### **2.1.7.2 Evidências Empíricas**

A análise técnica é criticada pela elevada subjetividade envolvida em seus fundamentos (LO; MAMAYSKY; WANG, 2000; AGRAWAL; CHOURASIA; MITTRA, 2013). Lo, Mamaysky e Wang (2000) citam por exemplo que as formas geométricas no histórico de movimentações podem muitas vezes ser reconhecidas apenas aos olhos de quem observa. Este problema também afeta a utilização de indicadores técnicos, pois um mesmo indicador pode ser interpretado de maneira distinta por diferentes analistas. Reilly e Brown (2011) ainda afirmam que o grande desafio enfrentado pela análise técnica consistem nos resultados empíricos apresentados pela HME. Como pode ser observado, a análise técnica conflita com a HME em sua hipótese fraca.

Várias pesquisas têm buscado verificar a eficiência de mercados acionários por meio da utilização de componentes da análise técnica. Por exemplo, no contexto de análise gráfica Lo, Mamaysky e Wang (2000) propõem a utilização de uma abordagem automatizada de regressão não-paramétrica por kernel para reconhecimento de padrões gráficos utilizados na AT. O modelo desenvolvido foi aplicado na análise de diversas ações americanas em atividade entre os anos de 1962 e 1996. Os autores verificaram que alguns padrões gráficos auxiliaram com informações incrementais, principalmente em ações da NASDAQ. No entanto, Lo, Mamaysky e Wang (2000) salientam que os resultados alcançados não implica em afirmar que a análise téc-

nica pode ser utilizada para alcançar retornos excessivos na negociação de ações, apenas indica que ela pode contribuir no processo de tomada de decisão.

Na mesma linha, o trabalho desenvolvido por Cervelló-Royo, Guijarro e Michniuk (2015) aborda a identificação do padrão gráfico *flag* (bandeira) como sinal de entrada. Para o reconhecimento do padrão foi utilizada uma matriz de pesos em que foram submetidos valores de cotação ("abertura" e "fechamento"). O experimento foi conduzido sobre dados intradiários de 15 minutos do índice DJIA, no período de maio de 2000 a novembro de 2013, totalizando 91307 registros. O melhor resultado alcançado pelo modelo no período foi de 180% sobre o capital inicial. Já o emprego de *Buy-and-Hold* simples sobre o índice DJIA apresentaria uma valorização de aproximadamente 50,17% para o mesmo período, o que, segundo os autores, comprovaria a ineficiência deste mercado. No entanto é necessário fazer algumas considerações. Primeiramente nota-se que os autores não contabilizaram custos transacionais. No experimento de maior retorno foram efetuadas 186 operações lucrativas, mais 1216 negativas (*stops*), totalizando 1402 transações de entrada (compra) mais 1402 de saída (venda). Então seria necessário contabilizar o custo de 2804 transações no período. A não contabilização dos custos envolvidos deixa dúvidas quanto à eficácia do modelo em superar a HME em sua hipótese fraca.

Já na aplicação de indicadores técnicos, o trabalho desenvolvido por Metghalchi, Chang e Garza-Gomez (2012) estuda a lucratividade na utilização de estratégias de negociação baseadas em 9 indicadores populares. O estudo foi conduzido no índice da bolsa de valores de Taiwan, no período de novembro de 1990 a agosto de 2010. Os indicadores foram combinados e utilizados em três estratégias de atuação distintas. Ao todo 66 configurações foram avaliadas. De modo geral, foi observado uma relação inversa entre a quantidade de indicadores técnicos combinados, e a lucratividade. Os autores chegam à conclusão que as técnicas possuem poder preditivo, mas não é fácil projetar uma estratégia capaz de superar o emprego de um simples B&H, após a contabilização dos custos operacionais. Embora tenham sido avaliadas 66 modelos, baseados em 6 indicadores, somente alguns foram capazes de superar o emprego de B&H.

Han, Yang e Zhou (2013) abordam a utilização de médias móveis como indicador técnico para sinal de negociação. Foi avaliada a aplicação da técnica no período de julho de 1963 a dezembro de 2009 entre diversos portfólios de investimento em ações do mercado norte americano. Dentre as configurações avaliadas, o melhor resultado foi atingido com uma média móvel de 10 períodos. Com esta configuração, a quantidade de operações chegou a 20% do total de dias do período, e cada operação foi mantida por cerca de 9 a 10 dias antes de ser encerrada. Na

comparação com B&H, os autores afirmam conseguir um retorno anual médio superior entre 8,42% e 18,7%. Foi constatado pelos autores que a técnica é capaz de gerar maior retorno em períodos de recessão que expansão.

Yu et al. (2013) avaliam a aplicação de médias móveis e da técnica *trading range breakout* (TRB) como indicadores de sinal de negociação. Foram avaliados cinco índices das bolsas de Singapura, Malásia, Indonésia, Filipinas e Tailândia, nos períodos de 1991 a 2008. O TRB emprega o conceito de linhas de suporte e resistência, onde o sinal de compra é gerado quando o preço de fechamento atual supera a máxima histórica (50, 150 ou 200 dias), e o sinal de venda quando o fechamento atual é menor que a mínima histórica. Já nas regras com médias móveis, o sinal de compra ou venda é dado pelo cruzamento das médias, uma de curto prazo (1, 2 ou 5 dias) e outra de longo prazo (50, 150 ou 200). Sem considerar os custos de operação, tanto MM e TRB conseguiram retornos significativos. Os resultados com TRB foram consistentemente superiores à utilização de médias móveis. No entanto, nenhuma das técnicas conseguiu superar o emprego de B&H após contabilização dos custos operacionais.

No trabalho desenvolvido por Neely et al. (2014), alguns indicadores técnicos são utilizados para previsão do prêmio de risco — recompensa por assumir risco (HILLIER et al., 2014) — para investimento em ações do mercado norte americano. Foram efetuadas comparações quanto à utilização de indicadores fundamentalistas (variáveis macroeconômicas) para o mesmo fim. Os resultados estatísticos e econômicos apresentam melhores desempenhos com a utilização de indicadores técnicos que fundamentalistas.

É importante destacar o trabalho de Park e Irwin (2007), em que são analisados mais de 100 trabalhos acerca da lucratividade na utilização de estratégias de negociação baseadas em análise técnica. Os autores agrupam os estudos em duas categorias: "antigos" (1960–1987) e "recentes" (1988–2004). Os estudos "antigos" indicam que estratégias baseadas em análise técnica são rentáveis em mercados *Foreign Exchange* (FOREX) e mercados futuros, mas não no mercado acionário. Já quanto aos resultados "recentes", estes indicam que estratégias de negociação baseadas em análise técnica foram capazes de gerar lucros consistentes no mercado acionário americano ao menos até o início da década de 1990, mas não além disto. De um total de 95 estudos "recentes", 56 apontam resultados positivos na utilização de análise técnica, 20 indicam desempenho negativo, e 19 apontam resultados mistos. Os autores ressaltam que embora as evidências indicam capacidade de sucesso quanto à utilização de estratégias de negociação baseadas em análise técnica, muitos estudos estão sujeitos a vários problemas quanto a seus



procedimentos de teste, como: *data dredging* (SMITH; EBRAHIM, 2002), dificuldades em estimar risco, e não contabilização de custos operacionais. Os resultados mostram que estratégias baseadas em análise técnica dificilmente sobrevivem à contabilização de custos transacionais.

## 2.2 Classificação de Dados

Classificação, segundo Tan et al. (2006), consiste na tarefa de organizar objetos em categorias pré-determinadas. Um algoritmo de classificação (classificador), de acordo com Herawan, Ghazali e Deris (2014), consiste em um procedimento para seleção de uma hipótese a partir de um conjunto de alternativas, de tal forma que a escolha melhor se adeque ao conjunto de dados utilizados para observação. O objetivo de um classificador consiste na construção de modelos que apresentem capacidade de prever as classes, ou categorias, de diferentes objetos (HERAWAN; GHAZALI; DERIS, 2014). Ainda de acordo com Sebastiani (2002), a tarefa de classificação tem por objetivo rotular, de forma automática, dados às categorias corretas.

Um classificador adquire conhecimento através do processo de aprendizagem. De acordo com (BISHOP, 1995), são três os paradigmas de aprendizagem existentes:

- supervisionado: é um paradigma de aprendizagem no qual o treinamento é conduzido com a utilização de valores alvo, onde, para cada entrada apresentada ao modelo, há um valor de saída desejado (BISHOP, 1995; HAYKIN, 1998);
- não-supervisionado: é um paradigma de aprendizagem no qual não são fornecidos valores alvo ao algoritmo (BISHOP, 1995; HAYKIN, 1998). Este paradigma é muito utilizado para clusterização através de agrupamento probabilístico (BISHOP, 1995). Valores similares com base em alguma medida estatística são agrupados em classes (BISHOP, 1995);
- por reforço: é um paradigma de aprendizagem cuja saída apresentada pelo modelo é avaliado segundo critérios pré-definidos de correto ou incorreto, sem, no entanto, informar o valor desejado (BISHOP, 1995).

A eficiência do classificador em categorizar corretamente amostras não pertencentes ao conjunto empregado no treinamento, traduz sua capacidade de generalização (BISHOP, 1995; MITCHELL, 1997). Desta forma, pode-se dizer que o objetivo final do treinamento consiste na maximização da capacidade de generalização do modelo (BISHOP, 1995).

### 2.2.1 Máquinas de Vetores de Suporte


Máquinas de Vetores de Suporte (SVM - *Support Vector Machines*) constituem uma técnica de aprendizado supervisionado, concebida por Cortes e Vapnik (1995). O algoritmo SVM consiste em um método de classificação binário, e possui embasamento na teoria de aprendizagem estatística de Vapnik (1995). O objetivo desta teoria é encontrar uma função matemática específica, capaz de classificar dados desconhecidos a partir de um conjunto de dados de treinamento (SCHÖLKOPF; SMOLA, 2002).

SVMs possuem capacidade de classificação linear de dados originalmente não linearmente separáveis (CORTES; VAPNIK, 1995; HEASRT et al., 1998; SCHÖLKOPF; SMOLA, 2002). Isto é possível pois o conjunto de dados originais é mapeado em um novo espaço de maior dimensão, denominado espaço de características (CORTES; VAPNIK, 1995; HEASRT et al., 1998; SCHÖLKOPF; SMOLA, 2002). SVMs, diferentemente de Redes Neurais Artificiais (MITCHELL, 1997), garantem que o hiperplano obtido na separação dos dados corresponde àquele de maior margem de afastamento (CORTES; VAPNIK, 1995; HEASRT et al., 1998). O hiperplano ótimo é aquele capaz de fazer a separação linear dos dados nesta nova dimensão (CORTES; VAPNIK, 1995; SCHÖLKOPF; SMOLA, 2002).

A Figura 2.1 apresenta um problema de classificação binária entre dois tipos objetos distintos, onde o hiperplano ótimo é representado pela linha sólida central (SCHÖLKOPF; SMOLA, 2002). Esta figura exhibe um vetor de pesos  $w$  e um limiar  $b$ , tal que  $y_i((w, x_i) + b) > 0$ , onde  $(i = 1, \dots, m)$ . Redimensionando  $w$  e  $b$ , de modo que os pontos mais próximos ao hiperplano satisfaçam  $|(w, x_i) + b| = 1$ , obtêm-se uma forma canônica de  $(w, b)$  relativa ao hiperplano, satisfazendo  $y_i((w, x_i) + b) \geq 1$ . A margem de separação, medida perpendicularmente ao hiperplano, neste exemplo, equivale a  $2/\|w\|$ . Isto pode ser observado ao considerar dois pontos  $x_1, x_2$ , em lados opostos da margem de separação, ou seja,  $(w, x_1) + b = 1$  e  $(w, x_2) + b = -1$ , e projetá-los sobre o vetor normal do hiperplano  $w/\|w\|$ .

Considerando que um conjunto de dados pode conter ruídos e *outliers* — valores atípicos —, podendo impossibilitar separação linear, mesmo em dimensões superiores, Cortes e Vapnik (1995) apresentam uma modificação no SVM que permite a existência de erros no conjunto de dados de treinamento. Esta modificação é denominada SVM de margens suaves (*soft margin*) (CORTES; VAPNIK, 1995). Desta forma, SVMs lineares podem ser empregados em problemas de classificação não linearmente separáveis.

Figura 2.1 – Hiperplano Ótimo e Margens de Separação Sobre um Problema de Classificação Binária.




Fonte: (SCHÖLKOPF; SMOLA, 2002).

De acordo com Hearst et al. (1998), a utilização de funções *kernel* possibilita a obtenção de um hiperplano de separação não linear, sem necessidade de mapeamento explícito dos dados para o espaço de características. Os cálculos necessários são feitos a partir dos próprios dados de entrada (HEASRT et al., 1998). Hearst et al. (1998) mostram ainda que os resultados obtidos com funções *kernel* apropriadas, são equivalentes àqueles computados a partir dos produtos escalares dos pontos no espaço de características.

A utilização de funções *kernel* atribui característica não linear ao SVM, pois, o hiperplano gerado a partir dos dados de entrada corresponde a uma função de decisão não linear, cuja forma é definida pela própria função *kernel* empregada (HEASRT et al., 1998). De acordo com Burges (1998), a não-linearização de SVMs a partir de funções *kernel* torna o algoritmo mais eficiente e tratável do ponto de vista computacional. E segundo Herbrich (2001), funções *kernel* são capazes de calcular o produto escalar entre pontos no espaço de características, a partir dos pontos provenientes do espaço de entrada. Desta maneira, pode-se dizer que a utilização de SVMs com funções *kernel* simplifica e adiciona não-linearidade ao modelo, sem no entanto diminuir a capacidade classificatória. A Figura 2.2 exibe um exemplo de classificador SVM resultante da aplicação de uma função *kernel* RBF (*Radial Basis Function*)

$k(x, x') = \exp(-||x - x'||^2)$ , com espaço de entrada definido em  $X = [-1, 1]^2$  (SCHÖLKOPF; SMOLA, 2002).

Figura 2.2 – Exemplo de classificador SVM encontrado por uma função RBF.



Fonte: (SCHÖLKOPF; SMOLA, 2002).

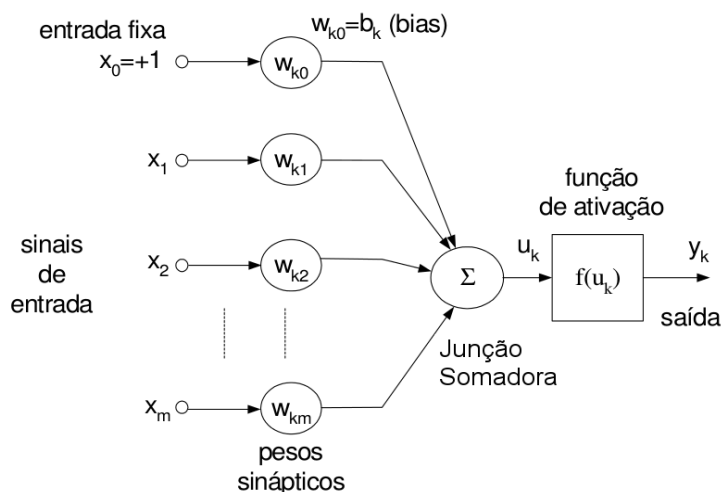
De acordo com Cortes e Vapnik (1995), e Burges (1998), para que uma função seja utilizada como *kernel* do SVM, esta precisa satisfazer as condições do teorema de *Mercer* (MERCER, 1909). As funções *kernel* mais utilizadas, de acordo com Huang et al. (2015), são: (i) polinomial; (ii) função de base radial (RBF - *Radial Basis Function*), ou gaussiana; e (iii) tangente hiperbólica.

### 2.2.2 Redes Neurais Artificiais

Redes Neurais Artificiais (ANNs - *Artificial Neural Networks*) compreende um campo da inteligência computacional em que busca-se o desenvolvimento de sistemas computacionais inteligentes, cuja forma de aprendizado é inspirada no processo desempenhado pelo sistema neural biológico (RAO, 1995; HAYKIN, 1998). Assim como o cérebro humano, uma rede neural utiliza um conjunto de unidades paralelas de processamento interconectadas, total ou parcialmente, denominadas neurônios, para processar informações (RAO, 1995; HAYKIN, 1998). Os estudos na área de redes neurais iniciaram-se em 1943, com a publicação de McCulloch e Pitts (1943), onde um neurônio artificial foi representado através de um modelo matemático simplificado.

O neurônio artificial, ilustrado pela Figura 2.3, é a unidade básica de processamento em uma rede neural, sendo fundamental para o seu funcionamento (HAYKIN, 1998).

Figura 2.3 – Estrutura básica de um neurônio artificial.



Fonte: adaptado de Haykin (1998).

A partir Figura 2.3, pode-se identificar os três componentes principais de um neurônio artificial:

- sinais de entrada: são os valores, juntamente com os respectivos pesos, apresentados à entrada da rede neural. Podem ser referenciados também como sinapses (HAYKIN, 1998);
- junção somadora: neste ponto é efetuada a soma dos sinais de entrada, já com os respectivos pesos aplicados (HAYKIN, 1998);
- função de ativação: utilizada para limitar, geralmente nos intervalos  $[0,1]$  e  $[-1,1]$ , a amplitude de saída do neurônio (HAYKIN, 1998).

A Figura 2.3 mostra ainda um quarto elemento, denominado *bias*. Este é um parâmetro externo fixo, informado juntamente com o conjunto de sinais de entrada. O *bias* atua como parâmetro de ajuste do grau de influência dos valores de entrada, sobre a saída da função de ativação (HAYKIN, 1998). O valor do *bias* é fixo, e o seu peso, assim como o peso das outras entradas, é modificado durante o processo de treinamento da rede.

Redes neurais possuem elevada capacidade de representação de mapeamento não-linear entre grande quantidade de variáveis de entrada e saída, em que a forma de mapeamento é determinada através de parâmetros (pesos) ajustáveis (BISHOP, 1995). O processo de ajuste

dos pesos, tendo como base um conjunto de dados, é chamado processo de treinamento, ou aprendizado (BISHOP, 1995; HAYKIN, 1998). E por esta razão, o conjunto de dados utilizado neste processo é denominado "dados de treinamento" (BISHOP, 1995; HAYKIN, 1998). O ajuste dos pesos é feito com o objetivo de minimizar o erro entre a saída apresentada pela rede e o valor esperado. O erro da rede é geralmente calculado por meio de uma função quadrática, como a *Mean Squared Error* (MSE) (RAO, 1995). O MSE indica o desvio global das previsões em relação aos valores esperados (RABUNAL; DORADO, 2005), sendo calculado a partir da seguinte equação:

$$MSE = \frac{1}{n} \sum_{t=1}^n (x_t - \hat{x}_t)^2 \quad (2.1)$$

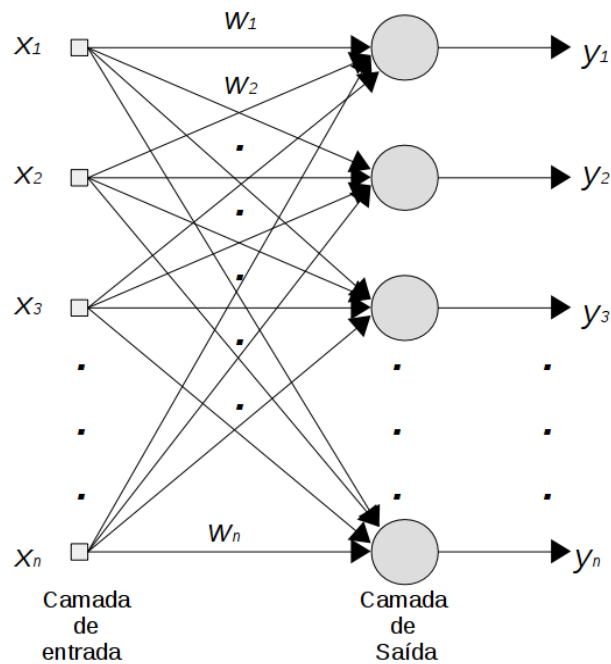
onde  $x_t$  denota o valor esperado. E  $\hat{x}_t$  especifica o valor retornado pela rede neural.

O treinamento da rede neural é um processo contínuo, onde cada passada por todo o conjunto de dados é denominado "época" (RAO, 1995). O processo é repetido através das épocas até que algum critério de parada seja satisfeito.

A maneira como os neurônios são dispostos em uma rede neural, influencia diretamente o algoritmo utilizado para treinamento (HAYKIN, 1998). Uma rede neural é constituída de neurônios dispostos em camadas, podendo ser *feedforward* ou recorrente (cíclica). Uma rede *feedforward* é aquela em que as saídas dos neurônios de uma camada são sempre enviadas como entrada para a camada subsequente (HAYKIN, 1998). Enquanto uma rede recorrente é aquela cuja saída dos neurônios de uma camada são enviados como entrada para neurônios da mesma camada ou camadas anteriores (HAYKIN, 1998). Abaixo são descritas as três classes fundamentais de arquiteturas de redes neurais:

1. *feedforward* de camada única: modelo *feedforward* ilustrado pela Figura 2.4, composto de uma camada de entrada e uma de saída (HAYKIN, 1998). Este modelo é chamado de camada única pois somente a camada de saída efetua processamento sobre os dados. De acordo com Bishop (1995), redes de camada única são bastante limitadas e pouco flexíveis quando comparadas às de múltiplas camadas;
2. *feedforward* de múltiplas camadas: este modelo, ilustrado pela Figura 2.5, distingue-se do anterior pela existência de uma ou mais camadas intermediárias, também referenciadas como camadas ocultas. De acordo com Haykin (1998), a adição de uma ou mais camadas ocultas habilita à rede extrair dados estatísticos de ordem superior, caracterís-

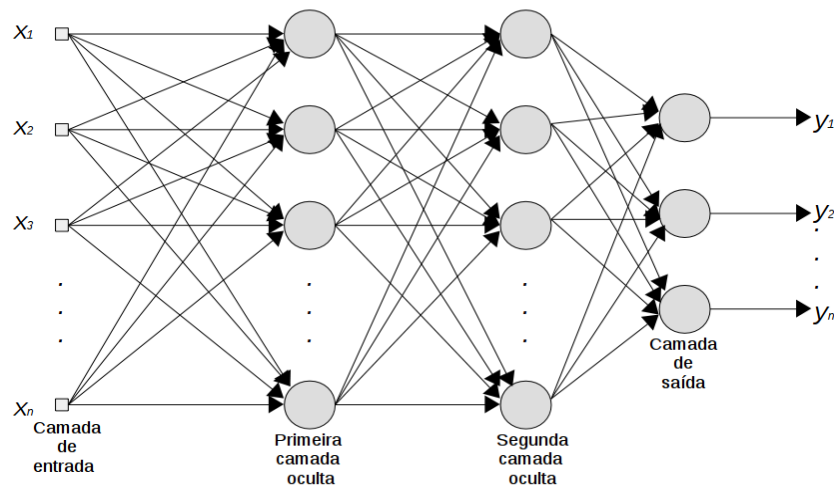
Figura 2.4 – Rede neural *feedforward* de camada única.



Fonte: adaptado de Haykin (1998).

tica de alta relevância quando a camada de entrada apresenta muitos elementos. Ainda segundo Bishop (1995), múltiplas camadas trazem maior capacidade de generalização à rede neural. Embora alguns problemas específicos sejam melhor resolvidos com uma quantidade maior de camadas (BISHOP, 1995), o teorema da aproximação universal (CYBENKO, 1989; HORNIK, 1991) diz que, uma rede neural *Multilayer Perceptron* (MLP), com apenas uma camada oculta, é capaz de aproximar qualquer função contínua definida em um hipercubo unitário;


Figura 2.5 – Rede neural *feedforward* de múltiplas camadas.



Fonte: adaptado de Haykin (1998).

3. recorrentes: são redes que possuem ao menos um laço de retorno, seja para a própria camada ou camadas anteriores (HAYKIN, 1998). Este tipo de rede pode também ser de camada única ou de múltiplas camadas, e a recorrência pode ocorrer tanto para o próprio neurônio (auto-realimentação), para outro na mesma camada, ou para camadas anteriores (HAYKIN, 1998). A Figura 2.6 ilustra uma rede neural recorrente sem camadas ocultas, e sem auto-realimentação.

Figura 2.6 – Rede neural recorrente sem camadas ocultas e sem auto-realimentação.



Fonte: Haykin (1998).

No contexto de redes neurais, funções de ativação são responsáveis por limitar a amplitude de saída do neurônio para uma faixa de valores estabelecida (HAYKIN, 1998). A escolha da função de ativação depende do tipo de problema abordado, e, segundo Bishop (1995), devido aos diferentes papéis desempenhados pelas camadas ocultas e a camada de saída, é comum a utilização de funções de ativação distintas em ambas. De acordo com Haykin (1998), são três os tipos básicos de função de ativação:

- degrau (*threshold*): esta é uma função binária, que pode assumir um entre dois valores.

A função degrau é definida pela seguinte equação:

$$f(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (2.2)$$



na equação acima, a função pode assumir os valores 0 ou 1;

- semi-linear (*piecewise-linear*): neste tipo de função, caso o fator de amplificação da região linear seja muito elevado, esta será reduzida à função degrau (HAYKIN, 1998). A função semi-linear é definida pela seguinte equação:

$$f(u) = \begin{cases} 1 & \text{se } u \geq 1 \\ u & \text{se } 0 < u < 1 \\ 0 & \text{se } u \leq 0 \end{cases} \quad (2.3)$$

- sigmoide (*sigmoid*): este tipo de função possui o gráfico no formato de S, e exibe um bom balanceamento entre os comportamentos linear e não-linear (HAYKIN, 1998). Ao contrário da função degrau, a sigmoide pode assumir qualquer valor no intervalo fechado [0,1]. Um exemplo de função sigmoide é a função logística definida pela seguinte equação:

$$f(u) = \frac{1}{1 + e^{-au}} \quad (2.4)$$

onde  $a$  é o parâmetro de inclinação da função  $f(u)$ .

Haykin (1998) afirma que a diferenciabilidade da função de ativação utilizada é uma característica importante no contexto de redes neurais, e neste aspecto, funções sigmoide são preferíveis às funções degrau e semi-linear.

As funções de ativação citadas possuem faixa de valores entre 0 e 1, não constituindo regra. Estas funções mencionados são as básicas, diversos outros tipos podem ser empregadas. Por exemplo, caso seja necessária a utilização de funções que englobam o intervalo de -1 a +1, uma alternativa à sigmoide pode ser a função tangente hiperbólica (*hyperbolic tangent*) (HAYKIN, 1998), definida pela seguinte equação:

$$\tanh(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (2.5)$$

Redes neurais possuem padrão de comportamento estocástico, pois os seus pesos são iniciados aleatoriamente. Em consequência, este tipo de algoritmo é não determinístico, pois a cada execução o resultado pode ser distinto. Por este motivo, no intuito de observar o desem-

penho médio e variação dos resultados apresentados pela rede neural, Bishop (1995) aponta a necessidade de repetição do treinamento por diversas vezes.

### 2.2.3 Pré-processamento

A aplicação de algum pré-processamento sobre os dados de entrada é muitas vezes necessária (BISHOP, 1995). E a escolha do método mais adequado contribui significativamente para a melhoria no desempenho final do classificador (BISHOP, 1995). Algumas das formas mais importantes de pré-processamento são listadas a seguir (BISHOP, 1995):

- **normalização:** uma das formas mais comuns de pré-processamento é através do processo de alteração da escala dos dados de entrada em um processo chamado normalização. A normalização é feita de forma que cada variável de entrada tenha uma nova escala com média zero, e desvio padrão unitário (BISHOP, 1995). O processo de normalização é muito útil principalmente nos casos em que as variáveis de distinguem muito umas das outras em relação à magnitude dos dados. Sem a normalização, variáveis com ordem de magnitude muito elevadas podem influenciar a saída mais que as outras. E de acordo com Bishop (1995), a amplitude do valor de entrada pode não refletir a sua importância sobre a saída desejada. Ao aplicar uma transformação linear para alteração de amplitude, todas as variáveis de entrada passarão a ter valores similares (BISHOP, 1995). Desta forma, é possível concluir que um dos objetivos da normalização é mitigar o efeito da magnitude da entrada sobre o treinamento. Ainda de acordo com Bishop (1995), para problemas de regressão, é aconselhado efetuar também a normalização dos valores-alvo utilizados no treinamento;
- **redução da dimensionalidade:** esta é uma abordagem que envolve a eliminação de parte dos dados de entrada e, segundo Bishop (1995) e Rao (1995), deve ser feita sempre que possível. Um dos principais problemas decorrentes da dimensão de entrada muito elevada é conhecido como "maldição da dimensionalidade" — a partir de um certo ponto, a adição de novas características pode levar a uma redução do desempenho do modelo, pois o custo computacional cresce exponencialmente com a dimensão do problema (NOVAK; RITTER, 1997). A redução da dimensionalidade pode ser feita através de três maneiras principais (BISHOP, 1995):

- remoção de variáveis irrelevantes: além do aumento desnecessário na dimensão, variáveis irrelevantes podem diminuir a capacidade de generalização do classificador, mesmo após aplicação de métodos para prevenção de *overfitting*. O problema ocorre pois, a informação irrelevante contida nestas variáveis pode influenciar no resultado para dados desconhecidos (ROMERO; SOPENA, 2008);
- remoção de variáveis com forte relação: a correlação entre variáveis também pode ser utilizada para redução da dimensionalidade. Quando a correlação entre duas ou mais variáveis é alta, há grandes chances de que uma mesma informação esteja representada mais de uma vez (BISHOP, 1995);
- combinação de variáveis: uma outra forma para reduzir a dimensão é através da combinação, linear ou não-linear, de valores para geração das entradas para o classificador;
- conhecimento a priori: desempenhada através da inclusão de informações adicionais e relevantes, que possam auxiliar na solução. Segundo Bishop (1995), a incorporação de conhecimento a priori pode melhorar drasticamente o desempenho do modelo em alguns casos. Ainda de acordo com Bishop (1995), o conhecimento a priori pode ser adicionado tanto na etapa de pré-processamento, quanto na estrutura do modelo;
- correção: devido a inconsistências, pode ser necessário algum tipo de ajuste nos dados disponíveis para treinamento.

#### 2.2.4 Seleção de Características

A técnica de Seleção de Características (SC) busca a redução da dimensionalidade, sem, no entanto, eliminar informações relevantes (HAYKIN, 1998), tratando o problema decorrente da "maldição da dimensionalidade". De acordo com Bishop (1995) e Romero e Sopena (2008), a redução da dimensionalidade pode ser desempenhada por três maneiras principais: (i) remoção de variáveis irrelevantes; (ii) remoção de variáveis com forte correlação; e (iii) combinação de variáveis. A redução da dimensionalidade pode resultar em maior agilidade no treinamento, e no aumento da capacidade de generalização (BISHOP, 1995).

Na expectativa de obtenção de um sub-conjunto de dados mais facilmente manipulável, diversas técnicas têm sido empregadas para redução da dimensionalidade do espaço de características original (DUDA; HART; STORK, 2000).

O discriminante linear de *Fisher* (FDR - *Fisher Discriminant Ratio*) (DUDA; HART; STORK, 2000), ou *Fisher Score*, consiste em uma técnica que possibilita a seleção de características por meio de ranqueamento, sendo uma das mais utilizadas para este fim (GU; LI; HAN, 2012). A ideia principal desta técnica consiste na seleção de um sub conjunto de características, de modo que as distâncias entre os dados de classes distintas sejam maximizadas, enquanto as distâncias entre dados de uma mesma classes sejam minimizadas (GU; LI; HAN, 2012). O FDR faz a seleção de parâmetros independentes, a partir do custo de cada variável (*score*) em relação ao critério de *Fisher* (DUDA; HART; STORK, 2000; GU; LI; HAN, 2012). De acordo com Gu, Li e Han (2012), a função custo do FDR é dada pela seguinte equação:

$$f(x_j) = \frac{\sum_{k=1}^c n_k (\mu_k^j - \mu^j)^2}{(\sigma^j)^2} \quad (2.6)$$

Onde,  $x_j = [x_1, \dots, x_n]^T$ ,  $n_k$  representa o tamanho da classe  $k$ .  $\mu_k^j$  representa a média da classe  $k$ , em relação à variável  $j$ . Enquanto  $\mu^j$  e  $\sigma^j$  denotam respectivamente a média e desvio padrão de todo o conjunto de dados em relação à variável  $j$ . O valor de  $(\sigma^j)^2$  é dado por:

$$(\sigma^j)^2 = \sum_{k=1}^c n_k (\sigma_k^j)^2 \quad (2.7)$$

Onde  $\sigma_k^j$  especifica o desvio padrão da classe  $k$  em relação à variável  $j$ .

É calculado um *score* para cada parâmetro independente, e os  $n$  parâmetros com maior *score* são selecionados (GU; LI; HAN, 2012). Esta abordagem, segundo Gu, Li e Han (2012), leva à seleção de um conjunto sub-ótimo de características, pois, embora a técnica FDR seja capaz de identificar as variáveis mais relevantes, não elimina casos de redundância.

Como apontado por Hall (1999), a técnica denominada Coeficiente de Correlação de *Pearson* (CCP) pode ser utilizada para seleção de características por meio da eliminação de atributos redundantes. Esta técnica possibilita mensurar a covariância — medida da variação conjunta, ou grau de associação, entre duas variáveis aleatórias (RICE, 2006) — entre dois parâmetros quaisquer. Sendo uma medida de associação linear entre duas variáveis (BOSLAUGH, 2012). Através do CCP é possível identificar o grau de redundância entre as duas variáveis avaliadas. Se cada variável possui  $N$  valores escalares, o coeficiente de correlação ( $p$ ) pode ser obtido a partir da seguinte equação (MATHWORKS, 2017):

$$p = \frac{1}{N-1} \sum_{i=1}^N \left( \frac{A_i - \mu_A}{\sigma_A} \right) \left( \frac{B_i - \mu_B}{\sigma_B} \right) \quad (2.8)$$

Onde  $\mu_A$  e  $\sigma_A$  representam respectivamente a média e desvio padrão de  $A$ . E  $\mu_B$  e  $\sigma_B$  denotam respectivamente a média e desvio padrão de  $B$ . Este coeficiente, representado por  $p$ , pode assumir valores entre -1 e 1 (BOSLAUGH, 2012). Onde 0 indica que não há nenhum tipo de relação, -1 especifica correlação negativa máxima, e +1 indica correlação positiva perfeita (BOSLAUGH, 2012). A correlação negativa mostra que, enquanto uma variável varia para uma direção, a outra varia em sentido oposto. E a correlação positiva indica variação para o mesmo sentido de ambos os parâmetros.

### 2.3 Estado da Arte

No trabalho de Hu et al. (2015), foi utilizado um algoritmo evolucionário do tipo *eXtended Classifier Systems* (XCS) no desenvolvimento de um sistema para atuação em mercado acionário. O algoritmo utiliza como base um conjunto de indicadores técnicos para a construção de regras de negociação, que são combinadas com uma estratégia de seguimento de tendência (TF - *Trend-Following*). O trabalho consiste na aplicação de técnicas de aprendizagem evolutiva para descoberta de regras de negociação (*trading rules*). Para lidar com o problema de *Concept-Drift* — característica não estacionária inerente ao comportamento do mercado de ações, onde dados subjacentes responsáveis pela precificação acionária sofrem alteração ao longo do tempo (TSYMBAL, 2004; ZLIOBAITE, 2010) —, comum neste tipo de problema, o algoritmo procura adaptar-se ao ambiente, avaliando novas regras e eliminando as antigas com baixo desempenho.

O modelo proposto por Hu et al. (2015) foi validado em três grandes índices da bolsa de *Shanghai* (*Shanghai Stock Exchange*), no período de Janeiro de 2001 a Julho de 2013. Para construção dos indicadores técnicos foram utilizados valores de cotação ("abertura", "máxima", "mínima" e "fechamento") e "volume" diários. A estratégia de negociação empregada consistiu na identificação de uma tendência superior por meio da análise de uma média móvel de 20 dias, atuando no mercado apenas quando a previsão do algoritmo alinhava-se à este indicador. Os resultados mostram que o modelo superou o emprego de B&H, mesmo após a contabilização dos custos. Os autores também constataram que o algoritmo proposto saiu-se melhor que a

utilização de árvores de decisão e redes neurais artificiais. Foram utilizados *Stop Loss* e *Stop Gain* de 5%.

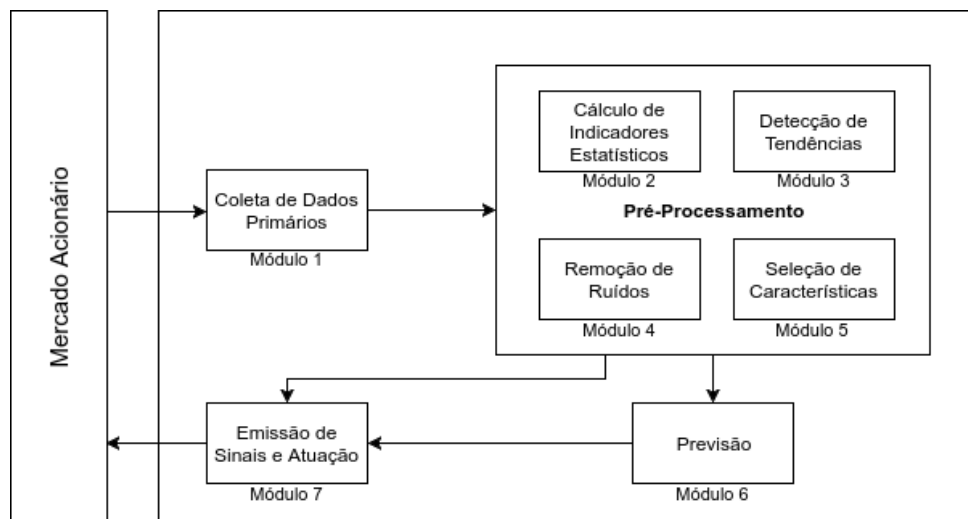
### 3 METODOLOGIA

Neste capítulo é apresentada a metodologia empregada neste trabalho. Primeiramente é feita a descrição do sistema proposto, bem como da versão desenvolvida para avaliação da proposta. Em seguida, são descritas as configurações relativas aos custos financeiros operacionais, *bid-ask spread*, período considerado, tamanhos dos lotes acionários, e base de dados utilizada. Na seção seguinte, são descritos os parâmetros de referência (*baselines*) adotados em comparação aos resultados alcançados pelo sistema desenvolvido. E as métricas de avaliação empregadas são apresentadas na última seção.

#### 3.1 Sistema Proposto

Esta seção apresenta um modelo de sistema para especulação de ativos em mercado acionário. A proposta de atuação é focada no médio e longo prazo, com utilização de dados históricos disponíveis livremente na *internet*. O modelo tem como fundamento características comportamentais do mercado, originárias da escola de Análise Técnica (AT) e Teoria de *Dow*. A estrutura do sistema proposto é ilustrada na Figura 3.1.

Figura 3.1 – Arquitetura geral do sistema proposto.



A Figura 3.1 apresenta uma estrutura modular, indicando a possibilidade de funcionamento distribuído e independente das partes. A utilização de dados disponíveis na *internet*

propicia coleta em tempo real. E o recurso de Acesso Direto ao Mercado (DMA - *Direct Market Access*)<sup>1</sup>, provido pela BM&FBovespa, viabiliza ao sistema um modo de atuação autônoma.

No intuito de verificar a viabilidade da proposta, foi desenvolvida uma versão do sistema para avaliação do desempenho sobre dados históricos. Os módulos 1, 2, 3, 4 e 7 foram desenvolvidos com a linguagem de programação *Java*<sup>2</sup>, e os módulos 5 e 6 foram implementados no *MATLAB*®<sup>3</sup>. Os dados coletados e manipulados pelo sistema são armazenados em Sistema de Gerenciamento de Banco de Dados (SGBD) *MySQL Server Community Edition*<sup>4</sup>.

Os módulos ilustrados pela Figura 3.1 são apresentados em seguida. E ao final de cada módulo, é feita a descrição da versão de avaliação desenvolvida.

### 3.1.1 Módulo 1 - Coleta de Dados Primários

#### 3.1.1.1 Proposta

Este módulo é responsável pela recuperação periódica dos dados primários necessários para operação do sistema. Neste trabalho, são considerados primários os dados históricos provenientes das negociações e comercialização do ativos, providos pela fonte da informação. As seguintes informações são consideradas dados primários e precisam ser recuperadas periodicamente para os tempos gráficos diário, semanal e mensal:

- data contendo dia, mês e ano;
- valor de abertura da ação;
- valor máximo alcançado pela ação;
- valor mínimo atingido pela ação;
- valor de fechamento da ação;
- quantidade de ativos negociados (volume);

<sup>1</sup> BM&FBOVESPA. **Acesso Direto ao Mercado - DMA**. 2007. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/servicos/negociacao/acesso-direto-ao-mercado-dma/sobre-dma/](http://www.bmfbovespa.com.br/pt_br/servicos/negociacao/acesso-direto-ao-mercado-dma/sobre-dma/)>. Acessado em 4 de março de 2017.

<sup>2</sup> ORACLE. **The Java Tutorials**. 2015. Disponível em: <<http://docs.oracle.com/javase/tutorial/java/>>. Acessado em 4 de março de 2017.

<sup>3</sup> MATHWORKS. **MATLAB**. 2017. Disponível em: <<https://www.mathworks.com/products/matlab.html>>. Acessado em 4 de março de 2017.

<sup>4</sup> ORACLE. **MySQL Community Server**. 2017. Disponível em: <<https://www.mysql.com/>>. Acessado em 4 de março de 2017.



- valor de fechamento ajustado para dividendos e desdobramentos.

Os dados de movimentação semanais e mensais podem ser computados a partir dos dados de movimentação diária. Portanto, se a fonte de dados utilizada não prover tais informações, as mesmas podem ser apuradas da seguinte forma:

- dados de movimentação semanais: para o valor "dia" do campo data, é utilizado o dia do primeiro dia útil da semana. O valor de abertura refere-se ao valor de abertura do primeiro dia útil da semana. Os valores máximo e mínimo referem-se respectivamente aos valores máximos e mínimos atingidos durante a semana. Os valores de fechamento e fechamento ajustado, dizem respeito aos valores de fechamento e fechamento ajustado do último dia útil da semana. E o volume é obtido através do cálculo da média aritmética dos volumes dos dias daquela semana;
- dados de movimentação mensais: para o valor "dia" do campo data, é utilizado o dia do primeiro dia útil do mês. O valor de abertura refere-se ao valor de abertura do primeiro dia útil do mês. Os valores máximo e mínimo referem-se respectivamente aos valores máximos e mínimos alcançados durante o mês. Os valores de fechamento e fechamento ajustado, dizem respeito aos valores de fechamento e fechamento ajustado do último dia útil do mês. E o volume é obtido a partir do cálculo da média aritmética dos volumes dos dias do mês em questão.

A distribuição de dividendos, bem como a ocorrência de desdobramentos e grupamentos, resulta em alterações bruscas nos preços das ações. Tais eventos, se não tratados, podem influenciar na análise da movimentação histórica do ativo. A variação brusca na linha do tempo pode levar a interpretações errôneas quanto ao movimento real desempenhado pelo ativo. Levando-se em conta que indicadores técnicos possuem como objetivo auxiliar na tomada de decisão, tendo como base o comportamento histórico do ativo, a utilização de valores ajustados mostrou-se mais adequada. Caso a fonte de dados não forneça todos os valores em formato ajustado, será preciso calcular os outros valores por meio de um fator de ajuste. É necessário observar que, caso exista alguma base de dados histórica armazenada pelo sistema, estes dados precisam ser atualizados para os novos padrões de ajuste.

O ajuste dos demais valores pode ser feito com base na relação de ajuste calculada entre um dos valores fornecidos em formato original e o seu formato ajustado. A relação de ajuste ( $r$ ) pode ser calculada através da seguinte equação:

$$r = \frac{v_a}{v} \quad (3.1)$$

Onde  $v_a$  denota o valor ajustado, e  $v$  o valor original.

Desta maneira, os valores fornecidos sem ajuste podem ser calculados a partir da equação:

$$v_a = v * r \quad (3.2)$$

Onde  $v_a$  identifica o novo valor ajustado,  $v$  o valor real, e  $r$  o fator de ajuste calculado por meio da equação 3.1.

### 3.1.1.2 Solução Desenvolvida para Avaliação

Foi utilizado como fonte de dados o *Yahoo Finance*<sup>5</sup>. Esta fonte disponibiliza forma de acesso *online* ao histórico de cotações de ativos da BM&FBovespa, nos tempos gráficos: diário, semanal, e mensal. Os dados foram recuperados em formato CSV (*Comma-Separated Values*), sendo constituído das seguintes informações:

- *date*: data em formato ano-mês-dia;
- *open*: valor de abertura do ativo;
- *high*: valor máximo do ativo;
- *low*: valor mínimo do ativo;
- *close*: valor de fechamento do ativo;
- *volume*: quantidade de ativos negociados;
- *adj close*: valor de fechamento ajustado para dividendos e desdobramentos.

Somente o valor de fechamento foi disponibilizado nos dois formatos, sem ajuste ("*Close*") e com ajuste ("*Adj Close*"), desta maneira, foi necessário ajustar os demais valores ("*Open*", "*High*" e "*Low*") por meio das equações 3.1 e 3.2. Foi constatado que os valores de "Volume" disponibilizados já se encontravam ajustados.

<sup>5</sup> YAHOO!. **Yahoo! Finace**. 2007. Disponível em: <<https://finance.yahoo.com/>>. Acessado em 4 de março de 2017.

Os dados dos três tempos gráficos foram coletados e armazenados em banco de dados. O módulo depende de um cadastro prévio dos códigos das ações a serem consideradas para coleta do histórico. Para este experimento, foram cadastradas as 50 ações constituintes do Índice IBrX-50 da BM&FBovespa.

### **3.1.2 Módulo 2 - Cálculo de Indicadores Estatísticos**

#### **3.1.2.1 Proposta**

Este módulo é responsável pela geração de indicadores técnicos estatísticos, calculados a partir da movimentação histórica do próprio ativo. Tais indicadores são elaborados a partir dos valores históricos de "abertura", "fechamento", "máxima", "mínima", e "volume", mantidos pelo Módulo 1. O emprego de indicadores técnicos baseia-se nos conceitos da Análise Técnica (AT), sobre a possibilidade de detecção e dedução de movimentos do ativo por meio da análise de atividade histórica do próprio mercado.

Há grande variedade de indicadores técnicos estatísticos com documentação acessível. Alguns deles, embora antigos, a exemplo do *Relative Strength Index* (RSI) (WILDER, 1978), são ainda largamente utilizados. Não há quantidade limite de indicadores a serem considerados neste módulo. A seleção de características relevantes, bem como o tratamento de redundâncias, são atividades desempenhadas por módulo específico.

Todos os indicadores técnicos considerados devem ser calculados para os tempos gráficos semanal e mensal. O indicador RSI é utilizado pelo módulo 7, sendo portanto necessário o seu cálculo também para o tempo gráfico diário.

#### **3.1.2.2 Solução Desenvolvida para Avaliação**

Buscou-se utilizar a maior gama possível de indicadores técnicos, a lista final foi definida após análise dos indicadores mais utilizados em trabalhos recentes (FONG; SI; TAI, 2012; BHAT; KAMATH, 2013; BODAS-SAGI et al., 2013; De Oliveira; NOBRE; ZÁRATE, 2013; WU; YU; CHANG, 2014; BISOI; DASH, 2014; SHYNKEVICH et al., 2014; WANG; YU; CHEUNG, 2014b; CHANG; WU, 2015; DASH; DASH, 2015; GONZALEZ; PADILHA; BARONE, 2015; PATEL et al., 2015; ZBIKOWSKI, 2015; AZIMIFAR; ARAABI; MORADI, 2015; IACOMIN, 2016), e por indicações em literatura especializada (CHANDE; KROLL, 1994; ROMEU; SERAJUDDIN, 2001; ACHELIS, 2000; LARSON, 2002; EDWARDS; MA-

GEE; BASSETTI, 2007; THOMSETT, 2010). São calculados 36 indicadores técnicos. Alguns indicadores resultam em mais de um dado de saída. Ao final, 43 dados distintos são produzidos.

Para as previsões de direção com dados fora da amostra a partir de 01/01/2010, foi necessário histórico de 24 meses de indicadores técnicos para as previsões mensais, e histórico de 104 semanas de indicadores para previsões semanais. Desta maneira, foi preciso calcular o grupo de indicadores desde o ano de 2008. Para tal, foram necessários dados desde o ano de 2004. O Indicador TRIX, por exemplo, necessita de 43 registros históricos em sua configuração original.

Os indicadores técnicos são calculados através da utilização de dados históricos da movimentação do próprio ativo, e possuem parametrização variável. Os indicadores foram construídos considerando a configuração padrão indicada pela documentação de cada um deles. Por exemplo, no indicador *Chaikin A/D Oscillator* (THOMSETT, 2010) são utilizadas duas médias móveis exponenciais, de 3 e 10 períodos.

A relação com todos os indicadores técnicos calculados pelo módulo é apresentada na Tabela 3.1. As colunas "Indicador" e "Saídas" da Tabela 3.1 especificam respectivamente, a descrição do indicador, e a quantidade de saídas de dados geradas pelo mesmo. Todos os indicadores listados pela Tabela 3.1 são calculados para os tempos gráficos semanal e mensal. Apenas o indicador RSI é calculado para os três tempos gráficos (diário, semanal e mensal), pois, além de ser utilizado para previsões semanais e mensais no Módulo 6, o RSI é utilizado como filtro de sinais pelo Módulo 7.

### **3.1.3 Módulo 3 - Detecção de Tendências**

#### **3.1.3.1 Proposta**

Este módulo é responsável pela detecção de tendências mensais e semanais de ativos do mercado acionário. Em alusão aos tipos de movimentos descritos pela Teoria de *Dow*, as tendências mensais e semanais são também referenciadas neste trabalho como "primárias" e "secundárias", respectivamente.

Ao observar o histórico de cotações de uma ação, é perceptível que em certos intervalos de tempo os preços parecem movimentarem-se rumo a uma direção principal. Se a movimentação é de valorização, é considerado que o ativo está em tendência de alta. Caso a movimentação seja de desvalorização, é assumida uma tendência de baixa. E nas situações com impossibili-

Tabela 3.1 – Relação de indicadores técnicos calculados pelo Módulo 2 da versão de avaliação.

<b>Indicador</b>	<b>Saídas</b>
<i>Chaikin A/D Line</i> (ad) (THOMSETT, 2010)	1
<i>Chaikin A/D Oscillator</i> (adosc) (THOMSETT, 2010)	1
<i>Average Directional Movement Index</i> (adx) (WILDER, 1978)	1
<i>Average Directional Movement Index Rating</i> (adxr) (WILDER, 1978)	1
<i>Absolute Price Oscillator</i> (apo) (FIDELITY, 2017)	1
<i>Aroon</i> (aroon) (THOMSETT, 2010)	2
<i>Aroon Oscillator</i> (aroonosc) (THOMSETT, 2010)	1
<i>Average True Range</i> (atr) (WILDER, 1978)	1
<i>Bollinger Bands</i> (bbands) (BOLLINGER, 2001)	3
<i>Balance Of Power</i> (bop) (LARSON, 2002)	1
<i>Commodity Channel Index</i> (cci) (ACHELIS, 2000)	1
<i>Chande Momentum Oscillator</i> (cmo) (CHANDE; KROLL, 1994)	1
<i>Directional Movement Index</i> (dx) (WILDER, 1978)	1
<i>Moving Average Convergence/Divergence</i> (macd) (ACHELIS, 2000)	2
<i>Moving Average Convergence/Divergence Histogram</i> (macd_hist) (ACHELIS, 2000)	1
<i>Money Flow Index</i> (mfi) (ACHELIS, 2000)	1
<i>Minus Directional Indicator</i> (minus_di) (WILDER, 1978)	1
<i>Minus Directional Movement</i> (minus_dm) (WILDER, 1978)	1
<i>Momentum</i> (mom) (WILDER, 1978)	1
<i>Normalized Average True Range</i> (natr) (FORMAN, 2006)	1
<i>On Balance Volume</i> (obv) (GRANVILLE, 2010)	1
<i>Plus Directional Indicator</i> (plus_di) (WILDER, 1978)	1
<i>Plus Directional Movement</i> (plus_dm) (WILDER, 1978)	1
<i>Percentage Price Oscillator</i> (ppo) (STOCKCHARTS, 2017b)	1
<i>Rate of Change</i> (roc) (APPEL; HITSCHLER, 1990)	1
<i>Relative Strength Index</i> (rsi) (WILDER, 1978)	1
<i>Parabolic Stop And Reverse</i> (SAR) (WILDER, 1978)	1
<i>Standard Deviation</i> (stddev) (STOCKCHARTS, 2017c)	1
<i>Stochastic</i> (stoch) (ACHELIS, 2000)	2
<i>Stochastic Fast</i> (stochf) (ACHELIS, 2000)	2
<i>Stochastic Relative Strength Index</i> (stochrsi) (CHANDE; KROLL, 1994)	2
<i>True Range</i> (trange) (CHANDE; KROLL, 1994)	1
<i>Triple Exponential Average</i> (trix) (CHANDE; KROLL, 1994)	1
<i>Ultimate Oscillator</i> (ultosc) (WILLIAMS, 1984)	1
<i>Variance</i> (var) (TRADINGSOLUTIONS, 2017)	1
<i>Williams' %R</i> (willr) (WILLIAMS, 1979)	1

dade de identificação da direção principal, é considerado que o ativo está sem tendência definida.

A SLR mostra que alguns trabalhos (SAHIN; OZBAYOGLU, 2014; WEI; CHAUDHARY, 2015; HU et al., 2015) utilizam a estratégia de cruzamento de médias móveis para detecção de tendências. Mas como bem apontado por Iman e Kemin (2015), o cruzamento de médias móveis funciona muito bem para ativos em tendência definida, podendo falhar em períodos de estagnação. No trabalho desenvolvido por Bhat e Kamath (2013), a identificação de tendências é feita com a utilização do indicador técnico *Moving Average Convergence/Divergence* (MACD). Este indicador apresentou-se mais adequado para detecção de tendências que o emprego de médias móveis. Desta maneira, neste módulo é indicado o uso do MACD para detecção de tendências.

### 3.1.3.2 Solução Desenvolvida para Avaliação

O indicador MACD, calculado pelo Módulo 2, foi utilizado para detecção de tendências primárias e secundárias. Para melhor entendimento da estratégia utilizada, a composição do MACD é descrita a seguir:

- linha MACD: diferença entre duas médias móveis exponenciais (EMA - *Exponential Moving Average*) de 12 e 26 períodos (EMA12 - EMA26);
- linha de Sinal: média móvel exponencial de 9 períodos sobre a linha MACD;
- histograma MACD: diferença entre a linha MACD e a linha de Sinal (Linha MACD - Linha de Sinal).

A identificação de tendências com o MACD foi desempenhada a partir das regras abaixo:

- tendência de alta: linhas MACD e Sinal maiores que zero. E histograma MACD positivo;
- tendência de baixa: linhas MACD e Sinal menor que zero. E histograma MACD negativo;
- tendência indefinida: qualquer outra combinação além daquelas citadas anteriormente.

As regras acima foram definidas após análise da composição e funcionamento do MACD. Este indicador é também utilizado por Bhat e Kamath (2013) na identificação de tendências, mas com regras diferentes às aplicadas aqui.

### 3.1.4 Módulo 4 - Remoção de Ruídos

#### 3.1.4.1 Proposta

Este módulo é responsável pela suavização dos efeitos da volatilidade excessiva nos valores de fechamento a serem utilizados para previsões de direção dos ativos. A volatilidade é uma característica inerente ao mercado acionário, sendo encarada neste trabalho como um ruído sobre o sentido principal da tendência. Entende-se que qualquer estratégia baseada em seguimento de tendências no mercado acionário está interessada em seguir o movimento principal, livre de ruídos intermediários. Ignorar a ocorrência de ruídos pode levar a um excesso de negociações, inviabilizando o sistema e estratégia empregados. Como evidenciado por Chiang et al. (2016), a suavização de ruídos por meio da eliminação de pequenas flutuações do mercado resultou em diminuição drástica na quantidade de atuações no mercado.

Os resultados da SLR indicam três técnicas principais utilizadas para suavização de ruídos provenientes da volatilidade sobre valores de fechamento em ativos do mercado acionário: (i) Médias Móveis (LUO; SI; FONG, 2012; BRASILEIRO et al., 2013; SHYNKEVICH et al., 2014; NAYAK; MISHRA; RATH, 2015); (ii) transformada *Wavelet* (CHIANG et al., 2016; DABHI; CHAUDHARY, 2016); e (iii) transformada de *Fourier* (HONG; ZHANG, 2012; HUANG et al., 2015). Foi observado por meio dos resultados dos trabalhos citados, que médias móveis mostraram-se adequadas à tarefa de suavização de ruídos, e dada a sua simplicidade de cálculo e interpretação, são indicadas para utilização neste módulo.

#### 3.1.4.2 Solução Desenvolvida para Avaliação

Assim como em outros trabalhos publicados (LUO; SI; FONG, 2012; BRASILEIRO et al., 2013; SHYNKEVICH et al., 2014; NAYAK; MISHRA; RATH, 2015), o tratamento de ruídos neste módulo foi efetuado por meio da aplicação de uma média móvel sobre os valores de fechamento. Após testes preliminares, optou-se pela utilização de uma média móvel simples (SMA - *Simple Moving Average*) de 12 períodos (SMA12) para os tempos gráficos semanal e mensal. Para exemplificar, na Figura 3.2 é exibido o gráfico semanal da ação SUZB5, juntamente com uma média móvel simples de 12 períodos. Como pode ser observado no gráfico, a média móvel empregada consegue suavizar as oscilações bruscas decorrentes da volatilidade.

Figura 3.2 – Exemplo de média móvel simples de 12 períodos (SMA12) sobre o gráfico semanal da ação SUZB5 para o período de 01/01/2012 a 01/01/2014.



### 3.1.5 Módulo 5 - Seleção de Características

#### 3.1.5.1 Proposta

Este módulo é encarregado pela etapa de seleção de características relevantes, tendo como base os indicadores técnicos gerados pelo Módulo 2. Em função da quantidade de indicadores técnicos estatísticos existentes, a dimensão de dados produzida pelo Módulo 2 é indeterminada. E devido ao problema decorrente da "maldição da dimensionalidade" (NOVAK; RITTER, 1997), a aplicação de técnicas para redução da complexidade dimensional mostra-se essencial.

Como mencionado por Gu, Li e Han (2012), a técnica FDR permite a seleção de características por meio de ranqueamento, sendo uma das técnicas mais utilizadas para este fim. E assim como feito por Ferreira (2010) e Zbikowski (2015), a técnica FDR foi adotada como ferramenta para seleção de características neste módulo.

Visto que o FDR não fornece um meio para eliminação de redundâncias (GU; LI; HAN, 2012), observou-se que o processo de seleção de características poderia ser otimizado com o emprego de verificação de correlação por meio da técnica CCP. Com esta técnica pode-se mensurar o grau de redundância, expresso pelo coeficiente de correlação, entre duas variáveis quaisquer.

#### 3.1.5.2 Solução Desenvolvida para Avaliação

A seleção de característica foi desempenhada em duas etapas, executadas de forma sequencial. Primeiro é feita a seleção dos parâmetros mais relevantes, resultando em um conjunto



sub-ótimo de características. Este conjunto é então submetido à etapa de verificação e eliminação de redundâncias. As etapas são descritas à seguir:

- seleção de parâmetros relevantes: de acordo com Gu, Li e Han (2012), de modo geral, a seleção de características com FDR é feita a partir da escolha dos  $n$  parâmetros com maior *score*. Sendo o valor de  $n$  definido de forma empírica. Neste trabalho, por outro lado, foram selecionados os parâmetros com *score* maior, ou equivalente, à media aritmética dos *scores* obtidos pelo conjunto de parâmetros. Desta maneira, a quantidade de parâmetros variou a cada etapa de seleção, de acordo com o *score* médio do conjunto. Este método foi utilizado após testes empíricos com diversas configurações de  $n$ , onde a abordagem com *score* médio mostrou-se mais adequada, promovendo melhores resultados classificatórios quando combinado à segunda etapa;
- eliminação de redundâncias: o conjunto de parâmetros resultante da etapa anterior é submetido a um processo de verificação e eliminação de redundâncias por CCP ( $p$ ). Nesta etapa, é calculado  $p$  de cada parâmetro em relação a todos os demais. Desta maneira, obtém-se uma matriz de coeficientes  $p$ , onde a diagonal principal é composta pelo número um, referente ao valor  $p$  do parâmetro com ele próprio. A diagonal principal foi desconsiderada na verificação de redundâncias. Após testes empíricos, foi observado que limites (*threshold*) de -0,8 e +0,8 resultaram em boa capacidade de eliminação de parâmetros, sem perda de eficiência de classificação. Desta forma, foram consideradas redundâncias valores de  $p$  positivos superiores a 0,8, e valores de  $p$  negativos inferiores a -0,8. A escolha entre os parâmetros a serem mantidos foi com base no *score* FDR de cada um deles, ou seja, o parâmetro com maior *score* foi mantido, e os outros em conflito com este foram descartados.

### 3.1.6 Módulo 6 - Previsão

#### 3.1.6.1 Proposta

Este módulo é responsável pela previsão da direção no instante um passo à frente, semanal e mensal, do ativo em análise. A atividade de previsão é abordada neste trabalho como um problema de classificação entre dois grupos distintos. É considerado que a direção livre de ruídos sempre varia, para cima ou para baixo, no instante um passo à frente. Os grupos de variação considerados são:

- positiva: taxa de variação no instante um passo à frente, em relação ao ponto atual, maior que zero;
- negativa: taxa de variação no instante um passo à frente, em relação ao ponto atual, menor ou igual à zero.

Caso não ocorra variação entre duas amostras, optou-se pela classificação negativa do evento. Esta abordagem evita a complexidade adicional de lidar com uma classe de variação extra. Levando-se em conta a volatilidade do mercado, uma variação nula entre dois eventos consecutivos mostra-se pouco provável.

### 3.1.6.2 Solução Desenvolvida para Avaliação

A SLR desempenhada como parte deste trabalho mostra que Máquinas de Vetores Suporte (SVM - *Support Vector Machine*), e Redes Neurais Artificiais (ANN - *Artificial Neural Network*), são os tipos de algoritmos mais utilizados para previsão comportamental de ativos em mercado acionário. Nas publicações analisadas, ambos algoritmos conseguem desempenhos promissores.

Diante das pesquisas realizadas, não foi possível constatar qual seria o melhor algoritmo para previsões em mercado acionário. Por exemplo, no trabalho de Xu, Li e Luo (2013), o SVM alcança desempenho superior ao algoritmo *Random-Forest* (RF) utilizado na comparação. Enquanto no trabalho desenvolvido por Patel et al. (2015), RF consegue melhores resultados que SVM e ANN. Na publicação de Paliyawan (2015) é feita uma comparação entre ANN e um algoritmo do tipo *Decision-Tree* (DT), ambos apresentam desempenhos similares. O mesmo ocorre em uma comparação entre DT e SVM, feita por Panigrahi e Mantri (2015a), onde ambos apresentam resultados similares.

Em função dos resultados observados, os algoritmos SVM e ANN foram considerados para composição deste módulo. Ambos algoritmos foram empregados na previsão de direção do movimento no instante um passo à frente, semanal e mensal, de todos os ativos considerados. O desempenho dos algoritmos foi comparado por meio da taxa de acerto de direção (HR - *Hit Ratio*). Devido sua natureza estocástica, o experimento com ANN foi repetido por 10 vezes, e a média aritmética sobre a medida HR foi utilizada na comparação com os resultados do SVM. Para ambos os classificadores, os dados de entrada, bem como os valores alvo, foram normalizados para o intervalo  $[-1,1]$ . O algoritmo com maior valor de HR médio sobre as previsões

semanais e mensais foi selecionado para composição deste módulo nos testes de desempenho financeiro do sistema. A seguir são descritas as configurações utilizadas para os algoritmos ANN e SVM, bem como a metodologia de treinamento empregada.

### 3.1.6.3 Configuração do Algoritmo ANN

Foi utilizada uma rede neural *Multilayer Perceptron* (MLP) com 3 camadas, com uma camada oculta. De acordo com o teorema da aproximação universal (CYBENKO, 1989; HORNIK, 1991), uma rede MLP com apenas uma camada oculta é capaz de aproximar qualquer função contínua definida em um hipercubo unitário. Foi utilizada a implementação de rede neural *patternnet*<sup>6</sup> do MATLAB®.

A quantidade de neurônios na camada de entrada varia de acordo com a dimensão dos dados resultantes da etapa de seleção de características. A camada de saída é composta por dois neurônios, um para cada classe de variação (alta ou baixa). E a quantidade de neurônios da camada oculta foi dada pela seguinte equação:

$$n = 2 * \sqrt{(m + 2) * ni} \quad (3.3)$$

Onde  $ni$  representa a quantidade de neurônios da camada de entrada, e  $m$  a quantidade de neurônios da camada de saída. A equação 3.3 foi proposta por Huang (2003), com evidências de ganho de desempenho preditivo, sendo mais tarde utilizada também por De Oliveira, Nobre e Zárate (2013). Sendo a quantidade de neurônios definida por um número inteiro, o resultado da equação 3.3 é arredondado à parte inteira.

Foi utilizada a função de ativação Tangente Hiperbólica para a camada oculta e camada de saída. O treinamento da rede neural foi efetuado com o algoritmo *Scaled Conjugate Gradient Backpropagation* (MILLER, 1993), sendo a quantidade limite de épocas de treinamento definida para 1000. O valor objetivo para minimização do *Mean Squared Error* (MSE) foi definida em 0, ou seja, o treinamento também será interrompido caso seja atingido um MSE igual a 0 para a base de treinamento.

A parcela de 10% dos dados disponíveis para treinamento foi utilizada como base de validação. Os dados utilizados para validação foram extraídos aleatoriamente da base disponível para treinamento, e utilizados para avaliação de desempenho durante o processo de treinamento

<sup>6</sup> MATHWORKS. **Pattern Recognition Network**. 2017. Disponível em: <<https://www.mathworks.com/help/nnet/ref/patternnet.html>>. Acessado em 4 de março de 2017.

da rede neural. O desempenho da rede sobre a base de validação foi também utilizado como um critério de parada do treinamento. Caso o MSE aumentasse por  $x$  vezes, definido em 10, sobre os dados de validação, o treinamento era encerrado, e a rede final era aquela com melhor desempenho sobre a base de validação.

Um último critério de parada foi quanto à magnitude do gradiente. Caso o desempenho do gradiente caísse abaixo do valor mínimo, definido em  $1e-6$ , o treinamento da rede neural era encerrado.

#### 3.1.6.4 Configuração do Algoritmo SVM

No *kernel* do SVM foi utilizada uma função de base radial (RBF - *Radial Basis Function*) gaussiana. Este tipo de função foi selecionado após análise de algumas publicações. Nos trabalhos de Lin e Lin (2003) e Wu e Chang (2012), são apontadas vantagens na utilização de função *kernel* do tipo RBF para o SVM. Este tipo de função *kernel* também é utilizada nas publicações de Chen e Chen (2013), Gonzalez, Padilha e Barone (2015), Huang et al. (2015) e Iacomini (2016), com o alcance de resultados promissores.

Foi utilizada a implementação do SVM *fitsvm*<sup>7</sup> do MATLAB®. A opção *KernelScale* do algoritmo foi configurada para *auto*, desta forma, a cada treinamento foi aplicada uma heurística interna para configuração do valor do *sigma* da função RBF utilizada. O treinamento do SVM foi desempenhado com o algoritmo *Sequential Minimal Optimization* (SMO) (PLATT, 1998).

#### 3.1.6.5 Metodologia Utilizada para Treinamento e Teste dos Classificadores

A movimentação do mercado acionário pode ser vista como resultante do comportamento humano na busca contínua pelo lucro. Esta busca leva a constantes mudanças de estratégias e consequente alteração na dinâmica de comportamento do mercado, invalidando estratégias até então funcionais. Este aspecto não estacionário está relacionado ao problema conhecido como *Concept-Drift*. Portanto, pode-se inferir que o êxito de um modelo de negociação autônomo para o mercado acionário depende da sua capacidade de adaptação contínua ao ambiente, uma importante característica também observada por Hassan et al. (2013) e Hu et al. (2015).

<sup>7</sup> MATHWORKS. **Support Vector Machine Classifier**. 2017. Disponível em: <<https://www.mathworks.com/help/stats/fitsvm.html>>. Acessado em 4 de março de 2017.

Como já observado por Chevapatrakul (2013) e Sirohi, Mahato e Attar (2014), o emprego de dados mais recentes pode contribuir para o aumento da capacidade adaptativa do modelo de previsão. Deste modo, um processo de treinamento e teste efetuado de forma progressiva (janela deslizante) sobre o conjunto de dados, aparenta ser mais adequado ao tipo de problema abordado nesta pesquisa. Assim como desempenhado por Chevapatrakul (2013) e Sirohi, Mahato e Attar (2014), a progressão da janela a cada nova previsão mostra-se coerente, pois o classificador sempre será treinado com dados recentes. Este tipo de abordagem busca adaptação aos padrões de comportamento recentes do ambiente. Pois, como já observado por Malkiel (2003), muitos padrões de comportamento que possibilitavam ganhos financeiros parecem ter desaparecido depois que se tornaram públicos. Desta maneira, é perceptível que qualquer padrão repetitivo capaz de gerar algum lucro tende a ser rapidamente extinto.

Os treinamentos e testes dos classificadores foram desempenhados com a utilização de janela deslizante. Foi empregada uma janela com 2 anos de dados históricos, ou seja, 24 e 104 registros para os tempos gráficos mensal e semanal, respectivamente. A janela foi deslocada a cada novo teste. Desta maneira, o teste fora da amostra utilizado no experimento  $k$ , passou a fazer parte da base de treinamento no experimento  $k + 1$ . Esta metodologia incremental garante a atualização do sistema quanto às movimentações mais recentes do mercado.

### **3.1.7 Módulo 7 - Emissão de Sinais e Atuação**

#### **3.1.7.1 Proposta**

Este módulo é responsável por gerar sinais indicativos de entrada e saída de operações financeiras no mercado. Neste trabalho, o termo "sinal" especifica o envio de um indicativo de entrada ou saída de operação financeira em ativos do mercado acionário. Um sinal de entrada pode ser dos tipos: (i) "compra"; ou (ii) "venda a descoberto". Enquanto um sinal de saída pode ser dos tipos: (i) "venda", para encerramento de operações de "compra" em andamento; ou (ii) "compra", para encerramento de operações de "venda a descoberto" em curso.

Para emissão de sinais de entrada, são utilizadas informações fornecidas pelos Módulos 2, 3 e 6. E a emissão de sinais de saída depende de informações providas pelo Módulo 3.

Para emissão de um sinal de entrada, os seguintes passos são necessários:

1. requisitar ao Módulo 3 as tendências primária e secundária em andamento;
2. requisitar ao Módulo 6 as previsões para o mês e semana correntes.

A identificação da tendência em andamento é feita por meio das tendências detectadas para a semana e mês anteriores. Estes dados estão indisponíveis para a semana e mês correntes pois são calculados a partir dos valores de fechamento.

Os passos anteriores resultam em quatro indicadores, sendo dois para as tendências em andamento, semanal e mensal, e dois para as previsões de direção, semanal e mensal. O alinhamento direcional dos quatro indicadores resultam na emissão de um sinal provisório. Se ocorre alinhamento para cima, um sinal provisório de compra será emitido. E se o alinhamento é para baixo, será emitido um sinal provisório de venda a descoberto.

Os sinais provisórios gerados na etapa anterior são submetidos a um filtro através do indicador técnico RSI, gerado pelo Módulo 2. O RSI é um oscilador de momento, normalizado entre 0 e 100 que, de acordo com o seu criador, Wilder (1978), é capaz de identificar pontos sobrecomprados e sobrevendidos. Assim como indica Wilder (1978), o módulo considera pontos sobrecomprados aqueles com RSI superior a 70, e sobrevendidos aqueles com RSI inferior a 30. O filtro RSI utilizado aqui é calculado sobre os valores de fechamento da semana e dia anteriores. Desta maneira, sinais de entrada somente são validados se o RSI da semana e dia anteriores estiverem abaixo de 70 para sinais de compra, e acima de 30 para sinais de venda a descoberto. Os trabalhos de Fong, Si e Tai (2012) e Brasileiro et al. (2013) utilizam o indicador RSI de forma semelhante àquela utilizada aqui, mas em apenas um tempo gráfico.

Para que um sinal de saída seja emitido é necessário que alguma operação esteja em andamento. O monitoramento e encerramento da posição constitui o gerenciamento de risco, o qual deve encerrar a operação em momento oportuno por meio do envio de um sinal de saída contrário ao sinal de entrada que originou a posição em aberto.

É comum o gerenciamento de risco ser desempenhado por meio do envio de ordens *Stop Loss* (SL) e *Stop Gain* (SG), tendo como base a evolução positiva ou negativa do capital alocado no ativo. Por exemplo: Teixeira e Oliveira (2010) utilizam SG e SL de 10% e 3% respectivamente; já Hu et al. (2015) utilizam a variação limite de 5% para ambos os casos; no trabalho de Brasileiro et al. (2013) os autores fazem a otimização dos limites de *Stop Loss* e *Stop Gain* através de um algoritmo do tipo *Artificial Bee Colony* (ABC), sendo estes limites variando até 42% para SG, e até 6,3% para SL; já no trabalho de Chen e Chen (2016) foi definido valor apenas para SL, de 10%, sendo a quantidade de dias com capital alocado (*holding-period*), entre 5 a 20 dias, um segundo critério para encerramento da posição.

Embora comum, a utilização de *Stop Loss* e *Stop Gain* mostra-se incoerente com a estratégia de atuação do sistema proposto neste trabalho. Sendo o sistema guiado por movimentações multitemporais, e considerando a existência de ruídos advindos da volatilidade, entende-se que a determinação de um percentual de SL ou SG impõe limitações ao sistema. Visto que a abordagem utilizada foca movimentações de médio e longo prazo, e considerando os fatores apontados, propõe-se que a emissão de sinais de saída seja guiada por meio da detecção de descontinuidade da tendência em curso. Desta maneira, a emissão de um sinal de saída deve seguir os seguintes passos:

1. requisitar ao Módulo 3 informações sobre a tendência em andamento;
2. caso a tendência detectada seja diferente daquela que originou a operação de entrada, um sinal de saída será emitido.

Quanto ao modo de atuação, é possível que o sistema opere de duas formas distintas, descritas em seguida:

- autônoma: através de Acesso Direto ao Mercado (DMA - *Direct Market Access*), o sistema pode operar de modo autônomo, enviando ordens diretamente à BM&FBovespa. Neste modo, pode ser ainda necessário atuação do utilizador nos casos de venda a descoberto. Pois, dependendo da corretora de valores utilizada será necessário entrar em contato para efetivação de contrato de aluguel do ativo;
- envio de sinais: o sistema pode atuar de modo indireto através do envio de sinais por *e-mail*, *sms*, aplicativos para *smartphones*, etc. Neste caso, será necessário uma confirmação por parte do utilizador quanto à efetivação da operação no mercado. Deste modo, o sistema poderá iniciar o processo de acompanhamento para emissão do sinal de saída em momento oportuno.

### **3.1.7.2 Solução Desenvolvida para Avaliação**

Nesta etapa, foram desenvolvidas em linguagem de programação *java*, as rotinas necessárias para simulações de operação em mercado (*backtesting*) a partir da base de dados histórica. Foram observadas as questões operacionais e regras de negociação detalhadas na seção 3.2.

O gerenciamento de risco foi desempenhado por meio da verificação de descontinuidade da tendência secundária. Tendências primárias mostraram-se demasiadamente lentas, atrasando a saída, e tendências terciárias muito rápidas, em função da volatilidade do mercado.

## 3.2 Configuração do Ambiente de Avaliação

A seguir são detalhadas as configurações utilizadas nos experimentos desempenhados neste trabalho. São descritos: custos financeiros operacionais; *bid-ask spread*; o período considerado; tamanho dos lotes de ações; procedimentos para simulação de ordens de compra e venda; além da base de dados utilizada.

### 3.2.1 Custos Financeiros Operacionais

A simulação de operação em mercado (*backtesting*) possibilitou verificar o desempenho virtual financeiro da versão de avaliação do sistema sobre dados históricos do conjunto de ativos considerados. A contabilização de custos operacionais mostra-se essencial para uma avaliação adequada do desempenho financeiro. A Tabela 3.2 apresenta os custos considerados nas simulações deste trabalho.

Tabela 3.2 – Taxas consideradas na contabilização dos custos financeiros.

<b>Taxa</b>	<b>Valor</b>
Corretagem	R\$ 14,90
Emolumentos	0,005%
Liquidação	0,0275%
Aluguel (a.a.)	1,00%
Liquidação CBLC (a.a.)	0,25%

Os valores percentuais referentes a "Emolumentos" e "Liquidação" da Tabela 3.2 foram coletados no *site* da BM&FBovespa<sup>8</sup> em dezembro de 2016, onde estão disponibilizados sob o identificador "Pessoas físicas e demais investidores" da tabela "Emolumentos, Liquidação e Registro", disponibilizada no endereço eletrônico.

Os valores de "Corretagem" e "Liquidação CBLC" da Tabela 3.2 foram recuperados do *site* da corretora XP Investimentos (XPI)<sup>9</sup>, em dezembro de 2016. Na data da consulta aos custos operacionais desta corretora, constava isenção quanto à taxa de custódia para renda variável.

<sup>8</sup> BM&FBOVESPA. **Custos para o Mercado de Ações**. 2017. Disponível em: <<http://www2.bmfbovespa.com.br/pt-br/servicos/custos-e-tributos/custos-operacionais/acoes.aspx>>. Acessado em 4 de março de 2017.

<sup>9</sup> XP Investimentos. **Custos Operacionais**. 2017. Disponível em: <<https://www.xpi.com.br/comece-a-investir/custos-operacionais/>>. Acessado em 4 de março de 2017.



As taxas de aluguel podem variar a cada novo contrato firmado para cada ativo. Diante disto, foi utilizado um valor fixo de aluguel para todas as ações. O valor do campo "Aluguel (a.a.)" da Tabela 3.2 refere-se à taxa média de aluguel de 1,00% ao ano (a.a.), definida após consulta ao *site* de empréstimos registrados<sup>10</sup> da BM&FBovespa, feita em dezembro de 2016. Foram observadas as últimas taxas médias de empréstimo ao tomador, negociadas em um prazo de quinze dias úteis, sendo este o maior prazo disponibilizado para consulta. Como exemplo, na época da consulta, foram observadas as taxas médias a.a. de 0,40%, 0,46%, 0,60% e 0,29% para os ativos PETR4, VALE5, USIM5 e SUZB5, respectivamente.

Quanto à forma de contabilização dos custos listados na Tabela 3.2, os valores de "Corretagem", "Liquidação", e "Emolumentos" foram considerados a cada operação de entrada e saída. Além dos custos listados anteriormente, sobre operações de saída decorrentes de vendas a descoberto incidem também as taxas de "Aluguel" e "Liquidação CBLC", que de acordo com a corretora XPI (2017), devem ser calculadas considerando o valor pro rata, no dia seguinte à data de devolução das ações (D+1);

### 3.2.2 *Bid-Ask Spread*

O *bid-Ask spread* interfere no desempenho financeiro ao impedir que a operação seja executada no valor exato esperado pelo investidor. Diversas publicações (CHEN; SZETO, 2012; LIANG; NG, 2012; WU; CHANG, 2012; BEKIROS, 2013; BRASILEIRO et al., 2013; WU; YU; CHANG, 2014; XUE et al., 2015) não consideram a existência de *bid-Ask spread*, sendo comum a utilização dos valores absolutos de abertura ou fechamento para simulações de operações. Neste trabalho é entendido que a utilização dos valores de abertura ou fechamento, sem contabilizar nenhum tipo de perda, conflita com a realidade.

Ao considerar a impossibilidade de execução da ordem no preço desejado, este trabalho, assim como feito por Bijl et al. (2016), contabilizou uma perda de 0,04% por operação. Nas simulações realizadas neste trabalho, as operações foram efetuadas no valor de abertura do dia útil seguinte à emissão do sinal, sendo contabilizado um custo adicional de 0,04% por operação.

---

<sup>10</sup> BM&FBovespa. **Empréstimos Registrados**. 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/servicos/emprestimo-de-ativos/emprestimos-registrados.htm](http://www.bmfbovespa.com.br/pt_br/servicos/emprestimo-de-ativos/emprestimos-registrados.htm)>. Acessado em 4 de março de 2017.

### 3.2.3 Período e Quantidades

O período utilizado nas simulações de operações financeiras foi de 01/01/2010 a 31/08/2016, o que corresponde a 6 anos e 8 meses. Em cada simulação foi utilizado o capital inicial hipotético de R\$100.000,00, sendo este capital atualizado com base nos resultados obtidos na evolução das negociações. Buscou-se empregar todo o capital disponível a cada operação de entrada.

A quantidade de ações negociadas em cada operação dependeu do valor da ação naquela data, bem como do capital disponível. As ações foram negociadas em lotes fechados. A quantidade de ações por lote foi definida tendo como base informações<sup>11</sup> sobre lotes de negociação disponibilizados pela BM&FBovespa. Neste site, a grande maioria dos ativos possui quantia de ações por lote definida para 100, portanto este valor foi utilizado. Desta maneira, a quantidade mínima de ações por operação foi de 100, e a quantia máxima foi definida em um valor múltiplo de 100.

Como as negociações foram efetuadas com base em lotes de ações, o capital total disponível dificilmente foi empregado por completo nas simulações. O valor total da operação de entrada foi definido a partir do produto resultante do preço da ação, pela quantidade máxima de ativos, calculada com base no tamanho do lote. O valor restante da operação foi tratado como um valor residual. Este valor residual, após o pagamento dos custos operacionais, foi somado novamente ao montante após o encerramento da operação.

Antes da efetivação da operação foi verificado se o valor residual seria suficiente para o pagamento dos custos operacionais. Em caso negativo, o montante inicialmente considerado para a negociação foi decrescido de 100 ações (1 lote), até que o valor residual fosse suficiente para o pagamento das taxas. Este procedimento foi necessário apenas para as operações de entrada, nas operações de saída as taxas foram descontadas após encerramento da posição.

### 3.2.4 Base de Dados

O universo inicial de ativos foi restringido ao grupo de ações compostas pelo Índice Brasil 50 (IBrX-50)<sup>12</sup>. Foi utilizado este índice pois trata-se de um indicador de desempenho médio dos ativos de maior negociabilidade e representabilidade do mercado de ações brasileiro

<sup>11</sup> BM&FBOVESPA. **Lotes de Negociação**. 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/servicos/market-data/consultas/mercado-a-vista/lotos-de-negociacao/](http://www.bmfbovespa.com.br/pt_br/servicos/market-data/consultas/mercado-a-vista/lotos-de-negociacao/)>. Acessado em 4 de março de 2017.

<sup>12</sup> BM&FBOVESPA. **Índice Brasil 50 (IBrX-50)**. 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/produtos/indices/indices-amplos/indice-brasil-50-ibrx-50.htm](http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-brasil-50-ibrx-50.htm)>. Acessado em 4 de março de 2017.

(BM&FBOVESPA, 2017). Foi considerada a composição do índice vigente em 10/08/2016, data em que o arquivo de composição do índice foi recuperado no *site*<sup>13</sup> da BM&FBovespa. A Tabela 3.3 apresenta a lista das ações pertencentes ao índice IBrX-50 em agosto de 2016.

Foram recuperados os dados de movimentação histórica diária, semanal e mensal, disponíveis no intervalo fechado de 01/01/2003 a 31/08/2016, para todas as ações listadas na Tabela 3.3. Algumas ações, por terem sido incluídas na BM&FBovespa após a data inicial considerada, não possuem dados a partir de 2003 exatamente, neste caso, a fonte de dados utilizada disponibilizou o arquivo com todos os dados existentes após o período inicial informado.

### 3.3 Comparativos

Esta seção descreve os parâmetros de referência (*baselines*) adotados para comparação com os resultados financeiros alcançados pelo sistema desenvolvido para verificação da proposta.

#### 3.3.1 Eficiência do Mercado Segundo a HME

O sistema proposto testa a Hipótese do Mercado Eficiente (HME) em sua forma fraca, pois a tomada de decisão é feita a partir de dados provenientes da própria movimentação histórica do ativo. A HME assume não ser possível auferir lucros excessivos, de forma consistente, com regras de negociação baseadas em qualquer tipo de informação. Neste sentido, Fama (1970) afirma que, se há eficiência de mercado, não será possível a obtenção de um retorno financeiro líquido consistente superior àquele alcançado pelo emprego de um *Buy-and-Hold* simples.

Neste trabalho, o desempenho B&H simples foi apurado com a efetivação de duas operações sobre cada ativo, sendo uma operação de compra, efetuada no primeiro dia considerado no experimento (01/01/2010), e uma operação de venda, efetiva no último dia (31/08/2016). Sobre estas operações foram aplicadas as mesmas regras descritas no tópico 3.2.3, para: capital inicial; quantidade de ações negociadas; e contabilização dos custos operacionais. O B&H simples reflete o desempenho do próprio ativo ao longo do tempo, ou seja, reflete o desempenho do mercado.

---

<sup>13</sup> BM&FBOVESPA. **Índice Brasil 50 (IBrX-50)**. 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/produtos/indices/indices-amplos/indice-brasil-50-ibrx-50-composicao-da-carreira.htm/](http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-brasil-50-ibrx-50-composicao-da-carreira.htm/)>. Acessado em 10 agosto de 2016.

Tabela 3.3 – Lista de ações compostas pelo índice IBrX-50 em Agosto de 2016.

<b>Código</b>	<b>Descrição</b>
ABEV3	AMBEV S/A
BBAS3	BRASIL
BBDC3	BRADESCO
BBDC4	BRADESCO
BBSE3	BBSEGURIDADE
BRAP4	BRADESPAR
BRFS3	BRF SA
BRKM5	BRASKEM
BRML3	BR MALLS PAR
BVMF3	BMFBOVESPA
CCRO3	CCR SA
CIEL3	CIELO
CMIG4	CEMIG
CPFE3	CPFL ENERGIA
CSAN3	COSAN
CSNA3	SID NACIONAL
CTIP3	CETIP
EMBR3	EMBRAER
EGIE3	ENGIE
EQTL3	EQUATORIAL
ESTC3	ESTACIO PART
FIBR3	FIBRIA
GGBR4	GERDAU
GOAU4	GERDAU MET
HYPE3	HYPERMARCAS
ITSA4	ITAUSA
ITUB4	ITAUUNIBANCO
JBSS3	JBS
KLBN11	KLABIN S/A
KROT3	KROTON
LAME4	LOJAS AMERIC
LREN3	LOJAS RENNER
MRVE3	MRV
MULT3	MULTIPLAN
NATU3	NATURA
PCAR4	P.ACUCAR-CBD
PETR3	PETROBRAS
PETR4	PETROBRAS
QUAL3	QUALICORP
RADL3	RAIADROGASIL
SBSP3	SABESP
SMLE3	SMILES
SUZB5	SUZANO PAPEL
TIMP3	TIM PART S/A
UGPA3	ULTRAPAR
USIM5	USIMINAS
VALE3	VALE
VALE5	VALE
VIVT4	TELEF BRASIL
WEGE3	WEG

Foram comparados os desempenhos alcançados com B&H àqueles obtidos nas simulações do sistema proposto. A verificação do nível de eficiência do mercado foi efetuada por meio da medida de desempenho *Return On Investment* (ROI). Esta medida calcula o percentual de retorno financeiro obtido ao final de cada experimento.

### 3.3.2 Cruzamento de Médias Móveis

Em análise técnica, o termo *Golden Cross*, ou *Moving Average Crossovers*, diz respeito ao uso do cruzamento de médias móveis como indicador de momento de entrada e saída em operações (EDWARDS; MAGEE; BASSETTI, 2001; ROMEU; SERAJUDDIN, 2001; STOCK-CHARTS, 2017a). Em um estudo publicado por ETFHQ (2017), foram conduzidos experimentos com diferentes tipos de médias móveis, e inúmeras configurações, de forma a verificar os melhores resultados deste tipo de estratégia sobre uma extensa base de dados histórica de ativos acionários. Os melhores resultados alcançados por ETFHQ (2017) foram obtidos com o emprego de duas médias móveis exponenciais de 13 e 48,5 períodos, sobre o tempo gráfico diário.

Foi desenvolvido em linguagem de programação *Java* um módulo para simulação do desempenho financeiro a partir de sinais gerados com o cruzamento de médias móveis. Foram utilizadas duas médias móveis exponenciais (EMA - *Exponential Moving Average*), de 13 (EMA-13) e 48 (EMA-48) períodos. Não foi utilizada a média móvel exponencial de 48,5 períodos, pois a biblioteca<sup>14</sup> utilizada para cálculo de médias móveis permite somente valores inteiros. Mas como pode ser observado nos resultados apresentados por ETFHQ (2017), a variação percentual de retorno anualizado na faixa de médias móveis entre 47 e 50 períodos é de apenas 0,26%.

A partir do cálculo das médias móveis exponenciais de 13 e 48 períodos, para o tempo gráfico diário, os seguintes sinais de negociação foram gerados:

- compra: quando EMA-13 cruza para cima EMA-48;
- venda: quando EMA-13 cruza para baixo EMA-48.

Neste tipo de estratégia, a operação é sempre iniciada com uma compra, e finalizada com a venda. Como o cruzamento de médias móveis consiste em um indicador de tendência

<sup>14</sup> TA-Lib. **Technical Analysis Library**. 2007. Disponível em: <<http://www.ta-lib.org/>>. Acessado em 4 de março de 2017.

de mercado, a operação é iniciada com a detecção do início de uma tendência de alta, sendo encerrada com a detecção de término do movimento.

Foram aplicadas as mesmas regras utilizadas na simulação do sistema, descritas no tópico 3.2.3. Foi considerado também o fator relativo ao *bid-ask spread*, relatado no tópico 3.2.2.

A comparação de resultados entre médias móveis e o sistema desenvolvido foi efetuada por meio das medidas de desempenho: *Annual Rate of Return* (ARR), *Return On Investment* (ROI), *Maximum Drawdown* (MDD), *Average Rate of Return per Trade* (ARRT), *Average Annual Trades* (AAT), *Average Days Per Trade* (ADT), e *Time Rate with Capital Employed* (TRCE).

### 3.3.3 Estado da Arte

A forma de atuação empregada por Hu et al. (2015) é semelhante àquela utilizada no sistema proposto neste trabalho. Ambas estratégias baseiam-se apenas em dados históricos de movimentação do próprio mercado, e utilizam estratégias para detecção e seguimento de tendências. Portanto buscou-se fazer uma comparação de desempenho entre ambos. Para tal, seria necessário acesso aos mesmos dados históricos utilizados por Hu et al. (2015). No entanto, foi conseguido acesso aos dados históricos necessários apenas do índice *SSE-Composite*. Para efetuar os testes de desempenho no intervalo de janeiro de 2001 a julho de 2013 foram necessários dados desde 1995. Os quatro primeiros anos, de 1995 a 1998, foram utilizados para gerar os indicadores técnicos necessários para o treinamento a partir de 1999, e testes de 2001 em diante. Os resultados foram comparados por meio das medidas de desempenho ARR, ROI e AAT.

Os dados deste índice foram obtidos por meio do *site Yahoo Finance*, onde é identificado por *SSE Composite Index*, e possui o código "000001.SS". Sobre este índice foram simuladas operações com o sistema, bem como a aplicação de B&H simples. Para viabilizar a utilização do mesmo capital inicial, de R\$100.000,00, utilizado nas outras simulações, bem como a utilização de lotes com 100 ativos, foi necessário diminuir a magnitude dos valores de cotação. Por tratar-se de um índice, os valores de cotação expressos são geralmente elevados, neste caso, para o período considerado, as cotações de fechamento variaram entre 10125 e 60921. Os valores de "abertura", "máxima", "mínima", e "fechamento" foram então deslocados em duas casas decimais à esquerda. Desta forma, os valores de fechamento passaram a variar entre 10,125 e 60,921, o que possibilitou uma simulação mais realística. É importante ressaltar que esta mudança não influenciou nas medidas de desempenho empregadas.

Quanto aos custos sobre operações de compra e venda, foram aplicadas as mesmas taxas consideradas por Hu et al. (2015). Ou seja, 0,1% para operações de compra, e 0,2% para operações de venda. Quanto aos custos adicionais relativos às operações de venda a descoberto, foram consideradas as taxas de "Aluguel (a.a.)" e "Liquidação CBLC" listadas na Tabela 3.2, embora Hu et al. (2015) não tenham comentado sobre taxas ou aplicação deste tipo de operação em seu algoritmo.

### 3.4 Métricas de Avaliação

A seguir são apresentadas as métricas de avaliação empregadas neste trabalho. Primeiramente é descrita a medida utilizada para mensurar e comparar a precisão dos classificadores. E em seguida são apresentadas as medidas empregadas na avaliação dos resultados obtidos por meio das simulações de operação em mercado, desempenhadas neste trabalho.

#### 3.4.1 Desempenho Preditivo

O desempenho preditivo dos algoritmos ANN e SVM foi comparado quanto a capacidade de classificação correta entre as classes "alta" e "baixa", relativas à direção do próximo movimento do ativo. Para este fim, foi utilizada a seguinte medida de desempenho:

- *Hit Ratio* (HR): medida para cálculo do desempenho dos classificadores quanto ao percentual de acerto de direção das previsões. O HR é calculado por meio da equação:

$$HR = \frac{\sum_{t=1}^n x}{n} 100 \quad (3.4)$$

onde  $x$  denota o acerto (1) ou erro (0) de direção prevista pelo modelo, e  $n$  indica a quantidade total de amostras.

#### 3.4.2 Desempenho Financeiro

A avaliação dos resultados financeiros foi efetuada por meio de sete medidas de desempenho. As três primeiras são medidas comuns e de uso recorrente na literatura. Já as outras quatro medidas de desempenho foram definidas neste trabalho<sup>15</sup>, de forma a possibilitar maior

<sup>15</sup> Nas pesquisas realizadas não foram localizadas medidas semelhantes em uso. Estas medidas podem ter sido aplicadas em outros trabalhos, inclusive com outras nomenclaturas.

detalhamento nas análises e comparativos entre resultados. A seguir são apresentadas as sete medidas utilizadas para análise do desempenho financeiro:

- *Annual Rate of Return* (ARR): medida para cálculo da taxa anualizada de retorno sobre o investimento. Esta medida equivale ao cálculo da taxa composta anual de crescimento (CAGR - *Compound Annual Growth Rate*) (CHAN, 2009). A equação para cálculo do ARR é dada por:

$$ARR = \left( \frac{V_b}{V_a}^{\frac{1}{n}} - 1 \right) 100 \quad (3.5)$$

onde  $V_b$  denota o capital final acumulado,  $V_a$  representa o montante financeiro inicial, e  $n$  especifica a quantidade total de anos compreendida no período;

- *Return On Investment* (ROI): indicador econômico que possibilita medir o percentual de retorno financeiro alcançado com a estratégia de investimento empregada (PHILLIPS; PHILLIPS, 2006). O valor do ROI consiste na razão do lucro líquido, pelo custo do investimento. É dado pela seguinte equação:

$$ROI = \frac{V_b - V_a}{V_a} 100 \quad (3.6)$$

onde  $V_a$  representa o capital inicial, e  $V_b$ , o capital acumulado ao final do período considerado;

- *Maximum Drawdown* (MDD): é uma medida de risco, que consiste no maior retorno negativo acumulado no período (ALDRIDGE, 2010; AUER, 2015). É o percentual de perda máximo atingido pelo investimento, em relação ao último montante máximo (pico) alcançado. Quanto maior o valor do MDD, menos arriscado mostra-se o investimento. O MDD é calculado a partir da seguinte equação:

$$MDD = \frac{m - p}{p} 100 \quad (3.7)$$

onde  $p$  representa o maior valor financeiro alcançado (pico) pelo investimento até o momento. E  $m$  especifica o menor valor atingido pelo investimento desde o último pico;



- **Percentual Médio de Retorno por Operação (ARRT - *Average Rate of Return per Trade*):** medida de desempenho que calcula o retorno percentual médio resultante de cada operação efetivada no mercado. A medida ARRT é dada pela seguinte equação:

$$ARRT = \frac{\sum_{t=1}^n x}{n} 100 \quad (3.8)$$

onde  $n$  denota a quantidade total de operações efetivadas durante todo o período. E  $x$  especifica o retorno percentual resultante de cada operação. O valor de  $x$  é obtido a partir da seguinte equação:

$$x = \frac{v_b - v_a}{v_a} \quad (3.9)$$

onde  $v_a$  especifica o valor inicial, antes do início da operação, e  $v_b$  o valor final, após o encerramento da operação;

- **Média Anual de Operações (AAT - *Average Annual Trades*):** esta medida retorna a média anual de operações unitárias efetuadas. Sendo cada operação, de entrada ou saída, contabilizada isoladamente. Esta medida de desempenho possibilita verificar a constância de atuação do sistema ou estratégia empregada. A equação para cálculo do AAT é dada por:

$$AAT = \frac{\sum_{t=1}^n}{y} \quad (3.10)$$

onde  $n$  especifica a quantidade total de operações isoladas. E  $y$  denota a quantidade total de anos do período considerado;

- **Média de Dias por Operação (ADT - *Average Days Per Trade*):** medida que retorna a quantidade média de dias decorridos entre a entrada e a saída das operações. A medida ADT é definida pela seguinte equação:

$$ADT = \frac{\sum_{t=1}^n k}{n} \quad (3.11)$$

onde  $k$  denota a quantidade de dias transcorridos em cada operação. E  $n$  especifica a quantidade total de operações realizadas durante o período considerado;

- Percentual de Tempo com Capital Alocado (TRCE - *Time Rate with Capital Employed*): esta medida de desempenho retorna o percentual de tempo em que o sistema, ou estratégia, permaneceram com o capital empregado, levando-se em conta o período completo. Desta maneira, a medida TRCE possibilita verificar o percentual de tempo médio em que a estratégia esteve fora de operação, e portanto, não utilizando o capital. Esta informação é importante em função da possibilidade de alocação do capital em algum outro investimento. O TRCE é obtido a partir da seguinte equação:

$$TRCE = \frac{A}{T} 100 \quad (3.12)$$

onde  $A$  especifica a soma do tempo total de todas as operações no período. E  $T$  denota o tempo total do período considerado. O valor de  $A$  é dado pela seguinte equação:

$$A = \sum_{t=1}^n T_b - T_a \quad (3.13)$$

onde  $T_a$  e  $T_b$  especificam respectivamente as datas de entrada e saída da operação. E  $n$  denota a quantidade total de operações realizadas no período.

## 4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados e discutidos os resultados obtidos com a execução das simulações de operação sobre dados históricos. Primeiramente, são descritos os resultados provenientes da etapa de previsão de comportamento, onde são comparados os algoritmos SVM e ANN. Em seguida, o desempenho financeiro alcançado pelo sistema proposto é detalhado e comparado àqueles atingidos com B&H simples, e pela estratégia com Cruzamento de Médias Móveis. E por fim, é feita a comparação dos resultados obtidos com o sistema, com aqueles alcançados pelo estado da arte.

### 4.1 Previsão de Comportamento

Para que os testes com dados fora da amostra fossem efetuados a partir de 01/01/2010, foram necessárias janelas históricas iniciais de 24 e 104 registros para os tempos gráficos mensal e semanal, respectivamente. Para tal, foi necessário o cálculo do grupo de indicadores desde 01/01/2008. O cálculo de alguns destes indicadores exigiu até 4 anos de dados históricos, ou seja, foram necessários dados desde 2004. Desta maneira, por falta de movimentações históricas necessárias para o cálculo de alguns indicadores técnicos, foi necessário desconsiderar um total de 17 ações. A relação com os ativos removidos por falta de histórico pode ser consultada na Tabela 4.1, sendo estes identificados pela frase "Histórico insuficiente", da coluna "Motivo".

Além de ações com histórico insuficiente, a Tabela 4.1 exhibe três outros ativos removidos do experimento por apresentarem inconsistência nos dados históricos coletados. As ações FIBR3 e UGPA3 apresentaram descontinuidade na linha do tempo, como pode ser observado pelas Figuras 4.1 e 4.2. Enquanto a ação LREN3 apresentou inconsistência em valores de fechamento (Figura 4.3). Desta maneira, no total, 20 ativos foram desconsiderados.

O desempenho *Hit Ratio* (HR) médio alcançado por cada classificador é apresentado na Tabela 4.2. As colunas "Semanal" e "Mensal" identificam os tempos gráficos semanal e mensal respectivamente. Devido a natureza não determinística da rede neural empregada, o experimento com *Artificial Neural Network* (ANN) foi repetido por 10 vezes para cada ação, a cada tempo gráfico. Portanto, o resultado apresentado para o algoritmo ANN equivale à média aritmética sobre o HR de 10 execuções. A Tabela 4.2 mostra que, em média, *Support Vector Machine* (SVM) e ANN conseguiram prever a direção correta do ativo em 87,86% e 85,06%, respectivamente. O desempenho HR foi o único critério para escolha do classificador.

Tabela 4.1 – Relação de ativos desconsiderados nas simulações.

<b>Ação</b>	<b>Data Inicial</b>	<b>Motivo</b>
BBDC4	02/01/2008	Histórico insuficiente
BBSE3	29/04/2013	Histórico insuficiente
BRML3	05/04/2007	Histórico insuficiente
BVMF3	09/05/2011	Histórico insuficiente
CIEL3	29/06/2009	Histórico insuficiente
CTIP3	28/10/2009	Histórico insuficiente
EQTL3	07/04/2008	Histórico insuficiente
ESTC3	11/07/2008	Histórico insuficiente
FIBR3	01/01/2003	Descontinuidade
HYPE3	18/04/2008	Histórico insuficiente
JBSS3	29/03/2007	Histórico insuficiente
KROT3	14/03/2012	Histórico insuficiente
KLBN11	23/01/2014	Histórico insuficiente
LREN3	01/01/2003	Inconsistência
MRVE3	23/07/2007	Histórico insuficiente
MULT3	27/07/2007	Histórico insuficiente
PCAR4	02/01/2008	Histórico insuficiente
QUAL3	29/06/2011	Histórico insuficiente
SMLE3	29/04/2013	Histórico insuficiente
UGPA3	02/01/2003	Descontinuidade

Figura 4.1 – Gráfico semanal do ativo FIBR3, no período de 01/01/2003 a 31/08/2016. Espaçamentos maiores retílineos entre pontos do gráfico exibem inconsistência nos dados.




Figura 4.2 – Gráfico semanal do ativo UGPA3, no período de 01/01/2006 a 31/08/2016. Espaçamentos maiores retilíneos entre pontos do gráfico exibem inconsistência nos dados.




Figura 4.3 – Gráfico semanal do ativo LREN3, no período de 01/01/2006 a 31/08/2016. Inconsistências devido à grande variação entre valores de fechamento subsequentes.



Portanto, as previsões semanais e mensais do algoritmo SVM, sobre os dados fora da amostra entre 01/01/2010 e 31/08/2016, foram utilizadas nas simulações de operação em mercado.

Tabela 4.2 – Desempenho *Hit Ratio* de SVM e ANN, nos tempos gráficos semanal e mensal, para o grupo de ativos considerados.

Ativo	SVM		ANN	
	Semanal	Mensal	Semanal	Mensal
ABEV3	84,48	85,00	82,39	87,00
BBAS3	89,37	85,00	87,27	76,00
BBDC3	87,36	90,00	85,34	81,00
BRAP4	87,93	90,00	86,26	84,75
BRFS3	87,93	91,25	85,55	89,50
BRKM5	91,95	87,50	88,82	81,75
CCRO3	83,91	90,00	81,64	88,88
CMIG4	87,93	80,00	86,38	76,13
CPFE3	89,08	87,50	88,05	85,63
CSAN3	87,93	87,50	87,21	87,88
CSNA3	87,64	90,00	85,23	84,50
EGIE3	85,92	87,50	83,10	81,25
EMBR3	86,21	93,75	85,34	88,50
GGBR4	90,03	90,00	88,86	85,38
GOAU4	90,52	90,00	88,68	88,13
ITSA4	83,91	85,00	82,27	75,38
ITUB4	85,59	82,50	84,27	74,00
LAME4	86,06	86,84	84,39	83,55
NATU3	87,36	90,00	86,01	87,13
PETR3	91,67	90,00	90,12	88,38
PETR4	91,86	87,50	90,76	85,63
RADL3	88,51	92,50	87,04	86,88
SBSP3	86,78	92,50	84,40	90,75
SUZB5	88,22	86,25	85,57	83,13
TIMP3	86,21	87,50	84,00	87,75
USIM5	88,76	90,00	88,13	85,13
VALE3	86,78	82,50	83,28	79,00
VALE5	86,74	90,00	84,47	86,38
VIVT4	87,64	88,75	84,45	89,38
WEGE3	83,33	87,50	82,30	83,25
<b>Média</b>	<b>87,59</b>	<b>88,14</b>	<b>85,72</b>	<b>84,40</b>
<b>Média Geral</b>	<b>87,86</b>		<b>85,06</b>	

A Seleção de Características (SC) por meio de FDR e CCP permitiu identificar os indicadores técnicos mais significativos a cada etapa de previsão. Foi alcançada redução média na dimensão dos dados em 94,6% e 92,9%, para os tempos gráficos semanal e mensal respectivamente. A redução da dimensionalidade não impactou o desempenho preditivo dos classificadores. Em média, foram utilizados 2,3 indicadores a cada previsão semanal, e 3,03 indicadores a

cada previsão mensal. As Tabelas 4.3 e 4.4 exibem respectivamente, para os tempos gráficos semanal e mensal, os 10 indicadores técnicos mais selecionados para treinamentos e previsões de direção dos ativos no período de 01/01/2010 a 31/08/2016.

Tabela 4.3 – Relação com os 10 indicadores técnicos mais utilizados para previsões semanais.

<b>Indicador</b>	<b>%</b>
willr	93,70
minus_dm	37,48
minus_di	28,60
stoch	18,45
natr	10,19
mfi	6,69
stochf	4,46
aroonosc	3,32
plus_di	3,16
stochrsi	3,09

Tabela 4.4 – Relação com os 10 indicadores técnicos mais utilizados para previsões mensais.

<b>Indicador</b>	<b>%</b>
willr	52,50
var	27,55
natr	23,91
sar	23,83
minus_dm	15,19
trix	13,27
ultosc	13,02
stochf	12,19
stochrsi	12,10
stoch	11,39

Para exemplificar, as Tabelas 4.5 e 4.6 mostram respectivamente os indicadores técnicos utilizados para previsões mensais e semanais do ano de 2015, para o ativo ABEV3. Os indicadores utilizados a cada etapa foram selecionados pelo módulo de SC. Em 2015, o SVM conseguiu HR semanal e mensal para ABEV3 de 84,62% e 91,67%, respectivamente.

Tabela 4.5 – Indicadores técnicos utilizados para previsões semanais de ABEV3 em 2015.

<b>Período</b>	<b>Indicadores</b>
05/01/2015	mfi, stoch, willr
12/01/2015	adx, mfi, rsi, stoch, ultosc
19/01/2015	adx, macd_hist, rsi, ultosc
26/01/2015 a 16/02/2015	adxr, macd_hist, rsi, ultosc
23/02/2015	adxr, rsi, ultosc
02/03/2015 a 18/05/2015	adxr, willr
25/05/2015	adxr, ppo, willr
01/06/2015 a 12/10/2015	adxr, plus_di, ppo, willr
19/10/2015	adxr, plus_di, willr
26/10/2015 a 02/11/2015	adxr, plus_di, ppo, willr
09/11/2015	adxr, cci, plus_di
16/11/2015	adxr, plus_di, willr
23/11/2015	adxr, plus_di, ppo, willr
30/11/2015 a 14/12/2015	plus_di, willr
21/12/2015	adx, willr
28/12/2015	natr, willr

Tabela 4.6 – Indicadores técnicos utilizados para previsões mensais de ABEV3 em 2015.

<b>Período</b>	<b>Indicadores</b>
Janeiro a Março	sar, willr
Abril a Junho	cci, sar, var
Julho a Setembro	sar, var
Outubro	sar, willr
Novembro a Dezembro	plus_di, willr



## 4.2 Simulações com Dados Históricos e Comparações

As simulações de operação do sistema sobre dados históricos foram conduzidas para os 30 ativos utilizados na etapa de previsão. A Tabela 4.7 exibe o desempenho resultante com a atuação do sistema no período de 01/01/2010 a 31/08/2016, sobre cada um dos ativos considerados.

Tabela 4.7 – Desempenho das simulações de atuação do sistema entre 01/01/2010 e 31/08/2016, para o conjunto de ativos considerados.


<b>Ação</b>	<b>ROI</b>	<b>ARR</b>	<b>MDD</b>	<b>ARRT</b>	<b>AAT</b>	<b>ADT</b>	<b>TRCE</b>
ABEV3	258,30	21,09	-3,34	15,07	3,03	75,50	31,02
BBAS3	12,69	1,81	-8,94	2,27	1,82	62,00	15,28
BBDC3	14,33	2,03	-26,58	1,57	4,24	43,43	24,98
BRAP4	124,36	12,88	-3,32	9,27	3,03	65,00	26,71
BRFS3	93,78	10,43	-5,72	5,84	3,94	65,38	34,92
BRKM5	46,52	5,90	-14,58	6,65	2,12	65,71	18,90
CCRO3	85,56	9,71	-4,73	7,26	3,03	50,70	20,83
CMIG4	58,04	7,10	-20,30	6,02	3,03	62,20	25,55
CPFE3	61,15	7,42	-3,67	6,47	2,42	67,38	22,14
CSAN3	132,14	13,46	-1,35	24,97	1,21	131,25	21,57
CSNA3	88,22	9,95	0,00	11,39	1,82	72,83	17,95
EGIE3	83,74	9,55	-4,40	6,22	3,33	77,91	35,21
EMBR3	68,56	8,14	-5,23	6,72	2,73	88,67	32,79
GGBR4	140,79	14,09	-8,99	11,02	2,73	57,56	21,28
GOAU4	129,82	13,29	-12,87	17,37	1,82	97,00	23,91
ITSA4	9,70	1,40	-11,63	1,27	3,03	52,60	21,61
ITUB4	9,91	1,43	-16,01	1,25	3,03	47,90	19,68
LAME4	35,06	4,61	-9,88	3,32	3,33	64,55	29,17
NATU3	119,25	12,49	-9,51	11,47	2,42	79,38	26,09
PETR3	22,82	3,13	-14,26	3,14	2,42	61,38	20,17
PETR4	52,26	6,51	-17,22	5,69	2,73	60,89	22,51
RADL3	365,56	25,94	-0,29	26,35	2,12	118,43	34,06
SBSP3	156,44	15,17	-21,33	11,07	3,33	68,00	30,73
SUZB5	163,52	15,64	0,00	22,41	1,52	95,40	19,60
TIMP3	34,86	4,59	-22,25	4,30	2,73	72,33	26,75
USIM5	257,70	21,06	-12,66	19,77	2,42	83,00	27,28
VALE3	49,47	6,21	-8,97	4,74	3,03	74,20	30,48
VALE5	55,89	6,89	-11,36	5,28	3,03	76,60	31,47
VIVT4	32,19	4,27	-8,96	3,14	3,03	52,10	21,41
WEGE3	161,61	15,51	-4,84	9,85	3,33	72,09	32,58
<b>Média</b>	<b>97,47</b>	<b>10,74</b>	<b>-9,77</b>	<b>9,04</b>	<b>2,73</b>	<b>72,05</b>	<b>25,55</b>

A "Média", contida nas Tabelas 4.7, 4.8 e 4.9, é calculada por meio da média aritmética dos valores de cada medida de desempenho, exceto para a medida ARR. O ARR médio foi obtido através da Fórmula 3.5, com a utilização de um montante financeiro inicial hipotético qualquer, e capital final acumulado calculado a partir do valor médio da medida ROI.

O maior retorno financeiro acumulado pelo sistema foi alcançado sobre o ativo RADL3. Neste ativo, como pode ser observado pela Tabela 4.7, foi obtido um ROI de 365,56%, e ARR de 25,94%. O MDD obtido em RADL3 foi de -0,29%. Ou seja, durante todo o período de atuação sobre este ativo, a taxa de contração máxima do capital acumulado, em relação ao montante histórico máximo alcançado, foi de -0,29%. Ao todo, sobre o ativo RADL3, foram efetuadas 14 operações, sendo 7 operações de entrada, todas de compra, e 7 operações de saída. O retorno percentual médio por operação finalizada em RADL3 foi de 26,35%, expresso por ARRT. A medida AAT indica que foram efetuadas sobre RADL3, em média, 2,12 operações unitárias por ano. A duração média de uma posição sobre RADL3 foi de 118,43 dias, expresso pela medida ADT. E durante todo o período considerado, a medida TRCE aponta utilização do capital em 34,06% do tempo.

A Figura 4.4 exibe o gráfico com a evolução do capital inicial investido, de R\$100.000,00, sobre a simulação de atuação do sistema sobre o ativo RADL3. Ao final da simulação, em 31/08/2016, o capital acumulado foi de R\$465.560,80.

Figura 4.4 – Evolução do capital investido sobre o ativo RADL3, com a aplicação do sistema proposto.



A Figura 4.5 mostra o gráfico com o retorno percentual atingido em cada operação efetuada sobre RADL3, ao longo do período considerado. Apenas o primeiro resultado foi negativo (-0,29%).

A Figura 4.6 exibe o gráfico com as operações efetuadas pelo sistema sobre a ação RADL3, entre 01/01/2010 e 31/08/2016. Como pode ser observado pelo gráfico, todas as operações foram de "Compra", seguidas de uma operação contrária de venda ("Saída da Operação"). Sem definição de regras para *Stop Loss* ou *Stop Gain*, o sistema encerrou a posição ao detectar alteração na tendência secundária.

Figura 4.5 – Retorno percentual alcançado ao final de cada operação efetuada pelo sistema sobre o ativo RADL3.

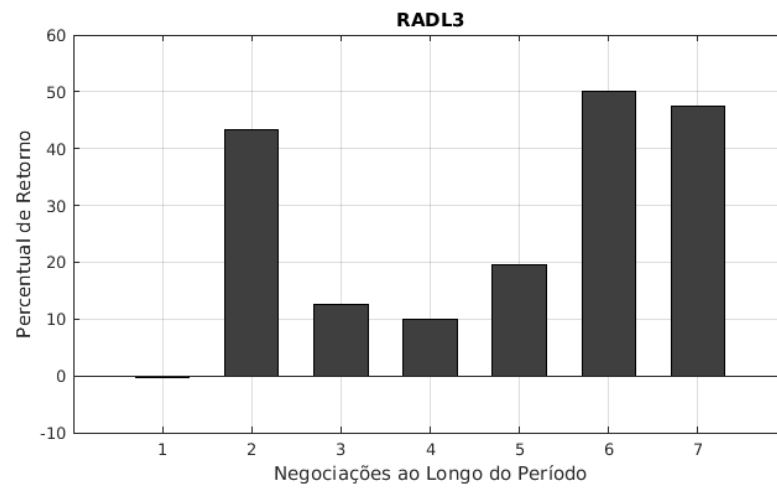



Figura 4.6 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema sobre o ativo RADL3.



O desempenho médio alcançado pelo sistema sobre o conjunto de ativos é exibido através da linha "Média" da Tabela 4.7. Como pode ser observado, o sistema conseguiu um percentual acumulado de retorno (ROI) médio de 97,47%, e uma taxa composta de retorno anual (ARR) média de 10,74%. Pode-se notar também por meio da medida TRCE, que em média o capital ficou em uso por 25,55% do tempo. O pior desempenho do sistema foi obtido no ativo ITSA4, com ROI e ARR de 9,70% e 1,40% respectivamente.

O encerramento de posições a partir da descontinuidade da tendência intermediária apresentou comportamento favorável. A duração média das operações com resultados positivos foi de 90,65 dias. Enquanto a média em operações com resultados negativos foi de 30,75 dias. Estes números sugerem viabilidade na utilização de estratégias baseadas em descontinuidade de tendências para o encerramento de posições.

#### 4.2.1 Comparação com *Buy-and-Hold* Simples

Foi calculado o desempenho *Buy-and-Hold* (B&H) para cada ativo utilizado nas simulações com o sistema proposto. A Tabela 4.8 mostra o desempenho B&H simples sobre as 30 ações consideradas. As medidas de desempenho ARRT, AAT e ADT não foram calculadas pois não se aplicam ao modo de operação B&H. A medida TRCE será sempre 100, pois neste tipo de estratégia o capital permanece em uso durante todo o período.

Tabela 4.8 – Desempenho das ações utilizadas nas simulações com o sistema proposto.


Ação	ROI	ARR	MDD	ARRT	AAT	ADT	TRCE
ABEV3	556,88	32,61	-21,35	-	-	-	100
BBAS3	19,96	2,77	-61,54	-	-	-	100
BBDC3	104,01	11,28	-41,56	-	-	-	100
BRAP4	-63,13	-13,90	-91,92	-	-	-	100
BRFS3	153,64	14,98	-39,07	-	-	-	100
BRKM5	111,26	11,87	-56,21	-	-	-	100
CCRO3	201,40	17,99	-45,45	-	-	-	100
CMIG4	-23,62	-3,96	-80,69	-	-	-	100
CPFE3	109,28	11,71	-42,68	-	-	-	100
CSAN3	102,78	11,18	-57,36	-	-	-	100
CSNA3	-53,63	-10,89	-88,99	-	-	-	100
EGIE3	145,69	14,43	-20,03	-	-	-	100
EMBR3	62,16	7,52	-53,68	-	-	-	100
GGBR4	-63,97	-14,19	-88,37	-	-	-	100
GOAU4	-86,06	-25,58	-97,32	-	-	-	100
ITSA4	45,28	5,76	-40,25	-	-	-	100
ITUB4	53,92	6,68	-41,14	-	-	-	100
LAME4	157,45	15,24	-34,49	-	-	-	100
NATU3	16,84	2,36	-63,73	-	-	-	100
PETR3	-58,30	-12,29	-84,73	-	-	-	100
PETR4	-60,43	-12,98	-87,55	-	-	-	100
RADL3	572,72	33,09	-43,22	-	-	-	100
SBSP3	294,07	22,83	-56,09	-	-	-	100
SUZB5	-38,15	-6,95	-81,74	-	-	-	100
TIMP3	60,12	7,31	-58,93	-	-	-	100
USIM5	-84,91	-24,69	-97,18	-	-	-	100
VALE3	-51,38	-10,25	-81,72	-	-	-	100
VALE5	-52,69	-10,62	-84,19	-	-	-	100
VIVT4	99,01	10,87	-36,09	-	-	-	100
WEGE3	199,88	17,90	-53,56	-	-	-	100
<b>Média</b>	<b>81,01</b>	<b>9,31</b>	<b>-61,03</b>	-	-	-	<b>100</b>

O desempenho B&H reflete o comportamento do próprio ativo. A operação é iniciada com a compra da ação no primeiro dia, e finalizada com a venda no último dia do experimento. Os melhores resultados B&H ocorreram sobre os ativos RADL3 e ABEV3, com a obtenção de um percentual de retorno acumulado (ROI) de 572,72% e 556,88%, respectivamente. Já os

piores desempenhos foram sobre as ações GOAU4 e USIM5, com ROI de -86,06% e -84,91%, respectivamente.

A Figura 4.7 mostra o desempenho financeiro acumulado sobre a ação RADL3, tanto do sistema proposto quanto do resultado B&H. Embora o retorno acumulado tenha sido menor com o sistema, a manutenção do capital durante períodos de reversão, como nos que antecederam 2014 e 2016, mostra boa adaptabilidade do sistema quanto à movimentação do ativo. Os resultados alcançados sobre RADL3 mostram eficiência do mercado quanto à atuação do sistema sobre este ativo, pois o emprego de B&H conseguiu maior retorno financeiro.

Figura 4.7 – Desempenho financeiro do sistema, e resultado B&H sobre o ativo RADL3.



O melhor resultado do sistema sobre o emprego de B&H foi alcançado no ativo USIM5. Nesta ação, o sistema obteve 257,70% de ROI, enquanto B&H resultou em prejuízo, com uma contração de -84,91% do capital investido. Ainda neste ativo, enquanto o sistema obteve um MDD de -12,66%, B&H atingiu -97,18% para a mesma medida. A Figura 4.8 exibe o gráfico com a evolução do capital investido em USIM5, para ambas estratégias. As operações efetuadas pelo sistema sobre este ativo podem ser observadas por meio do gráfico apresentado pela Figura 4.9. Com exceção da primeira operação, todas as outras foram operações de venda a descoberto. Os resultados percentuais obtidos pelo sistema sobre USIM5 podem ser visualizados no gráfico exibido pela Figura 4.10.

Figura 4.8 – Evolução do capital investido sobre o ativo USIM5, com a aplicação do sistema proposto e B&H.


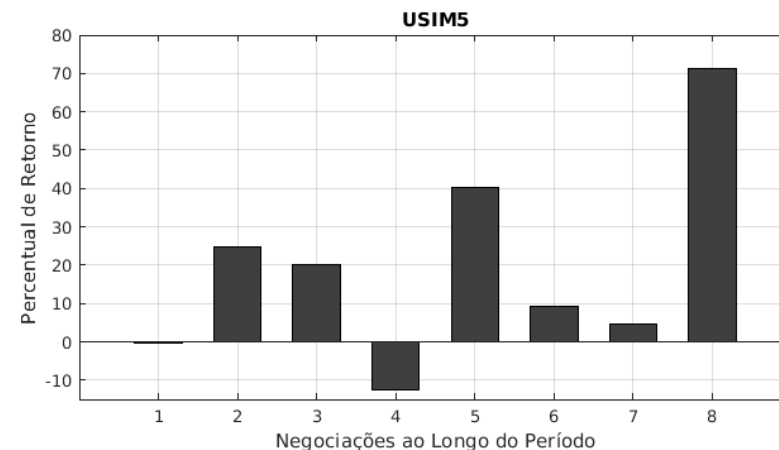


Figura 4.9 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema, sobre o ativo USIM5.



Figura 4.10 – Retorno percentual resultante de cada operação efetuada pelo sistema sobre o ativo USIM5.



O sistema também alcançou bons resultados sobre a ação SUZB5, quando comparado ao desempenho B&H. Enquanto os resultados ROI e MDD com B&H foram de respectivamente -38,15% e -81,74%, o sistema conseguiu 163,52% e 0% para as mesmas medidas. A Figura 4.11 mostra o gráfico com a evolução do capital resultante da aplicação de ambas as estratégias. Neste ativo, o capital foi utilizado pelo sistema em 19,60% do tempo. Como pode ser observado através do gráfico apresentado pela Figura 4.12, o sistema conseguiu atuação positiva nos dois modos, tanto na compra, quanto venda a descoberto. Todos os resultados foram positivos, como pode ser observado pelo gráfico exibido pela Figura e 4.13.

Figura 4.11 – Evolução do capital investido sobre o ativo SUZB5, com a aplicação do sistema proposto e B&H.


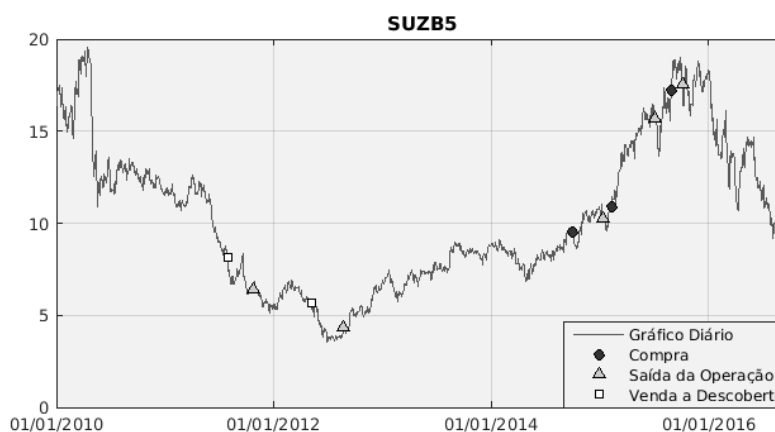


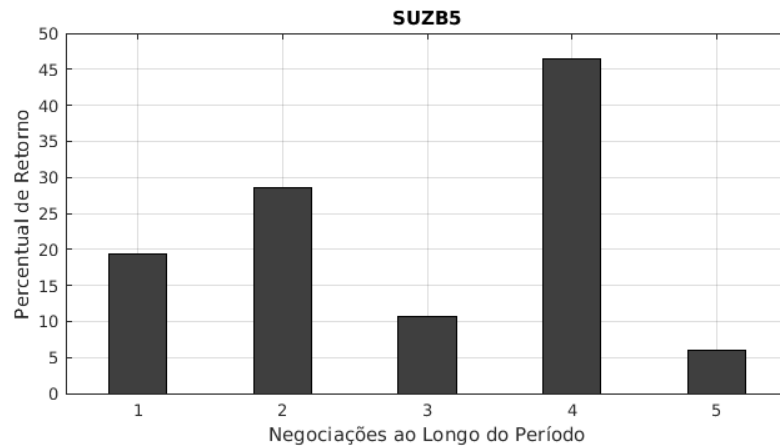
Figura 4.12 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema, sobre o ativo SUZB5.



O pior resultado do sistema ocorreu sobre a ação ITSA4, com valores de ROI, ARR e MDD de 9,70%, 1,40%, e -11,63% respectivamente. Neste mesmo ativo, o emprego de B&H atingiu valores respectivos de 45,28%, 5,76% e -40,25%, para as mesmas medidas. A Figura 4.14 apresenta o gráfico que mostra a evolução do capital com ambas estratégias. As atuações do sistema sobre o ativo ITSA4 podem ser observadas por meio do gráfico contido na Figura



Figura 4.13 – Retorno percentual resultante de cada operação efetuada pelo sistema sobre o ativo SUZB5.



4.15. Ao longo do período, o sistema efetuou 10 operações sobre ITSA4, com obtenção de resultados positivos em 4 delas. A Figura 4.16 apresenta o gráfico com o retorno percentual alcançado em cada atuação do sistema sobre este ativo. Como pode ser observado, o mercado mostrou-se eficiente quanto a utilização do sistema sobre o ativo ITSA4.

Figura 4.14 – Evolução do capital investido sobre o ativo ITSA4, com a aplicação do sistema proposto e B&H.

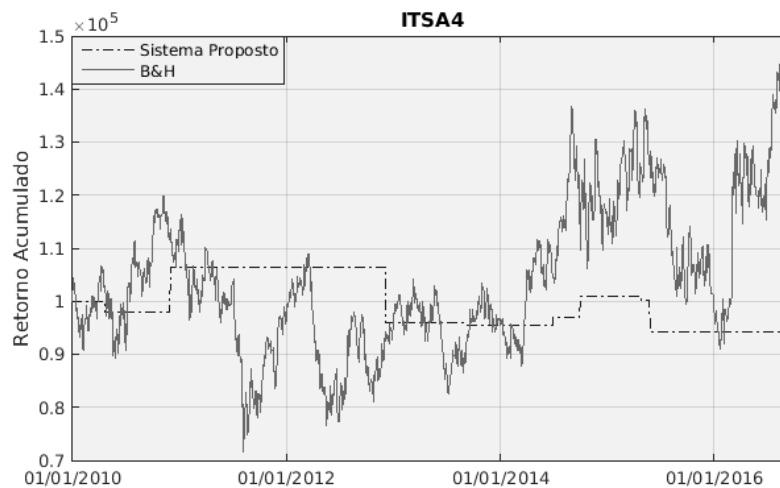


Figura 4.15 – Operações efetuadas entre 01/01/2010 e 31/08/2016 pelo sistema sobre o ativo ITSA4.


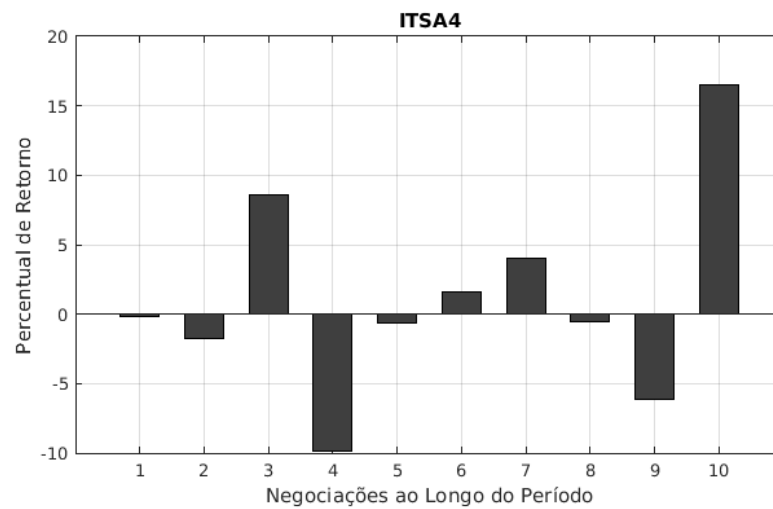


Figura 4.16 – Percentual de retorno a cada operação efetuada pelo sistema sobre o ativo ITSA4.



Os desempenhos médios alcançados com a aplicação de *Buy-and-Hold* sobre o conjunto de ativos podem ser consultados por meio do identificador "Média" da tabela 4.8. As médias ROI e ARR alcançados com B&H foram de respectivamente 81,01% e 9,31%, enquanto o sistema conseguiu respectivos 97,47% e 10,74% para as mesmas medidas. O valor MDD médio de -61,03% indica elevada volatilidade negativa na evolução do capital com o uso de B&H. Nesta mesma medida, o sistema obteve um valor médio de -9,77%, mostrando maior estabilidade. Já quanto ao desempenho individual por ativo, B&H conseguiu resultados financeiros superiores ao sistema em 53,33% dos casos, indicando eficiência do mercado.

#### 4.2.2 Comparação com Médias Móveis

Foram realizadas simulações de operação em mercado com a estratégia de Cruzamento de Médias Móveis (MM), para as 30 ações utilizadas nas simulações com o sistema proposto. A Tabela 4.9 apresenta os resultados alcançados com a estratégia MM para as 7 medidas de desempenho utilizadas.


Tabela 4.9 – Desempenho alcançado nas simulações de operação em mercado com a utilização da estratégia de cruzamento de médias móveis.

Ação	ROI	ARR	MDD	ARRT	AAT	ADT	TRCE
ABEV3	202,82	18,08	-25,97	7,30	6,36	86,33	74,49
BBAS3	-15,57	-2,51	-47,64	-0,12	7,58	44,84	46,06
BBDC3	-25,25	-4,27	-51,86	-0,45	8,48	45,82	52,71
BRAP4	18,78	2,61	-50,73	3,22	5,45	50,61	37,43
BRFS3	146,32	14,47	-14,44	6,69	4,85	100,56	66,11
BRKM5	148,92	14,65	-27,33	8,91	4,85	86,25	56,70
CCRO3	85,13	9,68	-33,76	4,63	6,06	80,60	66,23
CMIG4	141,72	14,15	-40,39	6,03	6,97	52,09	49,22
CPFE3	75,52	8,80	-21,86	4,62	4,85	78,69	51,73
CSAN3	129,54	13,27	-27,38	6,56	5,15	84,71	59,16
CSNA3	36,01	4,72	-50,19	4,72	5,76	49,74	38,82
EGIE3	40,06	5,18	-25,76	2,20	6,36	76,19	65,74
EMBR3	7,15	1,04	-39,28	1,08	5,76	72,37	56,49
GGBR4	-36,44	-6,57	-59,01	-1,33	5,45	59,67	44,12
GOAU4	33,03	4,37	-31,67	3,17	4,85	48,00	31,55
ITSA4	-30,84	-5,38	-45,74	-1,03	8,18	46,15	51,19
ITUB4	-12,08	-1,91	-42,14	-0,15	7,27	52,92	52,18
LAME4	89,46	10,06	-21,29	4,70	4,85	94,38	62,04
NATU3	26,93	3,64	-39,31	2,25	5,45	71,89	53,16
PETR3	59,92	7,29	-13,32	4,81	3,64	79,75	39,32
PETR4	56,43	6,94	-12,86	3,90	4,55	66,33	40,88
RADL3	286,85	22,49	-22,98	13,88	4,55	103,93	64,05
SBSP3	178,08	16,58	-21,47	6,96	6,67	75,09	67,87
SUZB5	34,51	4,55	-36,53	3,23	4,85	80,06	52,63
TIMP3	33,08	4,38	-34,82	2,97	5,76	69,95	54,60
USIM5	14,17	2,01	-34,71	2,68	5,15	54,59	38,13
VALE3	-58,63	-12,40	-68,53	-3,06	7,58	40,92	42,03
VALE5	-48,47	-9,46	-58,25	-2,62	6,67	49,68	44,91
VIVT4	19,67	2,73	-35,15	1,39	6,67	67,64	61,13
WEGE3	-12,03	-1,90	-49,83	0,69	6,06	76,85	63,15
<b>Média</b>	<b>54,16</b>	<b>6,70</b>	<b>-36,14</b>	<b>3,26</b>	<b>5,89</b>	<b>68,22</b>	<b>52,79</b>

A Tabela 4.9 mostra que o melhor resultado alcançado com MM foi obtido no ativo RADL3, com ROI de 286,85% e ARR de 22,49%. E o pior desempenho com MM ocorreu sobre VALE3, com ROI e ARR de respectivamente -58,63% e -12,40%.

As três estratégias obtiveram seu melhor desempenho sobre a ação RADL3. A Figura 4.17 exibe o gráfico com a evolução do capital resultante da aplicação das três estratégias: (i) Sistema Proposto, (ii) Cruzamento de Médias Móveis (MM), e (iii) *Buy-and-Hold* (B&H), sobre este ativo. Como pode ser observado pelo gráfico, o maior retorno acumulado ao final do experimento sobre RADL3 foi alcançado com B&H, seguido pelo sistema e por último pela estratégia MM.

Figura 4.17 – Evolução do capital investido sobre o ativo RADL3, com a utilização do sistema proposto, MM, e B&H.




A Figura 4.18 exibe o gráfico com a evolução do capital investido em VALE3, com a aplicação das três estratégias. A simulação do investimento inicial de R\$100.000,00 sobre a ação VALE3, com o emprego de B&H e MM, resultou em uma redução do capital inicial para R\$48.620,00 e R\$41.370,00, respectivamente. Já o sistema alcançou ao final do experimento o valor acumulado de R\$149.470,00.

Na comparação dos resultados sobre o ativo VALE3, a estratégia MM atingiu um MDD de -68,53%, frente a -8,97% atingido pelo sistema. Ainda neste ativo, a estratégia MM atuou 151% a mais que o sistema, com AAT de 7,58, enquanto o sistema obteve um valor de 3,03 para a mesma medida. Quanto ao tempo de utilização do capital (TRCE), enquanto MM utilizou em 42,03% do tempo, o sistema permaneceu com o capital alocado por 30,48%.


A estratégia com cruzamento de médias móveis conseguiu desempenho ROI superior ao sistema proposto em 8 ativos: BRFS3, BRKM5, CMIG4, CPFE3, LAME4, PETR3, PETR4 e SBSP3. Desta maneira, o sistema mostrou-se superior à estratégia MM em 73,33% dos casos. Um caso de sucesso com aplicação de MM pode ser observado pelo gráfico da Figura 4.19, onde a estratégia mostrou-se lucrativa mesmo com a desvalorização do ativo PETR4. Nas

Figura 4.18 – Evolução do capital investido sobre o ativo VALE3, com a utilização do sistema proposto, MM, e B&H.



simulações de desempenho sobre este ativo, o sistema proposto, MM, e B&H conseguiram respectivamente um desempenho ROI de 52,26%, 56,43% e -60,43%. O resultado sobre a ação PETR4 com MM mostrou-se superior também quanto à medida MDD, com -12,86%, frente a -17,22% do sistema e -87,55% de B&H. No entanto, nas medidas ARRT, AAT e TRCE o sistema mostrou-se superior. Com menos atuações (AAT menor), o retorno médio por operação (ARRT) foi superior com o sistema. Enquanto MM obteve um retorno de 3,90% por operação, o sistema conseguiu 5,69%. E enquanto MM manteve o capital alocado por 40,88% do tempo, o sistema permaneceu por 22,51%.

Figura 4.19 – Evolução do capital investido sobre o ativo PETR4, com a utilização do sistema proposto, MM, e B&H.



Quanto à estratégia com médias móveis, o mercado mostrou-se eficiente tanto no comparativo médio quanto individual. Enquanto MM conseguiu um ROI médio de 54,16%, B&H

alcançou 81,01%. Na comparação dos resultados alcançados sobre cada ativo, o emprego de *Buy-and-Hold* conseguiu desempenho financeiro superior em 56,67% dos casos.

### 4.2.3 Desempenhos Médios

A Tabela 4.10 apresenta os desempenhos médios alcançados com as simulações de atuação do sistema proposto e utilização das estratégias com cruzamento de médias móveis (MM), e *Buy-and-Hold* (B&H). Foi também incluído nesta tabela o desempenho do índice IBOVESPA<sup>1</sup> para o mesmo período considerado nas simulações. O índice IBOVESPA representa uma carteira teórica de ações, sendo um indicador de desempenho médio dos ativos com maior representatividade do mercado acionário brasileiro (BM&FBOVESPA, 2017).

Tabela 4.10 – Desempenhos médios alcançados com o sistema proposto, MM, B&H, e índice IBOVESPA.

<b>Estratégia</b>	<b>ROI</b>	<b>ARR</b>	<b>MDD</b>	<b>ARRT</b>	<b>AAT</b>	<b>ADT</b>	<b>TRCE</b>
Sistema Proposto	97,47	10,74	-9,77	9,04	2,73	72,05	25,55
B&H	81,01	9,31	-61,03	-	-	-	100
MM	54,16	6,70	-36,14	3,26	5,89	68,22	52,79
IBOVESPA	-17,34	-2,82	-48,63	-	-	-	100

Os valores exibidos na Tabela 4.10 indicam vantagens na utilização do sistema sobre os *baselines* considerados. Quanto ao percentual de retorno acumulado (ROI), o sistema conseguiu um resultado 20,32% e 79,97% superior aos obtidos por B&H e MM, respectivamente. Quanto à taxa de retorno anualizada (ARR), o sistema atingiu um desempenho 60,29% e 15,36% acima daqueles conseguidos por MM e B&H, respectivamente. E em relação à retração máxima do capital acumulado (MDD), o sistema mostrou-se bem menos arriscado que as demais estratégias utilizadas em comparação. A Tabela 4.10 mostra ainda que o sistema atingiu um retorno médio por operação (ARRT), 177,31% superior àquele alcançado com a estratégia MM. E enquanto a estratégia com médias móveis permaneceu com o capital alocado (TRCE) por 52,79% do tempo, o sistema fez o mesmo por 25,55%. Ou seja, o sistema possibilita certo grau de otimização no emprego do capital, deixando-o livre por aproximadamente 74% do tempo. Pode ser observado ainda que o índice IBOVESPA apresentou um desempenho bem inferior às demais estratégias, com percentual de retorno acumulado negativo de -17,34%.

<sup>1</sup> BM&FBOVESPA. **Índice Bovespa (Ibovespa)**. 2017. Disponível em: <[http://www.bmfbovespa.com.br/pt\\_br/produtos/indices/indices-amplos/indice-bovespa-ibovespa.htm](http://www.bmfbovespa.com.br/pt_br/produtos/indices/indices-amplos/indice-bovespa-ibovespa.htm)>. Acessado em 4 de março de 2017.

### 4.3 Comparação com Estado da Arte

Nesta seção, são apresentados os resultados alcançados com a simulação de operação do sistema proposto, sobre uma base de dados histórica do índice *SSE-Composite*. As simulações de operação foram efetuadas no período de 01/01/2001 a 31/07/2013, mesmo intervalo utilizado nas simulações do algoritmo proposto por Hu et al. (2015).

A Tabela 4.11 mostra o desempenho *Hit Ratio* dos algoritmos SVM e ANN para os tempos gráficos semanal e mensal do índice *SSE-Composite*. Os resultados apresentados com o algoritmo ANN equivalem às médias aritméticas sobre 10 execuções em cada tempo gráfico. A coluna "Média" da Tabela 4.11 é o resultado da média aritmética sobre os valores das colunas "Semanal" e "Mensal". Como pode ser observado na Tabela 4.11, o desempenho médio do SVM, de 84,94%, foi superior ao resultado médio da rede neural, de 81,98%, portanto, as previsões efetuadas com o algoritmo SVM foram utilizadas nas simulações de operação financeira.

Tabela 4.11 – Desempenho *Hit Ratio* dos algoritmos SVM e ANN sobre os tempos gráficos semanal e mensal do índice *SSE-Composite*.

Algoritmo	Semanal	Mensal	Média
ANN	89,82	74,13	<b>81,98</b>
SVM	91,12	78,75	<b>84,94</b>

As Tabelas 4.12 e 4.13 exibem respectivamente a lista com os 10 indicadores técnicos mais utilizados para os treinamentos e previsões nos tempos gráficos semanal e mensal do índice *SSE-Composite*, no período de 01/01/2001 a 31/07/2013. A seleção dos indicadores técnicos foi desempenhada pelo módulo de SC, com a utilização de FDR e CCP. Pode ser observado por meio da Tabela 4.12 que o indicador *Williams' %R* foi o mais utilizado para as previsões em ambos os tempos gráficos, seguido pelo indicador *Stochastic Relative Strength Index*, no gráfico semanal, e por *Normalized Average True Range*, no tempo gráfico mensal.

Na etapa de seleção de características, em média, a dimensão dos dados foi reduzida em 95,32% para o tempo gráfico semanal, e em 94,44% para o tempo gráfico mensal. Foram utilizados em média 2,01 e 2,39 indicadores técnicos para as previsões semanais e mensais, respectivamente.



Tabela 4.12 – Relação com os 10 indicadores técnicos mais utilizados nas previsões semanais do índice *SSE-Composite*.

<b>Indicador</b>	<b>%</b>
willr	25,26
stochrsi	16,51
var	10,00
aroonosc	9,14
minus_di	4,72
aroon_wown	4,58
aroon_up	4,22
trix	3,56
ultosc	2,75

Tabela 4.13 – Relação com os 10 indicadores técnicos mais utilizados nas previsões mensais do índice *SSE-Composite*.

<b>Indicador</b>	<b>%</b>
willr	23,35
natr	11,27
var	8,05
stochrsi	7,25
sar	6,60
minus_dm	5,96
stoch	3,86
trix	3,70
minus_di	3,06
ultosc	2,90

A Tabela 4.14 apresenta os resultados alcançados com as simulações de operação financeira sobre o índice *SSE-Composite*, tando do sistema proposto quanto da aplicação de *Buy-and-Hold* simples. Constam também nesta tabela os resultados apresentados no trabalho de Hu et al. (2015), para o mesmo índice e período utilizados. No trabalho de Hu et al. (2015), a medida ROI é referenciada como "*Accumulative Return*" (AR). Os valores das medidas ARR e AAT exibidas para Hu et al. (2015), foram calculados a partir dos seguintes dados: (i) ROI, (ii) período total considerado, e (iii) quantidade de resultados contabilizados a partir do gráfico exibido pela Figura 4.20.

Tabela 4.14 – Desempenho das simulações de operação sobre o índice *SSE-Composite*, com a utilização do sistema proposto, B&H, e Hu et al. (2015).


<b>Estratégia</b>	<b>ROI</b>	<b>ARR</b>	<b>MDD</b>	<b>ARRT</b>	<b>AAT</b>	<b>ADT</b>	<b>TRCE</b>
Sistema Proposto	254,21	10,57	-8,49	11,58	2,38	78,4	25,6
Hu et al. (2015)	187,00	8,74	-	-	22,72	-	-
B&H	-3,96	-0,32	-71,98	-	-	-	100

Os valores apresentados na Tabela 4.14 mostram que, para o período considerado, o emprego de B&H simples resultaria em perda de -3,96% (ROI) do capital investido, com uma taxa composta de crescimento anual (ARR) negativa de -0,32%. B&H também atingiu uma retração máxima do capital acumulado (MDD), de -71,98%. Nos resultados apresentadas no trabalho de Hu et al. (2015), foi alcançado ROI de 187,00%, e ARR de 8,74%. Este último, calculado a partir do ROI informado. Não foi possível contabilizar o MDD sobre os resultados de Hu et al. (2015), pois os valores de evolução do capital não foram informados.

Quanto ao desempenho do sistema proposto, foram atingidas medidas ROI e ARR respectivamente 35,94% e 20,93% superiores àquelas alcançadas por Hu et al. (2015). A medida de desempenho AAT mostra que nas simulações, o algoritmo proposto por Hu et al. (2015) atuou 854,62% a mais que o sistema proposto neste trabalho. A Tabela 4.14 mostra ainda que o sistema conseguiu um retorno médio de 11,58% por operação (ARRT), e cada operação teve uma duração média de 74,4 dias (ADT). A medida TRCE mostra que o sistema utilizou o capital em 25,6% do tempo total considerado na simulação.

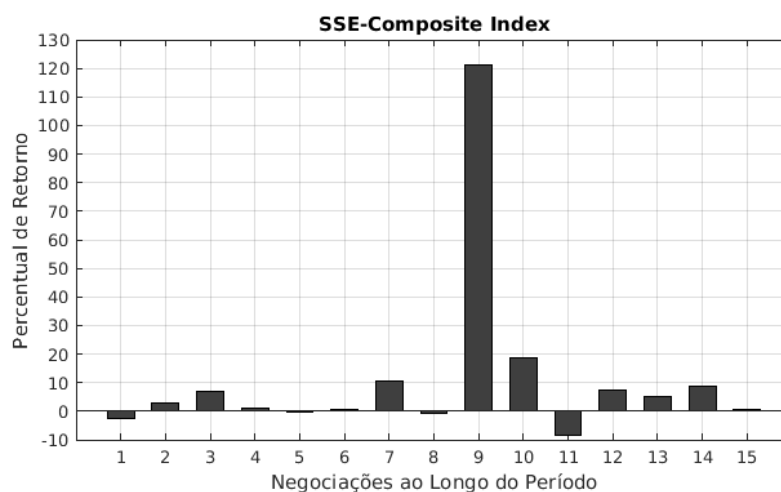
As Figuras 4.20 e 4.21 exibem respectivamente os gráficos com o retorno percentual alcançado em cada uma das operações efetuadas por Hu et al. (2015) e pelo sistema proposto, sobre o índice *SSE-Composite*.

Figura 4.20 – Retorno percentual de cada operação efetuada por Hu et al. (2015) sobre o índice *SSE-Composite* (*Composite Index*).




Fonte: (HU et al., 2015).

Figura 4.21 – Retorno percentual de cada operação efetuada pelo sistema sobre o índice *SSE-Composite*.



No trabalho de Hu et al. (2015) é feita uma comparação de desempenho entre o algoritmo desenvolvido pelos autores (*eTrend*), *Decision Tree* (DT) e *Neural Networks* (NN). A Figura 4.22 exibe o gráfico com a evolução do capital investido com *eTrend*, DT, NN, e os desempenhos B&H dos índices *SSE-Composite* (*Composite Index*) e *SSE-Industrial* (*Industrials Index*). O gráfico da Figura 4.22 mostra que a partir do final de 2008 ou início de 2009, o algoritmo *eTrend* proposto por Hu et al. (2015) supera as outras estratégias utilizadas na comparação.


Figura 4.22 – Comparativo de desempenho financeiro entre *eTrend*, DT, NN, *Composite Index* e *Industrials Index*, feito por Hu et al. (2015).



Fonte: (HU et al., 2015).

A Figura 4.23 mostra o gráfico com a evolução do capital investido sobre o índice *SSE-Composite*, alcançado com a aplicação do sistema proposto neste trabalho, e com o emprego de B&H simples. Na comparação entre os gráficos das Figuras 4.22 e 4.23 pode-se notar, em praticamente todo o período, desempenho superior por parte do sistema em detrimento aos outros resultados exibidos.

Figura 4.23 – Evolução do capital investido sobre o índice *SSE-Composite Index*, com a aplicação do sistema proposto e desempenho B&H.



O gráfico da Figura 4.23 mostra que o sistema conseguiu tirar proveito do movimento de alta ocorrido entre 2006 e final de 2007. O gráfico mostra ainda que o sistema conseguiu manter o capital acumulado, mesmo com a forte desvalorização sofrida pelo índice no período seguinte.

A Figura 4.24 mostra o gráfico com as operações efetuadas pelo sistema sobre o índice *SSE-Composite*. O melhor resultado obtido por uma única operação foi de 121,04%. Este resultado foi alcançado com uma operação de compra, iniciada em 10/10/2006 e finalizada em 26/06/2007, com duração de 259 dias corridos. E o pior resultado foi obtido por uma operação de venda a descoberto, com prejuízo de -8,49%. Esta operação foi iniciada em 08/07/2010 e finalizada em 03/08/2010, com duração de 26 dias corridos.

Figura 4.24 – Operações efetuadas entre 01/01/2001 e 31/07/2013 pelo sistema sobre o índice *SSE-Composite*.



Durante todo o período considerado na simulação, o sistema efetuou 15 operações sobre o índice *SSE-Composite*. Destas, 73,33% (11) resultaram em lucro. A duração média das operações com resultados positivos foi de 99,36 dias, e a média em operações com resultados negativos foi de 20,74 dias. Assim como nas simulações anteriores, esta diferença mostra que o sistema encerrou rapidamente as posições não favoráveis. Portanto, estes resultados também indicam viabilidade no encerramento de operações a partir da descontinuidade da tendência.

## 5 CONCLUSÃO

Os resultados mostram que o sistema proposto alcançou um resultado financeiro médio superior à média do mercado, mas não foi capaz de superá-lo consistentemente. Sobre o grupo de ativos da BM&FBovespa considerados, o sistema conseguiu ROI médio de 97,47%, enquanto o emprego de B&H atingiu 81,01% para a mesma medida. Já no desempenho individual por ativo, B&H conseguiu resultado superior em 53,33% dos casos. Isto significa que, ao aplicar o sistema sobre um ativo aleatório da base de dados considerada, seria alcançado resultado financeiro superior ao próprio desempenho do ativo em aproximadamente 46,70% das vezes. Desta maneira, pode-se concluir que para o escopo desta pesquisa, levando-se em conta o grupo de ativos, o período de tempo, e estratégia empregada, o mercado mostrou-se eficiente. Este resultado alinha-se à hipótese fraca da HME, onde é assumido não ser possível auferir retornos excessivos consistentemente, a partir de regras de negociação baseadas em dados históricos provenientes da própria movimentação histórica do ativo.

Embora o mercado tenha se mostrado eficiente do ponto de vista da HME, os resultados apresentam características interessantes quanto ao emprego do sistema proposto, como pode ser observado abaixo:

- o sistema apresentou boa capacidade de manutenção do capital acumulado ao longo do período de simulações, mantendo-se muitas vezes fora de operação durante momentos de incerteza e indefinição do mercado;
- o sistema apresentou-se bem menos arriscado que o emprego de B&H, o que pode ser constatado através da medida *Maximum Drawdown*;
- os resultados alcançados ao final dos experimentos mostram maior propensão de retornos positivos com a utilização do sistema, se comparado ao emprego de B&H simples. Enquanto B&H apresentou resultados financeiros negativos em 11 ações, o sistema conseguiu resultado final positivo em todos os casos;
- em média, o sistema utilizou o capital durante 25,55% do tempo total considerado. Isto significa que o capital poderia ser alocado em investimentos alternativos durante parcela do tempo livre, podendo contribuir para a potencialização dos retornos.

Diante dos pontos apresentadas, pode-se concluir que os resultados demonstram viabilidade quanto ao emprego de estratégias de seguimento de tendências (TF - *Trend-Following*),

apoiadas por algoritmos de inteligência computacional. Pode-se concluir ainda que o encerramento de posições a partir da descontinuidade da tendência mostrou-se compatível e viável para o tipo de estratégia empregado. Os resultados ainda apontam que os conceitos relativos à análise técnica e teoria de *Dow*, quanto ao modo de comportamento do mercado, possuem validade, mesmo com a utilização de dados disponibilizados livremente na *internet*.

Na mesma base de dados, o sistema superou uma estratégia de cruzamento de médias móveis em 73,33% dos casos. O desempenho do sistema foi ainda comparado aos resultados de Hu et al. (2015) sobre o índice *SSE-Composite*. Nesta última comparação, o sistema atingiu um desempenho ROI 35,94% superior.

Pode-se concluir também que o modo de atuação, focada no médio e longo prazo, torna o sistema adequado a pessoas que não dispõem de tempo para acompanhamento da movimentação constante do mercado. Desta maneira, apoiado pelos resultados obtidos em bases de dados históricas, pode-se dizer que o modelo de sistema proposto mostra-se candidato como solução no auxílio à pessoas que desejem especular no mercado de ações, mas não dispõem de tempo suficiente para acompanhamento e estudos diários.

## 5.1 Contribuições

Pode-se destacar que este trabalho contribui para o meio acadêmico, científico, e tecnológico, pelos seguintes motivos:

- fornece evidências empíricas favoráveis à Hipótese do Mercado Eficiente;
- apresenta resultados que indicam viabilidade quanto ao emprego de análise técnica e teoria de *Dow*, para o desenvolvimento de estratégias TF;
- fornece evidências que indicam viabilidade quanto à utilização de estratégias TF, apoiadas por algoritmos de IC, para atuação especulativa de médio e longo prazo em mercado de ações;
- provê resultados que mostram viabilidade quanto ao emprego de dados disponíveis livremente na *internet*;
- sintetiza o estado da arte em um tema de alta relevância e continuamente pesquisado.

## 5.2 Propostas para Continuidade da Pesquisa

Abaixo, são apresentadas as propostas de continuidade da pesquisa desempenhada neste trabalho:

- o conjunto de indicadores técnicos empregados neste trabalho foram parametrizados de acordo com a sua configuração original. Estes indicadores podem ser otimizados por meio de configuração dinâmica, através, por exemplo, de algoritmos evolucionários;
- foi empregado o indicador técnico MACD como ferramenta de detecção de tendências, e como qualquer outro indicador, seus parâmetros de construção podem ser otimizados. A etapa de detecção de tendências pode ainda ser desempenhada por meio de outras estratégias, podendo ser tratada, por exemplo, como um problema de classificação;
- o tamanho da janela de treinamento dos classificadores foi definida de forma empírica. Esta janela pode ser alterada de forma dinâmica, a partir da identificação de alterações nos padrões de comportamento do mercado. Desta maneira, o tratamento ao problema relativo ao *Concept-Drift* pode ser aperfeiçoado;
- embora o modelo de sistema proposto supõe a utilização de dados diários, semanais e mensais para atuação em médio e longo prazo, o modelo pode ainda ser avaliado sobre dados intradiários e operações *daytrade*.



## REFERÊNCIAS BIBLIOGRÁFICAS

ABHISHEK, K. et al. A stock market prediction model using Artificial Neural Network. In: **3rd International Conference on Computing, Communication and Networking Technologies, ICCCNT**. IEEE, 2012. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6396089>>.

ACHELIS, S. **Technical Analysis from A to Z**. 2nd. ed. New York, NY, USA: Mcgraw-hill, 2000. ISBN 9780071363488.

AGRAWAL, J.; CHOURASIA, V.; MITTRA, A. State-of-the-art in stock prediction techniques. **International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering**, v. 2, n. 4, p. 1360–1366, 2013.

AGUIAR, R. A. Forecasting of return of stocks portfolio based in fuzzy c-means algorithm and fuzzy transform. In: **IEEE Conference on Computational Intelligence for Financial Engineering and Economics, CIFEr**. IEEE, 2012. p. 419–423. ISBN 9781467318037 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84869767389{&}partnerID=40{&}md5=4594d0cf9662577281104f73c6>>.

AHMED, M.; SRIRAM, A.; SINGH, S. Towards a generic framework for short term firm-specific stock forecasting. In: S., M. et al. (Ed.). **3rd International Conference on Advances in Computing, Communications and Informatics, ICACCI**. Department of Information and Communication Technology, Manipal Institute of Technology, Manipal, India: Institute of Electrical and Electronics Engineers Inc., 2014. p. 2681–2688. ISBN 9781479930791 (ISBN).

AHUJA, R. et al. Stock market forecast using sentiment analysis. In: M.N., H. (Ed.). **2nd International Conference on Computing for Sustainable Global Development, INDIACom**. UG, BVCOE, New Delhi, India: Institute of Electrical and Electronics Engineers Inc., 2015. p. 1008–1010. ISBN 9789380544168 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84960856675{&}partnerID=40{&}md5=76f7f1a434b513eae30a65c708>>.

ALDRIDGE, I. **High-frequency trading: a practical guide to algorithmic strategies and trading systems**. 1nd. ed. Hoboken, New Jersey, USA: John Wiley and Sons, 2010. ISBN 9780470563762.

Alexandre MacEdo, J. et al. An intelligent decision support system to investment in the stock market. **IEEE Latin America Transactions**, Federal University of Alfenas, Alfenas, Minas Gerais, Brazil, v. 11, n. 2, p. 812–819, 2013. ISSN 15480992 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84879905264{&}partnerID=40{&}md5=07d313eb3ad37da9cb971c6c45>>.

ALLOUD, M. E. Profitability of directional change based trading strategies: The case of saudi stock market. **International Journal of Economics and Financial Issues**, Econjournals, Department of Management Information Systems, College of Business Administration, King Saud University, Saudi Arabia, v. 6, n. 1, p. 87–95, 2016. ISSN 21464138 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84979833360{&}partnerID=40{&}md5=e64b42bd6c6c1a3d81ac0d4ef7>>.

ALRASHEEDI, M. Predicting up/down direction using linear discriminant analysis and logit model: The case of SABIC price index. **Research Journal of Business Management**, Department of Quantitative Methods, School of Business, King Faisal University, Hofuf, Alhasa 31982, Saudi Arabia, v. 6, n. 4, p. 121–133, 2012. ISSN 18191932 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84872175981{&}partnerID=40{&}md5=322830ad8ad33665d13d7b496d>>.

APPEL, G.; HITSCHLER, W. **Stock Market Trading Systems**. USA: Traders Press, 1990. ISBN 9780934380164. Disponível em: <<https://books.google.com.br/books?id=ia3zAAAAMAAJ>>.

ARIAS, M.; ARRATIA, A.; XURIGUERA, R. Forecasting with twitter data. **ACM Transactions on Intelligent Systems and Technology**, Department de Llenguatges i Sistemes Informatics, Universitat Politècnica de Catalunya, Campus Nord, Edif., Omega-Barcelona, Spain, v. 5, n. 1, 2013. ISSN 21576904 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84891765968{&}partnerID=40{&}md5=0d82ee9bd7dbecf2f11ed9cf73>>.

ASNESS, C.; FABOZZI, F. J. **Short selling: strategies, risks, and rewards**. USA: John Wiley & Sons, 2004.

ATSALAKIS, G. S.; PROTOPAPADAKIS, E. E.; VALAVANIS, K. P. Stock trend forecasting in turbulent market periods using neuro-fuzzy systems. **Operational Research**, Springer Verlag, School of Production Engineering and Management, Technical University of Crete, Chania, Greece, v. 16, n. 2, p. 245–269, 2016. ISSN 11092858 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84940906715{&}partnerID=40{&}md5=a9b9de9fb85a375785897ee527>>.

ATSALAKIS, G. S.; VALAVANIS, K. P. Forecasting stock market short-term trends using a neuro-fuzzy based methodology. **Expert Syst. Appl.**, Pergamon Press, Inc., Tarrytown, NY, USA, v. 36, n. 7, p. 10696–10707, set. 2009. ISSN 0957-4174.

ATTIGERI, G. V. et al. Stock market prediction: A big data approach. In: **35th IEEE Region 10 Conference, TENCON**. Manipal Institute of Technology, Manipal, India: Institute of Electrical and Electronics Engineers Inc., 2016. v. 2016-Janua. ISBN 21593442 (ISSN); 9781479986415 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962185156{&}partnerID=40{&}md5=c47542775423d3234efde26bf9>>.

AUER, B. R. Does the choice of performance measure influence the evaluation of commodity investments? **International Review of Financial Analysis**, Elsevier, v. 38, p. 142–150, 2015.

AZIMIFAR, M.; ARAABI, B. N.; MORADI, H. Improving the performance of intelligent stock trading systems by using a high level representation for the inputs. In: **Signal Processing and Intelligent Systems Conference, SPIS**. School of Electrical and Computer Engineering, College of Engineering, University of Tehran, Tehran, Iran: Institute of Electrical and Electronics Engineers Inc., 2015. p. 15–19. ISBN 9781509001392 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84969508824{&}partnerID=40{&}md5=048820f70ec3e9fec4c9619115>>.

BEKAERT, G.; HARVEY, C. R. Foreign speculators and emerging equity markets. **The Journal of Finance**, Wiley Online Library, v. 55, n. 2, p. 565–613, 2000.

BEKIROS, S. D. Irrational fads, short-term memory emulation, and asset predictability. **Review of Financial Economics**, European University Institute, Florence, Italy, v. 22, n. 4, p. 213–219, 2013. ISSN 10583300 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84887614624{%&}partnerID=40{%&}md5=700c84f9e66c8cfce3d15f134f>>.

BHAT, A. A.; KAMATH, S. S. Automated stock price prediction and trading framework for Nifty intraday trading. In: **2013 4th International Conference on Computing, Communications and Networking Technologies, ICCCNT**. Department of Information Technology, National Institute of Technology, Karnataka, Surathkal, India: IEEE, 2013. ISBN 9781479939268 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84894477908{%&}partnerID=40{%&}md5=773638039ee392b9659c634325>>.

BIJL, L. et al. Google searches and stock returns. **International Review of Financial Analysis**, Elsevier Inc., Norwegian University of Science and Technology, Trondheim, Norway, v. 45, p. 150–156, 2016. ISSN 10575219 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962477109{%&}partnerID=40{%&}md5=865da6acbd2ff244a9396fec12>>.

BISHOP, C. M. **Neural Networks for Pattern Recognition**. New York, NY, USA: Oxford University Press, Inc., 1995. ISBN 0198538642.

BISOI, R.; DASH, P. K. A hybrid evolutionary dynamic neural network for stock market trend analysis and prediction using unscented Kalman filter. **Applied Soft Computing Journal**, Multidisciplinary Research Cell, Siksha O Anusandhan University, Bhubaneswar, Odisha, India, v. 19, p. 41–56, 2014. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84894612238{%&}partnerID=40{%&}md5=2973e5bb4559b385a12e195fa7>>.

BM&FBOVESPA. **BM&FBOVESPA**. 2017. <<http://www.bmfbovespa.com.br/>>. Acessado em 2 de janeiro de 2017.

BODAS-SAGI, D. J. et al. A parallel evolutionary algorithm for technical market indicators optimization. **Natural Computing**, Gestión Informática Empresarial, CES Felipe II (UCM), Madrid, Spain, v. 12, n. 2, p. 195–207, 2013. ISSN 15677818 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84878564150{%&}partnerID=40{%&}md5=64e8487a9a61f9f3d6bd67924a>>.

Bodas Sagi, D. J. et al. A technique for the optimization of the parameters of technical indicators with multi-objective evolutionary algorithms. In: **2012 IEEE Congress on Evolutionary Computation, CEC 2012**. CES Felipe II, UCM, Aranjuez, Spain: IEEE, 2012. ISBN 9781467315098 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84866875709{%&}partnerID=40{%&}md5=bfe8b0b0e6f5ac81e13d321f6f>>.

BOLLINGER, J. **Bollinger on Bollinger Bands**. Boston, MA: McGraw-Hill Education, 2001. ISBN 9780071373685.

BONABEAU, E.; DORIGO, M.; THERAULAZ, G. **Swarm intelligence: from natural to artificial systems**. Oxford, England, U.K.: Oxford university press, 1999.

BOSLAUGH, S. **Statistics in a nutshell**. USA: O Reilly Media, Inc., 2012. ISBN 9781449361129.

BOUKTIF, S.; AWAD, M. A. Predicting stock market movement: An evolutionary approach. In: A., F. et al. (Ed.). **7th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management, IC3K**. College of Information Technology, UAE University, Al Ain, United Arab Emirates: SciTePress, 2015. v. 1, p. 159–167. ISBN 9789897581588 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84960844394{&}partnerID=40{&}md5=aa3c8ae496d7d5f57ebf393685>>.

BRASILEIRO, R. C. et al. Automatic method for stock trading combining technical analysis and the Artificial Bee Colony Algorithm. In: **2013 IEEE Congress on Evolutionary Computation, CEC 2013**. Center of Informatics, Federal University of Pernambuco, Brazil: IEEE, 2013. p. 1810–1817. ISBN 9781479904549 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84881605552{&}partnerID=40{&}md5=952248d52a391b925a5f145123>>.

BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, Springer, v. 2, n. 2, p. 121–167, 1998.

BUSSOLA. **Bússola do investidor**. 2017. <<https://www.bussoladoinvestidor.com.br>>. Acessado em 31 de janeiro 2017.

CAO, W.; HU, L.; CAO, L. Deep modeling complex couplings within financial markets. In: **29th AAAI Conference on Artificial Intelligence, AAAI 2015 and the 27th Innovative Applications of Artificial Intelligence Conference, IAAI**. Advanced Analytics Institute, University of Technology, Sydney, United States: AI Access Foundation, 2015. v. 4, p. 2518–2524. ISBN 9781577357025 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84960153169{&}partnerID=40{&}md5=d8e485d48994a6c0420202e0ae>>.

CERVELLÓ-ROYO, R.; GUIJARRO, F.; MICHNIUK, K. Stock market trading rule based on pattern recognition and technical analysis: Forecasting the djia index with intraday data. **Expert Systems with Applications**, Elsevier, v. 42, n. 14, p. 5963–5975, 2015. ISSN 0957-4174.

CFTC. **Speculative Limits**. 2017. <<http://www.cftc.gov/IndustryOversight/MarketSurveillance/SpeculativeLimits/>>. Acessado em 2 de fevereiro 2017.

CHAI, J. et al. A hybrid least square support vector machine model with parameters optimization for stock forecasting. **Mathematical Problems in Engineering**, Hindawi Publishing Corporation, International Business School, Shaanxi Normal University, Xian, China, v. 2015, 2015. ISSN 1024123X (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84922311145{&}partnerID=40{&}md5=8e70d49327dbd075b78ac71877>>.

CHAN, E. **Harvard Business School Confidential: Secrets of Success**. USA: John Wiley & Sons, 2009.

CHANDAR, S. K.; SUMATHI, M.; SIVANADAM, S. N. Forecasting gold prices based on extreme learning machine. **International Journal of Computers, Communications and Control**, CCC Publications, Christ University, Bangalore, India, v. 11, n. 3, p. 372–380, 2016. ISSN 18419836 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962439513{&}partnerID=40{&}md5=a7c447feff9def71c6a6a6a94b>>.

CHANDAR, S. K.; SUMATHI, M.; SIVANANDAM, S. N. Prediction of stock market price using hybrid of wavelet transform and artificial neural network. **Indian Journal of Science and Technology**, Indian Society for Education and Environment, Christ University, Bangalore, Karnataka, India, v. 9, n. 8, 2016. ISSN 09746846 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84961990702{&}partnerID=40{&}md5=51e565e4466ff5a0ced4971d73>>.

CHANDE, T.; KROLL, S. **The new technical trader: boost your profit by plugging into the latest indicators**. USA: Wiley, 1994. (Wiley Finance). ISBN 9780471597803.

CHANG, P.-C.; WANG, D.-D.; ZHOU, C.-L. A novel model by evolving partially connected neural network for stock price trend forecasting. **Expert Systems with Applications**, Department of Information Management, Yuan Ze University, Taoyuan 32026, Taiwan, v. 39, n. 1, p. 611–620, 2012. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-81855161579{&}partnerID=40{&}md5=705639046823c1165502bd3143>>.

CHANG, P.-C.; WU, J.-L. The weighted Support Vector Machines for the stock turning point prediction. In: **2014 14th International Conference on Intelligent Systems Design and Applications, ISDA**. Department of Information Management, Innovation Center for Big Data and Digital Convergence, Yuan Ze University, Taoyuan, Taiwan: IEEE Computer Society, 2015. v. 2015-Janua, p. 205–210. ISBN 21647143 (ISSN); 9781479979387 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84940540859{&}partnerID=40{&}md5=1e61925871b312ca4d646a1105>>.

CHEN, C. et al. Exploiting social media for stock market prediction with factorization machine. In: Y., L. et al. (Ed.). **2014 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology - Workshops, WI-IAT**. College of Computer and Control Engineering, Nankai University, Tianjin, China: Institute of Electrical and Electronics Engineers Inc., 2014. v. 2, p. 49–56. ISBN 9781479941438 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84912527068{&}partnerID=40{&}md5=47520284ffa30d67dfd5df230>>.

CHEN, M.-Y. et al. International transmission of stock market movements: An adaptive neuro-fuzzy inference system for analysis of TAIEX forecasting. **Neural Computing and Applications**, Department of Information Management, National Taichung University of Science and Technology, Taichung, 404, Taiwan, v. 23, n. SUPPL1, p. 369–378, 2013. ISSN 09410643 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84888821660{&}partnerID=40{&}md5=50599daa4cf9506352fa69bee7>>.

CHEN, S.-M.; CHEN, S.-W. A new method for forecasting the taiex based on two-factors second-order fuzzy-trend logical relationship groups and the probabilities of trends of fuzzy logical relationships. In: **13th International Conference on Machine Learning and Cybernetics, ICMLC 2014**. Department of Computer Science and Information Engineering, National Taiwan University of Science and Technology, Taipei, Taiwan: IEEE Computer Society, 2015. v. 1, p. 332–337. ISBN 2160133X (ISSN); 9781479942169 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84921517637{&}partnerID=40{&}md5=bb36af466328352be9a067c2f0>>.

CHEN, S.-M.; CHEN, S.-W. Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and the probabilities of trends of fuzzy logical relationships.

**IEEE Transactions on Cybernetics**, Institute of Electrical and Electronics Engineers Inc., Department of Computer Science and Information Engineering, National Taiwan University of Science and Technology, Taipei, Taiwan, v. 45, n. 3, p. 405–417, 2015. ISSN 21682267 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84923368021&partnerID=40&md5=48f17221ce74e99dc42084a943>>.

CHEN, S.-M. et al. Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and particle swarm optimization techniques. **IEEE Transactions on Cybernetics**, Department of Computer Science and Information Engineering, National Taiwan University of Science and Technology, Taipei 106, Taiwan, v. 43, n. 3, p. 1102–1117, 2013. ISSN 21682267 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84890427180&partnerID=40&md5=632eab880fb39f0600dd0b1059>>.

CHEN, T.-L.; CHEN, F.-Y. An intelligent pattern recognition model for supporting investment decisions in stock market. **Information Sciences**, Elsevier Inc., Department of Digital Content Application and Management, Wenzao Ursuline College of Languages, 900 Mintsu, 1st Road, Kaohsiung, Taiwan, v. 346-347, p. 261–274, 2016. ISSN 00200255 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84959079724&partnerID=40&md5=24d09fefed34aba999a3219187>>.

CHEN, W.; SZETO, K. Y. Mixed time scale strategy in portfolio management. **International Review of Financial Analysis**, Department of Physics, Hong Kong University of Science and Technology, Clear Water Bay, Hong Kong SAR, China, v. 23, p. 35–40, 2012. ISSN 10575219 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84862868392&partnerID=40&md5=2e436f4da14123006a5745e097>>.

CHEN, Y.-J.; CHEN, Y.-M. A fundamental analysis-based method for stock market forecasting. In: **2013 4th International Conference on Intelligent Control and Information Processing, ICICIP**. Department of Accounting and Information Systems, National Kaohsiung First University of Science and Technology, Kaohsiung, Taiwan: SCI journal Soft Computing, 2013. p. 354–359. ISBN 9781467362481 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84883230420&partnerID=40&md5=713ecef6c1dfe0b7ed0197b4e>>.

CHEVAPATRAKUL, T. Return sign forecasts based on conditional risk: Evidence from the UK stock market index. **Journal of Banking and Finance**, Nottingham University Business School, The University of Nottingham, United Kingdom, v. 37, n. 7, p. 2342–2353, 2013. ISSN 03784266 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84877624442&partnerID=40&md5=dd5507896d40a8c517185e6ebc>>.

CHIANG, W.-C. et al. An adaptive stock index trading decision support system. **Expert Systems with Applications**, Elsevier Ltd, Collins College of Business, University of Tulsa, Helmerich Hall 118B, 800 South Tucker Drive, Tulsa, OK, United States, v. 59, p. 195–207, 2016. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84968867174&partnerID=40&md5=e7dd5d0202b9ea4e63ca0a3906>>.

COPELAND, T. E.; WESTON, F. J. **Financial theory and corporate policy**. 3rd. ed. New York, NY, USA: Addison-Wesley, 1988. ISBN 0201106485.

CORNELL, B.; ROLL, R. Strategies for pairwise competitions in markets and organizations. **The Bell Journal of Economics**, JSTOR, v. 12, n. 1, p. 201–213, 1981.

CORTES, C.; VAPNIK, V. Support-vector networks. **Machine learning**, Springer, v. 20, n. 3, p. 273–297, 1995.

CUI, L.-X.; LONG, W. Trading strategy based on dynamic mode decomposition: Tested in Chinese stock market. **Physica A: Statistical Mechanics and its Applications**, Elsevier, Research Center On Fictitious Economy & Data Science, Chinese Academy of Sciences, Beijing, China, v. 461, p. 498–508, 2016. ISSN 03784371 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84976253672&partnerID=40&md5=231e14f9460a0e3e54be816193>>.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of control, signals and systems**, Springer, v. 2, n. 4, p. 303–314, 1989.

DABHI, V. K.; CHAUDHARY, S. Financial Time Series Modeling and Prediction Using Postfix-GP. **Computational Economics**, Springer New York LLC, Department of Information Technology, Dharmsinh Desai University, Nadiad, India, v. 47, n. 2, p. 219–253, 2016. ISSN 09277099 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84957841521&partnerID=40&md5=1b5ea31756e79e638cb558783c>>.

DASH, R.; DASH, P. K. A comparative study of radial basis function network with different basis functions for stock trend prediction. In: R., B. et al. (Ed.). **IEEE Power, Communication and Information Technology Conference, PCITC**. Siksha 'o' Anusandhan University, Khandagiri Square, Bhubaneswar, OR, India: Institute of Electrical and Electronics Engineers Inc., 2015. p. 430–435. ISBN 9781479974559 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84966651036&partnerID=40&md5=2122293ffad6728a40042267da>>.

De La Fuente-Mella, H. et al. Modeling asymmetry of information for a sample of the Chilean companies using deterministic and stochastic methodologies. In: A., L.; I., F. (Ed.). **2nd International Symposium on Stochastic Models in Reliability Engineering, Life Science, and Operations Management, SMRLO 2016**. Facultad de Ciencias Económicas y Administrativas, Pontificia Universidad Católica de Valparaíso, Valparaíso, Chile: Institute of Electrical and Electronics Engineers Inc., 2016. p. 517–523. ISBN 9781467399418 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84964799470&partnerID=40&md5=56a953cbbb809492f77539b74b>>.

De Oliveira, F. A.; NOBRE, C. N.; ZÁRATE, L. E. Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index - Case study of PETR4, Petrobras, Brazil. **Expert Systems with Applications**, Computer Science Department, Applied Computational Intelligence Laboratory - LICAP, Pontifical Catholic University of Minas Gerais, Rua Walter Ianni 255, São Gabriel, CEP 31980-110 Belo Horizonte, MG, Brazil, v. 40, n. 18, p. 7596–7606, 2013. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84882384166&partnerID=40&md5=c135e41f5ad7fc0b4b65245637>>.

DEFUSCO, R. et al. **Quantitative Investment Analysis**. USA: Wiley, 2011. (CFA Institute Investment Series). ISBN 9781118044780. Disponível em: <[https://books.google.com.br/books?id=OQzbF5-a\\_7UC](https://books.google.com.br/books?id=OQzbF5-a_7UC)>.

DENG, W. et al. A multi-granularity combined prediction model based on fuzzy trend forecasting and particle swarm techniques. **Neurocomputing**, Elsevier, Chongqing

Institute of Green and Intelligent Technology, Chinese Academy of Sciences, Chongqing, China, v. 173, p. 1671–1682, 2016. ISSN 09252312 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84955109861{%&}partnerID=40{%&}md5=ea70a48a8a771e1d7818fd0d4c>>.

DEVI, B. U.; SUNDAR, D.; ALLI, P. An optimized approach to predict the stock market behavior and investment decision making using benchmark algorithms for Naïve investors. In: **2013 4th IEEE International Conference on Computational Intelligence and Computing Research, IEEE ICCIC**. Raja Doraisingam Government Arts College, Sivagangai, India: IEEE Computer Society, 2013. ISBN 9781479915972 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84894234383{%&}partnerID=40{%&}md5=dc9e20b4c3a466865b063198d3>>.

Do Nascimento, T. P. et al. A system based on genetic algorithms as a decision making support for the purchase and sale of assets at São Paulo Stock Exchange. In: **International Conference on Computer Vision and Image Analysis Applications, ICCVIA**. Post-graduation Program in Electrical Engineering, Federal University of Maranhão - UFMA, São Luís, Brazil: Institute of Electrical and Electronics Engineers Inc., 2015. ISBN 9781479971862 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84963787922{%&}partnerID=40{%&}md5=1ffd688b163b7911ab404d8281>>.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2nd. ed. USA: John Wiley & Sons, 2000. ISBN 0471056693.

DUNIS, C. L. et al. Forecasting IBEX-35 moves using support vector machines. **Neural Computing and Applications**, Liverpool Business School, Liverpool, United Kingdom, v. 23, n. 1, p. 229–236, 2013. ISSN 09410643 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84879840575{%&}partnerID=40{%&}md5=a97c7c607d92d69e1665d6e780>>.

DUONG, D.; NGUYEN, T.; DANG, M. Stock market prediction using financial news articles on Ho Chi Minh stock exchange. In: **10th International Conference on Ubiquitous Information Management and Communication, IMCOM**. University of IT, VNU HCMC, Ho Chi Minh, Viet Nam: Association for Computing Machinery, Inc, 2016. ISBN 9781450341424 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84965032304{%&}partnerID=40{%&}md5=b927008fa48282991933ae8b97>>.

EDWARDS, R.; MAGEE, J.; BASSETTI, W. **Technical Analysis of Stock Trends**. 8nd. ed. USA: Taylor & Francis, 2001. (John Magee Investment Series). ISBN 9781574442922.

EDWARDS, R.; MAGEE, J.; BASSETTI, W. **Technical Analysis of Stock Trends**. 9nd. ed. USA: CRC Press, 2007. ISBN 9781420013146.

ELSEVIER. **Elsevier**. 2016. <<https://www.elsevier.com>>. Acessado em 27 de setembro de 2016.

ETFHQ. **Golden Cross – Which is the best?** 2017. <<http://etfhq.com/blog/2013/01/15/golden-cross-which-is-the-best/>>. Acessado em 9 de janeiro de 2017.

FAMA, E. F. The behavior of stock market prices. **Journal of Business**, JSTOR, v. 38, n. 1, p. 34–105, 1965.



FAMA, E. F. Efficient capital markets: A review of theory and empirical work\*. **The journal of Finance**, Wiley Online Library, v. 25, n. 2, p. 383–417, 1970.

FAMA, E. F. Efficient capital markets: Ii. **The journal of finance**, Wiley Online Library, v. 46, n. 5, p. 1575–1617, 1991.

FAMA, E. F. Market efficiency, long-term returns, and behavioral finance. **Journal of financial economics**, Elsevier, v. 49, n. 3, p. 283–306, 1998.

FAZLI, M. S.; LEBRATY, J.-F. A comparative study on forecasting polyester chips prices for 15 days, using different hybrid intelligent systems. In: **2013 International Joint Conference on Neural Networks, IJCNN**. University of Montesquieu Bordeaux 4, France: IEEE, 2013. ISBN 9781467361293 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84893635120{&}partnerID=40{&}md5=373252be138cde4b98bbfa43cb>>.

FENG, H.-M.; CHOU, H.-C. Evolutionary fuzzy stock prediction system design and its application to the Taiwan stock index. **International Journal of Innovative Computing, Information and Control**, Department of Computer Science and Information Engineering, National Quemoy University, No. 1, University Road, Kin-Ning Vallage Kinmen 892, Taiwan, v. 8, n. 9, p. 6173–6190, 2012. ISSN 13494198 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84865743622{&}partnerID=40{&}md5=b4200b6ed5780e3802493e7971>>.

FERREIRA, D. D. **Análise de Distúrbios Elétricos em Sistemas de Potência**. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2010.

FIDELITY. **Absolute Price Oscillator**. 2017. <<https://www.fidelity.com/learning-center/trading-investing/technical-analysis/technical-indicator-guide/apo>>. Acessado em 2 de janeiro 2017.

FOGEL, D. B. **Evolutionary Computation: Toward a New Philosophy of Machine Intelligence**. Piscataway, NJ, USA: IEEE Press, 1995. ISBN 0-7803-1038-1.

FONG, S.; SI, Y.-W.; TAI, J. Trend following algorithms in automated derivatives market trading. **Expert Systems with Applications**, Department of Computer and Information Science, University of Macau, Macau, v. 39, n. 13, p. 11378–11390, 2012. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84861341466{&}partnerID=40{&}md5=eac74924996c9eb89001010147>>.

FONG, S.; TAI, J.; PICHAPPAN, P. Trend recalling algorithm for automated online trading in stock market. **Journal of Emerging Technologies in Web Intelligence**, Department of Computer and Information Science, University of Macau, Taipa, Macau, v. 4, n. 3, p. 240–251, 2012. ISSN 17980461 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84873600428{&}partnerID=40{&}md5=afe51f1a255ae039946d8ab258>>.

FORMAN, J. Cross-market evaluations with normalized average true range. **TECHNICAL ANALYSIS OF STOCKS AND COMMODITIES-MAGAZINE EDITION-**, TECHNICAL ANALYSIS, INC., v. 24, n. 6, p. 60, 2006.

GÖÇKEN, M. et al. Integrating metaheuristics and Artificial Neural Networks for improved stock price prediction. **Expert Systems with Applications**, Elsevier Ltd, Adana Science and Technology University, Engineering Department, Yeşiloba Yerleşkesi,

Adana, Turkey, v. 44, p. 320–331, 2016. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84944097250{&}partnerID=40{&}md5=17370d6f561f03612f95191480>>.

GÖNEN, M.; ALPAYDIN, E. Multiple kernel learning algorithms. **Journal of Machine Learning Research**, v. 12, n. Jul, p. 2211–2268, 2011.

GONZALEZ, R. T.; PADILHA, C. A.; BARONE, D. A. C. Ensemble System based on Genetic Algorithm for stock market forecasting. In: **IEEE Congress on Evolutionary Computation, CEC 2015**. Institute of Informatics, Federal University of Rio Grande Do sul, Porto Alegre, Brazil: Institute of Electrical and Electronics Engineers Inc., 2015. p. 3102–3108. ISBN 9781479974924 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84963553395{&}partnerID=40{&}md5=a689eddc6e4f8daf8d3d50271e>>.

GRANVILLE, J. **New Key to Stock Market Profits**. USA: Martino Publishing, 2010. ISBN 9781891396373.

GREGORIOU, G. **Handbook of High Frequency Trading**. USA: Elsevier Science, 2015. ISBN 9780128023624. Disponível em: <<https://books.google.com.br/books?id=sfScBAAAQBAJ>>.

GROSSMAN, S. J. Dynamic asset allocation and the informational efficiency of markets. **The Journal of Finance**, Wiley Online Library, v. 50, n. 3, p. 773–787, 1995.

GROSSMAN, S. J.; STIGLITZ, J. E. On the impossibility of informationally efficient markets. **The American economic review**, JSTOR, v. 70, n. 3, p. 393–408, 1980.

GU, Q.; LI, Z.; HAN, J. Generalized fisher score for feature selection. **arXiv preprint arXiv:1202.3725**, 2012.

GUNDUZ, H.; CATALTEPE, Z. Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection. **Expert Systems with Applications**, Elsevier Ltd, Computer Engineering Department, Istanbul Technical University, Maslak, Sariyer, Istanbul, Turkey, v. 42, n. 22, p. 9001–9011, 2015. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84940459928{&}partnerID=40{&}md5=c2529df5ac1ba22bac9182ed2d>>.

HAFEZI, R.; SHAHRABI, J.; HADAVANDI, E. A bat-neural network multi-agent system (BNNMAS) for stock price prediction: Case study of DAX stock price. **Applied Soft Computing Journal**, Elsevier Ltd, Technology Foresight Group, Department of Management, Science and Technology, Amirkabir University of Technology, P.O. Box 15875-4413, Tehran, Iran, v. 29, p. 196–210, 2015. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84922730958{&}partnerID=40{&}md5=9330df914fd898c03caaf35128>>.

HALL, M. A. **Correlation-based feature selection for machine learning**. Tese (Doutorado) — The University of Waikato, 1999.

HAMILTON, W. **The Stock Market Barometer**. 1nd. ed. New York And London: Harper & Brothers, 1922.

HAN, J.; PEI, J.; KAMBER, M. **Data mining: concepts and techniques**. USA: Elsevier, 2011.

HAN, Y.; YANG, K.; ZHOU, G. A new anomaly: The cross-sectional profitability of technical analysis. **Journal of Financial and Quantitative Analysis**, Cambridge Univ Press, v. 48, n. 05, p. 1433–1461, 2013.

HASSAN, M. R. et al. A hmm-based adaptive fuzzy inference system for stock market forecasting. **Neurocomputing**, Elsevier, v. 104, p. 10–25, 2013.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998. ISBN 0132733501.

HEASRT, M. et al. Trends and controversies-support vector machines. **IEEE Intelligent Systems**, v. 13, n. 4, p. 18–28, 1998.

HERAWAN, T.; GHAZALI, R.; DERIS, M. M. **Recent Advances on Soft Computing and Data Mining: Proceedings of The First International Conference on Soft Computing and Data Mining (SCDM-2014) Universiti Tun Hussein Onn Malaysia, Johor, Malaysia June 16th-18th, 2014**. USA: Springer, 2014.

HERBRICH, R. **Learning kernel classifiers: theory and algorithms**. USA: Mit Press, 2001.

HICKS, S. J. R. **Value and Capital: An Inquiry Into Some Fundamental Principles of Economic Theory**. Oxford, England, U.K.: Oxford: Clarendon Press, 1946.

HILLIER, D. et al. **Fundamentals of corporate finance, 10th Edition**. Boston, MA: McGraw Hill, 2014. ISBN 978-0077404895.

HONG, W.; ZHANG, L. Adaptive Fourier Decomposition based automatic stock movement forecasting system. In: **2nd International Conference on Computer Science and Network Technology, ICCSNT**. Faculty of Science and Technology, University of Macau, Macau: IEEE, 2012. p. 292–296. ISBN 9781467329644 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84880193376&partnerID=40&md5=635aaf83e86461c3c48678ffa7>>.

HORNIK, K. Approximation capabilities of multilayer feedforward networks. **Neural Networks**, v. 4, n. 2, p. 251 – 257, 1991. ISSN 0893-6080. Disponível em: <<http://www.sciencedirect.com/science/article/pii/089360809190009T>>.

HU, Y. et al. ITrade: An adaptive risk-adjusted intelligent stock trading system from the perspective of concept drift. In: **4th International Conference on Emerging Intelligent Data and Web Technologies, EIDWT**. Business Intelligence and Knowledge Discovery, Guangdong University of Foreign Studies, Sun Yatsen University, Guangzhou, China: IEEE, 2013. p. 160–167. ISBN 9780769550442 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84889604186&partnerID=40&md5=9e00f93003a3bb3a368207cd4d>>.

HU, Y. et al. Stock trading rule discovery with an evolutionary trend following model. **Expert Systems with Applications**, Elsevier Ltd, Institute of Business Intelligence and Knowledge Discovery, Guangdong University of Foreign Studies, Sun Yat-sen University, Guangzhou 510006, China, v. 42, n. 1, p. 212–222, 2015. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84906535769&partnerID=40&md5=d68484600fb40cec6ff727b7b7>>.

HU, Z.; ZHU, J.; TSE, K. Stocks market prediction using Support Vector Machine. In: **2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering, ICIII**. Marketing Department of Business School, Sun Yat-sen University, Guangzhou, China: IEEE, 2013. v. 2, p. 115–118. ISBN 9781479939855 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84893701382{%&}partnerID=40{%&}md5=25d7ddae9c99d42c71ac4707aa>>.

HUANG, C.-J.; CHEN, P.-W.; PAN, W.-T. Using multi-stage data mining technique to build forecast model for Taiwan stocks. **Neural Computing and Applications**, Department of Information Management, Aletheia University, New Taipei City, Taiwan, v. 21, n. 8, p. 2057–2063, 2012. ISSN 09410643 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84867723955{%&}partnerID=40{%&}md5=f9b5114e8cff647b2b4ca99efb>>.

HUANG, G.-B. Learning capability and storage capacity of two-hidden-layer feed-forward networks. **IEEE Transactions on Neural Networks**, v. 14, n. 2, p. 274–281, 2003. Cited By 269. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-0037361264&doi=10.1109%2fTNN.2003.809401&partnerID=40&md5=b5811b7c392ee735805e6545af8f1170>>.

HUANG, H. et al. Predicting stock trend using Fourier transform and support vector regression. In: X., L. et al. (Ed.). **17th IEEE International Conference on Computational Science and Engineering, CSE 2014 - Jointly with 13th IEEE International Conference on Ubiquitous Computing and Communications, IUCC 2014, 13th International Symposium on Pervasive Systems, Algorithms, a**. Department of Marketing, University of Kentucky, Lexington, United States: Institute of Electrical and Electronics Engineers Inc., 2015. p. 213–216. ISBN 9781479979813 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84925246757{%&}partnerID=40{%&}md5=239123f77f09d094129a5a8efe>>.

IACOMIN, R. Stock market prediction. In: M., B.; R., S.; S., C. (Ed.). **19th International Conference on System Theory, Control and Computing, ICSTCC 2015 - Joint Conference SINTES 19, SACCS 15, SIMSIS 19**. Faculty of Automatic Control and Computers, University POLITEHNICA of Bucharest, Bucharest, Romania: Institute of Electrical and Electronics Engineers Inc., 2015. p. 200–205. ISBN 9781479984817 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84957824593{%&}partnerID=40{%&}md5=05bcc0e99074ad9ce912a36733>>.

IACOMIN, R. Feature optimization on stock market predictor. In: **13th International Conference on Development and Application Systems, DAS**. Faculty of Automatics and Computer Science, University Politehnica of Bucharest, Romania: Institute of Electrical and Electronics Engineers Inc., 2016. p. 243–247. ISBN 9781509019939 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84980357149{%&}partnerID=40{%&}md5=d9da1a953786b4cb6af3f17dc2>>.

IEEE. **IEEE**. 2016. <<https://supportcenter.ieee.org>>. Acessado em 27 de setembro de 2016.

IMAN, K.; KEMIN, Z. How to invest in uncertain markets. In: Q., Z.; S., L. (Ed.). **34th Chinese Control Conference, CCC**. ExtraTech Systems LLCID, United States: IEEE Computer Society, 2015. v. 2015-Septe, p. 8617–8622. ISBN 19341768 (ISSN); 9789881563897 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84946606644{%&}partnerID=40{%&}md5=9885cd5f449312cc13e35edbe9>>.

- ISHII, Y.; TAKEYASU, K. A hybrid method to improve forecasting accuracy utilizing genetic algorithm and its application to stock market price data (J-REIT: Residential type). In: **2014 Joint 7th International Conference on Soft Computing and Intelligent Systems, SCIS 2014 and 15th International Symposium on Advanced Intelligent Systems, ISIS 2014**. Department of Management Design, Faculty of Business Administration, Osaka International University, 3-50-1, Sugi, Hirakata, Osaka, Japan: Institute of Electrical and Electronics Engineers Inc., 2014. p. 1280–1283. ISBN 9781479959556 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84946531158{&}partnerID=40{&}md5=9ef4f38d3fbb3b9b396fef911a>>.
- IUHASZ, G.; TIREA, M.; NEGRU, V. Neural network predictions of stock price fluctuations. In: **14th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing, SYNASC 2012**. West University of Timisoara, Computer Science Department, Timisoara, Romania: IEEE, 2012. p. 505–512. ISBN 9780769549347 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84875665044{&}partnerID=40{&}md5=3811c4b0af8dc2a0820090eaff>>.
- JAMES, J. et al. Simple trend-following strategies in currency trading. **Quantitative Finance**, Taylor & Francis, v. 3, n. 4, p. 75–77, 2003.
- JANG, J.-S. Anfis: adaptive-network-based fuzzy inference system. **Systems, Man and Cybernetics, IEEE Transactions on**, v. 23, n. 3, p. 665–685, May 1993. ISSN 0018-9472.
- JEGADEESH, N.; TITMAN, S. Returns to buying winners and selling losers: Implications for stock market efficiency. **The Journal of finance**, Wiley Online Library, v. 48, n. 1, p. 65–91, 1993.
- KAMP, M.; BOLEY, M.; GÄRTNER, T. Beating human analysts in nowcasting corporate earnings by using publicly available stock price and correlation features. In: P., N.-T. et al. (Ed.). **14th SIAM International Conference on Data Mining, SDM**. Fraunhofer IAIS, United States: Society for Industrial and Applied Mathematics Publications, 2014. v. 2, p. 641–649. ISBN 9781510811515 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84959868247{&}partnerID=40{&}md5=98270285a913fa9a73fd67485a>>.
- KEYNES, J. M. Some aspects of commodity markets. **Manchester Guardian Commercial: European Reconstruction Series**, v. 13, p. 784–786, 1923.
- KITCHENHAM, B. **Procedures for Performing Systematic Reviews**. 2004. <[http://www.ucalgary.ca/~medlibr/kitchenham\\_2004.pdf](http://www.ucalgary.ca/~medlibr/kitchenham_2004.pdf)>. Acessado em 20 de agosto de 2016.
- LAHMIRI, S.; BOUKADOUM, M.; CHARTIER, S. Information fusion and S&P500 trend prediction. In: **2013 IEEE and Arab Computing Society (ACS) International Conference on Computer Systems and Applications, AICCSA 2013**. ESCA School of Management, Casablanca, Morocco: IEEE, 2013. ISBN 21615322 (ISSN); 9781479907922 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84887223747{&}partnerID=40{&}md5=a3558e1f8c63a898ee82c89c52>>.
- LARSON, M. **Technical Charting for Profits**. USA: Wiley, 2002. (Wiley online trading for a living). ISBN 9780471437987.
- LEWIS, M. **Flash Boys: A Wall Street Revolt**. USA: W. W. Norton, 2014. ISBN 9780393244670. Disponível em: <<https://books.google.com.br/books?id=AarfAgAAQBAJ>>.

- LI, M.; QIU, Y.; ZHANG, Z. Combining recursive feature elimination and support vector machines for stock price forecasting. **Journal of Computational Information Systems**, China Center for Industrial Security Research, Beijing Jiaotong University, Beijing 100044, China, v. 9, n. 16, p. 6519–6526, 2013. ISSN 15539105 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84883189890{&}partnerID=40{&}md5=9fcfc1b62d51025243c4b7a009>>.
- LI, Q. et al. A Tensor-Based Information Framework for Predicting the Stock Market. **ACM Transactions on Information Systems**, Association for Computing Machinery, Southwestern University of Finance and Economics, Collaborative Innovation Center for the Innovation and Regulation of Internetbased Finance, School of Economic Information Engineering, Chengdu, Sichuan, China, v. 34, n. 2, 2016. ISSN 10468188 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84958759335{&}partnerID=40{&}md5=e312a3cb1eaf89398cfabef413>>.
- LI, Q. et al. Media-aware quantitative trading based on public Web information. **Decision Support Systems**, Elsevier, Southwestern University of Finance and Economics, China, v. 61, n. 1, p. 93–105, 2014. ISSN 01679236 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84897550633{&}partnerID=40{&}md5=0513007fb12ba97c669fe4e35b>>.
- LIANG, X.-L.; NG, W. W. Y. Stock investment decision support using an ensemble of L-GEM based on RBFNN diverse trained from different years. In: **2012 International Conference on Machine Learning and Cybernetics, ICMMLC 2012**. Machine Learning and Cybernetic Research Center, School of Computer Science and Engineering, South China University of Technology, Guangzhou, China: IEEE, 2012. v. 1, p. 394–399. ISBN 2160133X (ISSN); 9781467314855 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84871654303{&}partnerID=40{&}md5=b3ace3f27caccb4eb9be15e72b>>.
- LIN, H.-T.; LIN, C.-J. A study on sigmoid kernels for svm and the training of non-psd kernels by smo-type methods. **submitted to Neural Computation**, p. 1–32, 2003.
- LIN, Y.; GUO, H.; HU, J. An SVM-based approach for stock market trend prediction. In: **2013 International Joint Conference on Neural Networks, IJCNN 2013**. Graduate School of Information, Production and Systems, Waseda University, Japan: IEEE, 2013. ISBN 9781467361293 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84893619529{&}partnerID=40{&}md5=189397c9fb01b4883750eb323c>>.
- LIU, Y. et al. Composite leading search index: a preprocessing method of internet search data for stock trends prediction. **Annals of Operations Research**, Kluwer Academic Publishers, School of Management, University of Chinese Academy of Sciences, Beijing, China, v. 234, n. 1, p. 77–94, 2015. ISSN 02545330 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84943355600{&}partnerID=40{&}md5=8f13f9d0dde5724491f4cdafe6>>.
- LIU, Y. et al. A preprocessing method of internet search data for prediction improvement: Application to chinese stock market. In: **Workshop on Data Mining and Intelligent Knowledge Management, DM-IKM 2012**. New York, NY, USA: ACM, 2012. (DM-IKM '12), p. 3:1–3:7. ISBN 9781450315517 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84877325390{&}partnerID=40{&}md5=02072d9b355bd4fa318e353672>>.

LO, A. W.; MAMAYSKY, H.; WANG, J. Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. **Journal of Finance**, v. 55, p. 1705–1765, 2000.

LOUWERSE, V.; ROTHKRANTZ, L. Intraday stock forecasting. In: B., R.; A., S. (Ed.). **15th International Conference on Computer Systems and Technologies, CompSysTech 2014**. Faculty of Electrical Engineering, Mathematics and Computer Science, Delft University of Technology, Mekelweg 4, Delft, Netherlands: Association for Computing Machinery, 2014. v. 883, p. 202–209. ISBN 9781450327534 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84908676181{&}partnerID=40{&}md5=22f50d6e875abdc9c2145bbbd>>.

LUO, J.; SI, Y.-W.; FONG, S. Trend following with float-encoding genetic algorithm. In: **7th International Conference on Digital Information Management, ICDIM 2012**. Department of Computer and Information Science, University of Macau, Av. Padre Tomas Pereira, Taipa, Macau: ACM, 2012. p. 173–176. ISBN 9781467324281 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84871605738{&}partnerID=40{&}md5=e587e4e19728ddf12d7890744f>>.

LUO, Y. et al. Stock trends prediction based on hypergraph modeling clustering algorithm. In: Y., W.; X., L.; H., C. (Ed.). **2014 2nd IEEE International Conference on Progress in Informatics and Computing, PIC 2014**. State Key Lab of Software Engineering, Wuhan University, Wuhan, China: Institute of Electrical and Electronics Engineers Inc., 2014. p. 27–31. ISBN 9781479920334 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84919397199{&}partnerID=40{&}md5=b61aa80fe03382b0361eac5e95>>.

MA, N. et al. Neural network algorithm based method for stock price trend prediction. **Journal of Applied Sciences**, College of Information Technology, Beijing Union University, Beijing 100101, China, v. 13, n. 22, p. 5384–5390, 2013. ISSN 18125654 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84887593751{&}partnerID=40{&}md5=b9d25f2d7758ac03361b0888f9>>.

MACHADO, J.; NEVES, R.; HORTA, N. Developing multi-time frame trading rules with a trend following strategy, using GA. In: S., S. (Ed.). **17th Genetic and Evolutionary Computation Conference, GECCO 2015**. Instituto de Telecomunicações, Instituto Superior Técnico, Torre Norte - Piso 9, Av. Rovisco Pais, 1, Lisboa, Portugal: Association for Computing Machinery, Inc, 2015. p. 765–766. ISBN 9781450334884 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84959440367{&}partnerID=40{&}md5=48ac370a288dbb1ab5df867e9a>>.

MAHMUD, M. S.; MEESAD, P. Time series stock price prediction using recurrent error based neuro-fuzzy system with momentum. In: **2014 International Electrical Engineering Congress, iEECON 2014**. Faculty of Information Technology, King Mongkut's University of Technology North Bangkok, Bangkok, Thailand: Institute of Electrical and Electronics Engineers Inc., 2014. ISBN 9781479931743 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84911894061{&}partnerID=40{&}md5=c25cdb1a7019e3e3946e99aaab>>.

MALKIEL, B. G. The efficient market hypothesis and its critics. **Journal of economic perspectives**, JSTOR, p. 59–82, 2003.

MANOJLOVIĆ, T.; ŠTAJDUHAR, I. Predicting stock market trends using random forests: A sample of the Zagreb stock exchange. In: V., S. et al. (Ed.). **38th International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2015**. University of Rijeka, Faculty of Engineering, Department of Computer Engineering, Rijeka, Croatia: Institute of Electrical and Electronics Engineers Inc., 2015. p. 1189–1193. ISBN 9789532330854 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84946135452{&}partnerID=40{&}md5=69d4a71486411d799d4a7efa1d>>.

MARKOVIĆ, I. P.; STOJANOVIĆ, M. B.; BOŽIĆ, M. M. Stock market trend prediction using a sparse Bayesian framework. In: B., R.; S., S. (Ed.). **12th Symposium on Neural Network Applications in Electrical Engineering, NEUREL 2014**. Faculty of Economics at the University of Nis, Trg Kralja Aleksandra Ujedinitelja 11, Niš, Serbia: Institute of Electrical and Electronics Engineers Inc., 2015. p. 207–210. ISBN 9781479958887 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84922799984{&}partnerID=40{&}md5=5d72ab0fc436071bfde8ce8977>>.

MARTIN, V. Predicting the french stock market using social media analysis. In: **8th International Workshop on Semantic and Social Media Adaptation and Personalization, SMAP 2013**. Université de Toulon, CNRS, LISIS, 83957 La Garde, France: IEEE Computer Society, 2013. p. 3–7. ISBN 9780769551326 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84896774588{&}partnerID=40{&}md5=9054b6c87a50ad3198349e588e>>.

MATHWORKS. **Mathworks Documentation**. 2017. <<https://www.mathworks.com>>. Acessado em 7 de janeiro de 2017.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.

MEESAD, P.; LI, J. Stock trend prediction relying on text mining and sentiment analysis with tweets. In: **2014 4th World Congress on Information and Communication Technologies, WICT 2014**. Faculty of Information Technology, King Mongkut's University of Technology North Bangkok, Bangkok, Thailand: Institute of Electrical and Electronics Engineers Inc., 2014. p. 257–262. ISBN 9781479981151 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84946693251{&}partnerID=40{&}md5=86ba9291b205bee36d569eb153>>.

MEESAD, P.; RASEL, R. I. Predicting stock market price using support vector regression. In: **2013 2nd International Conference on Informatics, Electronics and Vision, ICIEV 2013**. Faculty of Information Technology, King Mongkut's University of Technology, North-Bangkok, Thailand: IEEE, 2013. ISBN 9781479903979 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84883381673{&}partnerID=40{&}md5=b8578b5f60edc8b497ec660e69>>.

MERCER, J. Functions of positive and negative type, and their connection with the theory of integral equations. **Philosophical transactions of the royal society of London. Series A, containing papers of a mathematical or physical character**, JSTOR, v. 209, p. 415–446, 1909.

METGHALCHI, M.; CHANG, Y.-H.; GARZA-GOMEZ, X. Technical analysis of the taiwanese stock market. **International Journal of Economics and Finance**, v. 4, n. 1, p. p90, 2012.



MICHAELY, R.; THALER, R. H.; WOMACK, K. Price reactions to dividend initiations and omissions: Overreaction or drift? **The Journal of finance**, v. 50, n. 2, p. 573–608, 1995.

MILLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, v. 6, n. 4, p. 525 – 533, 1993. ISSN 0893-6080. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0893608005800565>>.

MITCHELL, T. M. **Machine learning**. Boston, MA: McGraw-Hill, 1997. ISBN 0070428077.

MURPHY, J. J. **Technical analysis of the financial markets: A comprehensive guide to trading methods and applications**. Westminster, London, U.K.: Penguin, 1999.

MURPHY, K. P. Naive bayes classifiers. **University of British Columbia**, 2006.

NASDAQ. **NASDAQ**. 2016. <<http://www.nasdaq.com/investing/glossary/h/high-frequency-trading>>. Acessado em 26 de agosto de 2016.

NAYAK, R. K.; MISHRA, D.; RATH, A. K. A Naïve SVM-KNN based stock market trend reversal analysis for Indian benchmark indices. **Applied Soft Computing Journal**, Elsevier Ltd, Department of Computer Science and Engineering, Institute of Technical Education and Research, Siksha 'O' Anusandhan University, Khandagiri, Bhubaneswar, OD, India, v. 35, p. 670–680, 2015. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84937902211{&}partnerID=40{&}md5=0abe4fe152d2f5d2ebac37baf4>>.

NEELY, C. J. et al. Forecasting the equity risk premium: the role of technical indicators. **Management Science**, INFORMS, v. 60, n. 7, p. 1772–1791, 2014.

NELSON, S. **The ABC of stock speculation**. Garden City, New York: Doubleday, Page & Company, 1912.

NIE, C.-X.; JIN, X.-B. The interval slope method for long-term forecasting of stock price trends. **Advances in Mathematical Physics**, Hindawi Publishing Corporation, School of Computer and Information Engineering, Beijing Technology and Business University, Beijing, China, v. 2016, 2016. ISSN 16879120 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962010132{&}partnerID=40{&}md5=0d4fbaad5d04cfb96f80485ba4>>.

NOVAK, E.; RITTER, K. The curse of dimension and a universal method for numerical integration. In: \_\_\_\_\_. **Multivariate Approximation and Splines**. Basel: Birkhäuser Basel, 1997. p. 177–187. ISBN 978-3-0348-8871-4. Disponível em: <[http://dx.doi.org/10.1007/978-3-0348-8871-4\\_15](http://dx.doi.org/10.1007/978-3-0348-8871-4_15)>.

OXFORD. **speculation**. 2017. <<https://en.oxforddictionaries.com/definition/speculation>>. Acessado em 2 de fevereiro 2017.

PALIYAWAN, P. Stock market direction prediction using data mining classification. **ARPN Journal of Engineering and Applied Sciences**, Asian Research Publishing Network, Thailand, v. 10, n. 3, p. 1302–1310, 2015. ISSN 18196608 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84923852192{&}partnerID=40{&}md5=1559ce49c1ef7177dc468ee1e8>>.

PANIGRAHI, S. S.; MANTRI, J. K. A text based Decision Tree model for stock market forecasting. In: **1st International Conference on Green Computing and Internet of Things, ICGCIoT 2015**. Deptt. of Computer Science and Applications, North Odisha University, India: Institute of Electrical and Electronics Engineers Inc., 2015. p. 405–411. ISBN 9781467379090 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84966473186{&}partnerID=40{&}md5=d9ec30221f55f32096980c0287>>.

PANIGRAHI, S. S.; MANTRI, J. K. Epsilon-SVR and decision tree for stock market forecasting. In: **1st International Conference on Green Computing and Internet of Things, ICGCIoT 2015**. Deptt. of Computer Science and Applications, North Odisha University, India: Institute of Electrical and Electronics Engineers Inc., 2015. p. 761–766. ISBN 9781467379090 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84966661159{&}partnerID=40{&}md5=1104b2d97af40a857204c0c717>>.

PARK, C.-H.; IRWIN, S. H. What do we know about the profitability of technical analysis? **Journal of Economic Surveys**, Blackwell Publishing Ltd, v. 21, n. 4, p. 786–826, 2007. ISSN 1467-6419. Disponível em: <<http://dx.doi.org/10.1111/j.1467-6419.2007.00519.x>>.

PATEL, J. et al. Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. **Expert Systems with Applications**, Elsevier Ltd, Computer Science and Engineering Department, Institute of Technology, Nirma University, Ahmedabad, Gujarat, India, v. 42, n. 1, p. 259–268, 2015. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84906535768{&}partnerID=40{&}md5=eb236158be7adf71d1a01fd2bc>>.

PHILLIPS, P. P.; PHILLIPS, J. J. **Return on investment (ROI) basics**. USA: American Society for Training and Development, 2006.

PLATT, J. Fast training of support vector machines using sequential minimal optimization. In: SCHOELKOPF, B.; BURGESS, C.; SMOLA, A. (Ed.). **Advances in Kernel Methods - Support Vector Learning**. MIT Press, 1998. Disponível em: <<http://research.microsoft.com/~jplatt/smo.html>>.

PRASANNA, S.; MARAN, E. Stock market prediction using clustering with meta-heuristic approaches. **Gazi University Journal of Science**, Gazi University Eti Mahallesi, Information Technology and Engineering, Vellore Institute of Technology, Vellore, India, v. 28, n. 3, p. 395–403, 2015. ISSN 13039709 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84941661201{&}partnerID=40{&}md5=32b5b313d782555c9d772b8fb9>>.

PRESS, O. U. **OXFORD DICTIONARIES**. 2016. <<http://www.oxforddictionaries.com/definition/english/algorithm>>. Acessado em 26 de agosto de 2016.

PRING, M. J. **Technical Analysis Explained, Fifth Edition: The Successful Investor's Guide to Spotting Investment Trends and Turning Points**. Boston, MA: McGraw-Hill, 2014. ISBN 978-0-07-182655-6.

QU, H.; ZHANG, Y. A new kernel of support vector regression for forecasting high-frequency stock returns. **Mathematical Problems in Engineering**, Hindawi Publishing Corporation, School of Management and Engineering, Nanjing University, No. 22 Hankou Road, Nanjing, China, v. 2016, 2016. ISSN 1024123X (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84973345056{&}partnerID=40{&}md5=1767443703b5192fff2b86fb2f>>.

QUINLAN, J. R. Simplifying decision trees. **International journal of man-machine studies**, Elsevier, v. 27, n. 3, p. 221–234, 1987.

RABUNAL, J.; DORADO, J. **Artificial neural networks in real-life applications**. London, England, UK: Idea Group Pub., 2005. ISBN 1591409047.

RAO, T.; SRIVASTAVA, S. Modeling movements in oil, gold, forex and market indices using search volume index and twitter sentiments. In: **3rd Annual ACM Web Science Conference, WebSci 2013**. Netaji Subhas Institute of Technology, Delhi, India: ACM, 2013. p. 336–345. ISBN 9781450318891 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84883061680{&}partnerID=40{&}md5=d09398c08cfa4283dd0dc31c6>>.

RAO, V. B. **C++, neural networks and fuzzy logic**. Foster City, California, USA: M&T Books, IDG Books Worldwide, Inc., 1995. ISBN 1558515526.

REILLY, F.; BROWN, K. **Investment Analysis and Portfolio Management**. 10nd. ed. USA: Cengage Learning, 2011. ISBN 9780538482387.

RHEA, R. **The Dow Theory**. New York, N.Y.: Barron's, 1932.

RICE, J. **Mathematical statistics and data analysis**. Scarborough, Canada: Nelson Education, 2006. ISBN 978-0534399429.

ROKACH, L. Ensemble-based classifiers. **Artificial Intelligence Review**, Springer, v. 33, n. 1-2, p. 1–39, 2010.

ROMERO, E.; SOPENA, J. Performing feature selection with multilayer perceptrons. **Neural Networks, IEEE Transactions on**, v. 19, n. 3, p. 431–441, March 2008. ISSN 1045-9227.

ROMEU, R.; SERAJUDDIN, U. **Technical Analysis for Direct Access Trading: A Guide to Charts, Indicators, and Other Indispensable Market Analysis Tools: A Guide to Charts, Indicators, and Other Indispensable Market Analysis Tools**. Boston, MA: McGraw-Hill Education, 2001. (The Direct access trader series). ISBN 9780071382656.

ROSAS-ROMERO, R.; DÍAZ-TORRES, A.; ETCHEVERRY, G. Forecasting of stock return prices with sparse representation of financial time series over redundant dictionaries. **Expert Systems with Applications**, Elsevier Ltd, Department of Electrical and Computer Engineering, Universidad de Las Américas-Puebla, Mexico, v. 57, p. 37–48, 2016. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962349243{&}partnerID=40{&}md5=c6597b5281b8f66a689ca6abaf>>.

ROSILLO, R.; GINER, J.; De La Fuente, D. Stock market simulation using support vector machines. **Journal of Forecasting**, John Wiley and Sons Ltd, Business Management Department, Faculty of Business, University of Leon, C/Campus de Vegazana s/n, Leon 24071, Spain, v. 33, n. 6, p. 488–500, 2014. ISSN 02776693 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84906947839{&}partnerID=40{&}md5=7a49ccaf52e3d12aaf5179226a>>.

RYOTA, K.; TOMOHARU, N. Stock market prediction based on interrelated time series data. In: **2012 IEEE Symposium on Computers and Informatics, ISCI 2012**. Graduate School of Environment and Information Sciences, Yokohama National University, Kanagawa, Japan: IEEE, 2012. p. 17–21. ISBN 9781467316859 (ISBN). Disponível

em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84864270533{&}partnerID=40{&}md5=f08c783130b9c3212516aee9ca>>.

SADAEI, H. J. et al. A hybrid model based on differential fuzzy logic relationships and imperialist competitive algorithm for stock market forecasting. **Applied Soft Computing Journal**, Elsevier Ltd, Graduate Program in Electrical Engineering, Federal University of Minas Gerais, Av. Antônio Carlos 6627, Belo Horizonte, MG, Brazil, v. 40, p. 132–149, 2016. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84950124977{&}partnerID=40{&}md5=6dbdbe76915d82af04ca5c2a46>>.

SADHU, C. et al. Android application for stock market prediction by fuzzy logic. In: **2014 IEEE International Conference on Advanced Communication, Control and Computing Technologies, ICACCCT 2014**. Department of Electronics and Telecommunication, College of Engineering, Pune, India: Institute of Electrical and Electronics Engineers Inc., 2014. p. 1681–1685. ISBN 9781479939145 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84923268179{&}partnerID=40{&}md5=e481e4de0af8ad0672c0521c41>>.

SAHIN, U.; OZBAYOGLU, A. M. TN-RSI: Trend-normalized RSI indicator for stock trading systems with evolutionary computation. In: C.H., D. (Ed.). **Complex Adaptive Systems, 2014**. TOBB University of Economics and Technology, Department of Computer Engineering, Ankara, Turkey: Elsevier, 2014. v. 36, n. C, p. 240–245. ISBN 18770509 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84938564135{&}partnerID=40{&}md5=90eadcfa541503deda0efe47d8>>.

SANDS, T. M. et al. Robust stock value prediction using support vector machines with particle swarm optimization. In: **IEEE Congress on Evolutionary Computation, CEC 2015**. Electrical and Microelectronic Engineering, Rochester Institute of Technology, Rochester, NY, United States: Institute of Electrical and Electronics Engineers Inc., 2015. p. 3327–3331. ISBN 9781479974924 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84963558369{&}partnerID=40{&}md5=3e0bbb602ac57a3b2253c9921c>>.

SCHÖLKOPF, B.; PLATT, J.; HOFMANN, T. Learning with hypergraphs: Clustering, classification, and embedding. In: \_\_\_\_\_. **Advances in Neural Information Processing Systems 19: Proceedings of the 2006 Conference**. MIT Press, 2007. p. 1601–1608. ISBN 9780262256919. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6287378>>.

SCHÖLKOPF, B.; SMOLA, A. J. **Learning with kernels**. London, England: MIT press, 2002.

SCOPUS. **SCOPUS**. 2016. <<https://www.scopus.com>>. Acessado em 27 de setembro de 2016.

SEBASTIANI, F. Machine learning in automated text categorization. **ACM computing surveys (CSUR)**, ACM, v. 34, n. 1, p. 1–47, 2002.

SHAKERI, B. et al. Fuzzy clustering rule-based expert system for stock price movement prediction. In: **Annual Meeting of the North American Fuzzy Information Processing Society, NAFIPS 2015**. Computational Intelligent Systems Laboratory, Department of Industrial Engineering and Management Systems, Amirkabir University of Technology, Tehran, Iran: Institute of Electrical and Electronics Engineers Inc., 2015. v. 2015-Sept. ISBN 9781467372473 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84961938146{&}partnerID=40{&}md5=52231855b8a3e5068adbb5d381>>.

SHEN, Y. et al. Stock trends prediction by hypergraph modeling. In: **2012 IEEE 3rd International Conference on Software Engineering and Service Science, ICSESS 2012**. State Key Lab of Software Engineering, School of Computer Science, Wuhan University, Wuhan, China: IEEE, 2012. p. 104–107. ISBN 9781467320054 (ISBN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84866522106{&}partnerID=40{&}md5=269350962fe40107214bd31f78>>.

SHILLER, R. J. **Irrational exuberance**. USA: Princeton University Press, 2015.

SHYNKEVICH, Y. et al. Forecasting stock price directional movements using technical indicators: Investigating window size effects on one-step-ahead forecasting. In: R.J., A. et al. (Ed.). **2014 IEEE Conference on Computational Intelligence for Financial Engineering and Economics, CIFEr 2014**. Intelligent Systems Research Centre, University of Ulster, Derry Northern Ireland, United Kingdom: Institute of Electrical and Electronics Engineers Inc., 2014. p. 341–348. ISBN 9781479923809 (ISBN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84908121933{&}partnerID=40{&}md5=55ee4f17cee6264725f64eac80>>.

SHYNKEVICH, Y. et al. Stock price prediction based on stock-specific and sub-industry-specific news articles. In: **International Joint Conference on Neural Networks, IJCNN 2015**. Intelligent Systems Research Centre, University of Ulster, Derry, United Kingdom: Institute of Electrical and Electronics Engineers Inc., 2015. v. 2015-Septe. ISBN 9781479919604 (ISBN); 9781479919604 (ISBN); 9781479919604 (ISBN); 9781479919604 (ISBN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84951163585{&}partnerID=40{&}md5=5f38f5c18a69af7591902b780b>>.

SIEW, H. L.; NORDIN, M. J. Regression techniques for the prediction of stock price trend. In: **2012 International Conference on Statistics in Science, Business and Engineering, ICSSBE 2012**. Malaysian Institute of Information Technology, Universiti Kuala Lumpur, Kuala Lumpur, Malaysia: IEEE, 2012. p. 99–103. ISBN 9781467315821 (ISBN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84872932354{&}partnerID=40{&}md5=b4b11e1beca4a20db29f8f4047>>.

SIROHI, A. K.; MAHATO, P. K.; ATTAR, V. Multiple Kernel Learning for stock price direction prediction. In: **2014 International Conference on Advances in Engineering and Technology Research, ICAETR 2014**. Department of Comput. Eng. and IT, Coll. of Eng. Pune, Pune, India: Institute of Electrical and Electronics Engineers Inc., 2014. ISBN 9781479963935 (ISBN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84941058733{&}partnerID=40{&}md5=67c68313df98537280e47172fd>>.

SMITH, G. D.; EBRAHIM, S. Data dredging, bias, or confounding. **Bmj**, v. 325, n. 7378, p. 1437–8, 2002.

SMOLA, A. J. et al. **Regression estimation with support vector learning machines**. Tese (Doutorado) — Master's thesis, Technische Universität München, 1996.

SON, Y.; NOH, D.-J.; LEE, J. Forecasting trends of high-frequency KOSPI200 index data using learning classifiers. **Expert Systems with Applications**, Department of Industrial Engineering, Seoul National University, 1 Gwanak-ro, Gwanak-gu, Seoul 151-744, South Korea, v. 39, n. 14, p. 11607–11615, 2012. ISSN 09574174 (ISSN). Disponible em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84861799918{&}partnerID=40{&}md5=ab3faa4bae2cc58f8c11d94329>>.

STOCKCHARTS. **Moving Averages - Simple and Exponential**. 2017. <[http://stockcharts.com/school/doku.php?id=chart\\_school:technical\\_indicators:moving\\_averages](http://stockcharts.com/school/doku.php?id=chart_school:technical_indicators:moving_averages)>. Acessado em 9 de janeiro 2017.

STOCKCHARTS. **Percentage Price Oscillator**. 2017. <[http://stockcharts.com/school/doku.php?id=chart\\_school:technical\\_indicators:price\\_oscillators\\_ppo](http://stockcharts.com/school/doku.php?id=chart_school:technical_indicators:price_oscillators_ppo)>. Acessado em 2 de janeiro 2017.

STOCKCHARTS. **Standard Deviation**. 2017. <[http://stockcharts.com/school/doku.php?id=chart\\_school:technical\\_indicators:standard\\_deviation\\_volatility](http://stockcharts.com/school/doku.php?id=chart_school:technical_indicators:standard_deviation_volatility)>. Acessado em 2 de janeiro 2017.

SU, Z.; HADZIKADIC, M. An agent-based System for issuing stock trading signals. In: J., K.; T., O.; M.S., O. (Ed.). **5th International Conference on Simulation and Modeling Methodologies, Technologies and Applications, SIMULTECH 2015**. Complex Systems Institute, University of North Carolina at Charlotte, 9201 University City Blvd., Charlotte, NC, United States: SciTePress, 2015. p. 352–358. ISBN 9789897581205 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84960961109{&}partnerID=40{&}md5=360f3a5cadfc2ad8403d157bf3>>.

SUBHA, M. V.; NAMBI, S. T. Classification of stock index movement using k-nearest neighbours (k-NN) algorithm. **WSEAS Transactions on Information Science and Applications**, Department of Online and Distance Education, Anna University of Technology, Coimbatore, Jyothispuram, Coimbatore -641 047, Tamil Nadu, India, v. 9, n. 9, p. 261–270, 2012. ISSN 17900832 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84872454745{&}partnerID=40{&}md5=7baf110d62db2bb88a98cb63f8>>.

SZADO, E. Defining speculation: The first step toward a rational dialogue. **The Journal of Alternative Investments**, Chartered Alternative Investment Analyst Association, v. 14, p. 75–82, 2011.

SZAKMARY, A. C.; SHEN, Q.; SHARMA, S. C. Trend-following trading strategies in commodity futures: A re-examination. **Journal of Banking & Finance**, Elsevier, v. 34, n. 2, p. 409–426, 2010.

TAN, P.-N. et al. **Introduction to data mining**. Karnataka, India: Pearson Education India, 2006.

TEIXEIRA, L. A.; OLIVEIRA, A. L. I. D. A method for automatic stock trading combining technical analysis and nearest neighbor classification. **Expert systems with applications**, Elsevier, v. 37, n. 10, p. 6885–6890, 2010.

TEWELES, R.; BRADLEY, E. **The Stock Market, 7th Edition**. USA: John Wiley & Sons Inc., 1998. ISBN 978-0-471-19134-6.

THOMSETT, M. **CMF–Chaikin Money Flow: Changes Anticipating Price Reversal**. USA: Pearson Education, 2010. (FT Press Delivers Insights for the Agile Investor). ISBN 9780132492065. Disponível em: <<https://books.google.ca/books?id=kDbOOGSNMW8C>>.

TICKNOR, J. L. A Bayesian regularized artificial neural network for stock market forecasting. **Expert Systems with Applications**, Duke University, Pratt School of Engineering, 121 Hudson Hall, Durham, NC 27708, United States, v. 40, n. 14, p. 5501–5506, 2013. ISSN

09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84877852473&partnerID=40&md5=5e268f11d4b53f15668218efdb>>.

TIREA, M.; NEGRU, V. Investment portfolio optimization based on risk and trust management. In: **2013 IEEE 11th International Symposium on Intelligent Systems and Informatics, SISY 2013**. West University of Timisoara, Computer Science Department, Timisoara, Romania: IEEE, 2013. p. 369–374. ISBN 9781479903054 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84892527238&partnerID=40&md5=fab8910dfc41c157f4e2bb7442>>.

TIREA, M.; TANDAU, I.; NEGRU, V. Multi-agent stock trading algorithm model. In: **13th International Symposium on Symbolic and Numeric Algorithms for Scientific Computing, SYNASC 2011**. Computer Science Department, West University of Timisoara, Timisoara, Romania: IEEE, 2012. p. 365–372. ISBN 9780769546308 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84860466741&partnerID=40&md5=37f62c704924da05efe6e83983>>.

TRADINGSOLUTIONS. **Variance**. 2017. <<http://www.tradingsolutions.com/functions/Variance.html>>. Acessado em 2 de janeiro 2017.

TSAI, C.-F.; QUAN, Z.-Y. Stock prediction by searching for similarities in candlestick charts. **ACM Transactions on Management Information Systems**, Association for Computing Machinery, Department of Information Management, National Central University, China, v. 5, n. 2, 2014. ISSN 2158656X (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84905750500&partnerID=40&md5=f648af626f23b505020c127ec9>>.

TSYMBAL, A. The problem of concept drift: definitions and related work. **Computer Science Department, Trinity College Dublin**, Citeseer, v. 106, n. 2, 2004.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. New York, NY, USA: Springer-Verlag New York, Inc., 1995. ISBN 0-387-94559-8.

WANG, D.; LIU, X.; WANG, M. A DT-SVM strategy for stock futures prediction with big data. In: **2013 16th IEEE International Conference on Computational Science and Engineering, CSE 2013**. Software Engineering Institute, East China Normal University, Shanghai 200062, China: IEEE, 2013. p. 1005–1012. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84900381752&partnerID=40&md5=5ba03b105ecefcc882020bfeb1>>.

WANG, F.; YU, P. L. H.; CHEUNG, D. W. Complex stock trading strategy based on Particle Swarm Optimization. In: **2012 IEEE Conference on Computational Intelligence for Financial Engineering and Economics, CIFE 2012**. Department of Computer Science, University of Hong Kong, Pokfulam, Hong Kong, Hong Kong: IEEE, 2012. p. 48–53. ISBN 9781467318037 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84869843640&partnerID=40&md5=83eef84dc3de5da596d9a4ea6b>>.

WANG, F.; YU, P. L. H.; CHEUNG, D. W. Combining technical trading rules using parallel particle swarm optimization based on Hadoop. In: **2014 International Joint Conference on Neural Networks, IJCNN 2014**. Department of Computer Science, University of Hong Kong, Pokfulam, Hong Kong: Institute of Electrical and Electronics Engineers Inc., 2014. p. 3987–3994. ISBN 9781479914845 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84908474587&partnerID=40&md5=575d2873fe2d214bd08d3b134f>>.

WANG, F.; YU, P. L. H.; CHEUNG, D. W. Combining technical trading rules using particle swarm optimization. **Expert Systems with Applications**, Department of Computer Science, University of Hong Kong, Pokfulam Road, Hong Kong, Hong Kong, v. 41, n. 6, p. 3016–3026, 2014. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84890568708{&}partnerID=40{&}md5=1ec2b5aac39e2198bfed8087c7>>.

WANG, L. et al. Stock market trend prediction using dynamical Bayesian factor graph. **Expert Systems with Applications**, Elsevier Ltd, School of Economics and Management, Tsinghua University, Beijing, China, v. 42, n. 15-16, p. 6267–6275, 2015. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84929493247{&}partnerID=40{&}md5=900f2e648c998162491f9bb5bf>>.

WANG, S.; SHANG, W. Forecasting direction of China security index 300 movement with least squares support vector machine. In: **2nd International Conference on Information Technology and Quantitative Management, ITQM 2014**. NCMIS, Academy of Mathematics and Systems Science, Chinese Academy of Sciences, Beijing 100190, China: Elsevier, 2014. v. 31, p. 869–874. ISBN 18770509 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84902283260{&}partnerID=40{&}md5=8e18c05aa945601b6e56935e72>>.

WANG, T. et al. A sentiment-based hybrid model for stock return forecasting. In: **17th Pacific Asia Conference on Information Systems, PACIS 2013**. School of Economic Information Engineering, Southwestern University of Finance and Economics, Chengdu, China: Pacific Asia Conference on Information Systems, 2013. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84928494242{&}partnerID=40{&}md5=1b0e25f3cf51bba9f4e7413dec>>.

WEBFINANCE. **stock exchange**. 2017. <<http://www.businessdictionary.com/definition/stock-exchange.html>>. Acessado em 30 de janeiro 2017.

WEI, G.; ZHANG, W.; ZHOU, L. Stock trends prediction combining the public opinion analysis. In: R., Z. et al. (Ed.). **International Conference on Logistics, Informatics and Service Science, LISS 2015**. School of Management, University Of Science and Technology Beijing, Beijing, China: Institute of Electrical and Electronics Engineers Inc., 2015. ISBN 9781479918904 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84971622020{&}partnerID=40{&}md5=030ff55b2a50948cc5fae57842>>.

WEI, L.-Y. A hybrid model based on ANFIS and adaptive expectation genetic algorithm to forecast TAIEX. **Economic Modelling**, Department of Information Management, Yuanpei University, 306 Yuanpei Street, Hsin Chu 30015, Taiwan, v. 33, p. 893–899, 2013. ISSN 02649993 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84880320790{&}partnerID=40{&}md5=3a8268c501e6368512ffb97e02>>.

WEI, L.-Y.; CHENG, C.-H. A hybrid recurrent neural networks model based on synthesis features to forecast the Taiwan stock market. **International Journal of Innovative Computing, Information and Control**, Department of Information Management, Yuanpei University, No. 306, Yuanpei Street, Hsin Chu 30015, Taiwan, v. 8, n. 8, p. 5559–5571, 2012. ISSN 13494198 (ISSN).

WEI, L.-Y.; CHENG, C.-H.; WU, H.-H. A hybrid ANFIS based on n-period moving average model to forecast TAIEX stock. **Applied Soft Computing Journal**, Department of Information



Management, Yuanpei University, 306 Yuanpei Street, Hsin Chu 30015, Taiwan, v. 19, p. 86–92, 2014. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84896857665{&}partnerID=40{&}md5=7818f0ccbe8870dc8d36f530a3>>.

WEI, Y.; CHAUDHARY, V. The influence of sample reconstruction on stock trend prediction via NARX neural network. In: **IEEE 14th International Conference on Machine Learning and Applications, ICMLA 2015**. Department of Computer Science and Engineering, University at Buffalo, Buffalo, NY, United States: Institute of Electrical and Electronics Engineers Inc., 2015. p. 52–57. ISBN 9781509002870 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84969601784{&}partnerID=40{&}md5=338956b0a9a93d92de38ba16d4>>.

WEN, F. et al. Stock price prediction based on SSA and SVM. In: **2nd International Conference on Information Technology and Quantitative Management, ITQM 2014**. Business School of Central South University, Changsha, 410081, China: Elsevier, 2014. v. 31, p. 625–631. ISBN 18770509 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84902253455{&}partnerID=40{&}md5=d52db136fc6808cc46a340f50f>>.

WICHADIT, S.; KITTITORNKUN, S. Predicting SET50 stock prices using CARIMA (Cross Correlation ARIMA). In: **19th International Computer Science and Engineering Conference, ICSEC 2015**. Dept. of Computer Engineering, Faculty of Engineering, King Mongkut's Institute of Technology, Ladkrabang, Thailand: Institute of Electrical and Electronics Engineers Inc., 2015. ISBN 9781467378253 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84964402894{&}partnerID=40{&}md5=cc7b0649ad600aaab501f85622>>.

WIDIPUTRA, H.; PAHLEVI, B. Inter-transaction association rule mining in the Indonesia stock exchange market. In: **2012 International Conference on Uncertainty Reasoning and Knowledge Engineering, URKE 2012**. Faculty of Information Technology, Perbanas Institute, Jakarta, Indonesia: IEEE, 2012. p. 149–152. ISBN 9781467314596 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84868232022{&}partnerID=40{&}md5=3a1540b19cb98248e8c0b14678>>.

WILDER, J. **New Concepts in Technical Trading Systems**. Greensboro, North California, USA: Trend Research, 1978. ISBN 9780894590276.

WILLIAMS, L. **How I Made One Million Dollars Last Year Trading Commodities**. USA: Windsor Books, 1979. ISBN 9780930233105.

WILLIAMS, L. The ultimate oscillator. **Technical Analysis of Stocks and Commodities**, v. 3, n. 4, p. 140–141, 1984.

WU, B.-H.; HE, J.-M. The trend analysis of China's stock market based on fractal method and BP neural network model. In: H., L.; Y.-H., Y. (Ed.). **21th Annual International Conference on Management Science and Engineering, ICMSE 2014**. School of Economics and Management, Southeast University, Nanjing, China: IEEE Computer Society, 2014. p. 1258–1266. ISBN 21551847 (ISSN); 9781479953752 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84908455880{&}partnerID=40{&}md5=f97134ae13ce6ecbe03e5a9134>>.

WU, J.-L.; CHANG, P.-C. A trend-based segmentation method and the support vector regression for financial time series forecasting. **Mathematical Problems in Engineering**, Department of Information Management, Yuan Ze University, Taoyuan 32026, Taiwan, v. 2012, 2012. ISSN 1024123X (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84867948503{&}partnerID=40{&}md5=46b370ff02c1f685245f61b878>>.

WU, J.-L.; YU, L.-C.; CHANG, P.-C. An intelligent stock trading system using comprehensive features. **Applied Soft Computing Journal**, Elsevier Ltd, Innovation Center of Big Data and Digital Convergence, Yuan Ze University, Taoyuan, Taiwan, v. 23, p. 39–50, 2014. ISSN 15684946 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84903639947{&}partnerID=40{&}md5=9ccccfafcbcf2d0c134899fb5f>>.

WU, K.-P.; WU, Y.-P.; LEE, H.-M. Stock trend prediction by using k-means and aprioriall algorithm for sequential chart pattern mining. **Journal of Information Science and Engineering**, Institute of Information Science, Department of Computer Science and Information Engineering, National Taiwan University of Science and Technology, Taipei, 106, Taiwan, v. 30, n. 3, p. 653–667, 2014. ISSN 10162364 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84902332770{&}partnerID=40{&}md5=0b23d79413f6fcf03e5d16b582>>.

WU, M.-T.; YONG, Y. The research on stock price forecast model based on data mining of BP neural networks. In: **2013 3rd International Conference on Intelligent System Design and Engineering Applications, ISDEA 2013**. Economic and Management College Northeast Petroleum University, Daqing, Heilongjiang, 163318, China: IEEE, 2013. p. 1526–1529. ISBN 9780769549231 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84874489792{&}partnerID=40{&}md5=74912084c9b2c6bddd334c6e0>>.

WU, Y.-P.; WU, K.-P.; LEE, H.-M. Stock trend prediction by sequential chart pattern via K-Means and AprioriAll algorithm. In: **2012 Conference on Technologies and Applications of Artificial Intelligence, TAAI 2012**. Department of Computer Science and Information Engineering, National Taiwan University of Science and Technology, Taipei, Taiwan: IEEE, 2012. p. 176–181. ISBN 9780769549194 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84873376384{&}partnerID=40{&}md5=958fac104260c700181f8191c4>>.

XIA, Y.; LIU, Y.; CHEN, Z. Support Vector Regression for prediction of stock trend. In: **2013 6th International Conference on Information Management, Innovation Management and Industrial Engineering, ICIII 2013**. School of International Trade and Economics, Central University of Finance and Economics, Beijing, China: IEEE, 2013. v. 2, p. 123–126. ISBN 9781479939855 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84893691897{&}partnerID=40{&}md5=74f4da3dae834758479c341d2e>>.

XING, T. et al. The analysis and prediction of stock price. In: **2013 IEEE International Conference on Granular Computing, GrC 2013**. International School of Software, Wuhan University, Wuhan, China: IEEE Computer Society, 2013. p. 368–373. ISBN 9781479912810 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84900635740{&}partnerID=40{&}md5=29031f86e60001effb8a0c8d2f>>.

XPI. **Aluguel (BTC)**. 2017. <<https://www.xpi.com.br/investimentos/acoes/btc/>>. Acessado em 6 de janeiro de 2017.

XU, M.; LAN, Y.; JIANG, D. Unsupervised Learning Part-Based Representation for Stocks Market Prediction. In: **8th International Symposium on Computational Intelligence and Design, ISCID 2015**. Department of Economics and Management, Jiangxi Agricultural University, Nanchang, China: Institute of Electrical and Electronics Engineers Inc., 2016. v. 2, p. 63–66. ISBN 9781467395861 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84978153356{&}partnerID=40{&}md5=ae77a2834afa9ec6324888ae5f>>.

XU, Y.; LI, Z.; LUO, L. A study on feature selection for trend prediction of stock trading price. In: **2013 5th International Conference on Computational and Information Sciences, ICCIS 2013**. Department of Automation, Xiamen University, Xiamen, China: IEEE, 2013. p. 579–582. ISBN 9780769550046 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84890870453{&}partnerID=40{&}md5=c63ac185f03621f6abffbc771c>>.

XUE, Y. et al. Stock market trading rules discovery based on biclustering method. **Mathematical Problems in Engineering**, Hindawi Publishing Corporation, Laboratory of Quantum Engineering and Quantum Materials, School of Physics and Telecommunication Engineering, South China Normal University, Guangzhou, China, v. 2015, 2015. ISSN 1024123X (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84925324944{&}partnerID=40{&}md5=68b7d3c67ef398e5f3a6fa6282>>.

YANG, F.; ZHANG, J. Bullish-bearish-based neural network stock trading decision support and its application in Hong Kong stock market. In: **International Conference on Wavelet Analysis and Pattern Recognition, ICWAPR 2015**. Machine Learning and Cybernetics Research Center, School of Computer Science and Engineering, University of Technology, Guangzhou, China: IEEE Computer Society, 2015. v. 2015-October, p. 179–184. ISBN 21585695 (ISSN); 9781467372244 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84953870827{&}partnerID=40{&}md5=74d345024df57a0d10cc1ad777>>.

YANG, J.-H.; DAI, X.-Z. Prediction of Shanghai and Shenzhen 300 index based on EMD-SVM model. In: **2012 International Conference on Systems and Informatics, ICSAI 2012**. School of Business Administration, South China University of Technology, Guangzhou, China: IEEE, 2012. p. 1209–1212. ISBN 9781467301992 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84864271173{&}partnerID=40{&}md5=a2c31b43a06d04323b1ed593d3>>.

YANG, K.; WU, M.; LIN, J. The application of fuzzy neural networks in stock price forecasting based on Genetic Algorithm discovering fuzzy rules. In: **2012 8th International Conference on Natural Computation, ICNC 2012**. School of Information Management, Beijing Information Science and Technology University, 100192, Beijing, China: IEEE, 2012. p. 470–474. ISBN 21579555 (ISSN); 9781457721311 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84866181490{&}partnerID=40{&}md5=b5838dddaa512a15817161da29>>.

YIN, S. et al. Support vector regression based approach for key index forecasting with applications. In: **13th International Conference on Industrial Informatics, INDIN 2015**. School of Astronautics, Harbin Institute of Technology, Heilongjiang, China: Institute of Electrical and Electronics Engineers Inc., 2015. p. 591–596. ISBN 9781479966493 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84949514411{&}partnerID=40{&}md5=673787d6504fab9e31a6d40eb1>>.

YU, H. et al. Predictive ability and profitability of simple technical trading rules: Recent evidence from southeast asian stock markets. **International Review of Economics & Finance**, Elsevier, v. 25, p. 356–371, 2013.

ZADEH, L. Fuzzy sets. **Information and Control**, v. 8, n. 3, p. 338 – 353, 1965. ISSN 0019-9958. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S001999586590241X>>.

ZBIKOWSKI, K. Using Volume Weighted Support Vector Machines with walk forward testing and feature selection for the purpose of creating stock trading strategy. **Expert Systems with Applications**, Elsevier Ltd, Institute of Computer Science, Faculty of Electronics and Information Technology, Warsaw University of Technology, Warsaw, Poland, v. 42, n. 4, p. 1797–1805, 2015. ISSN 09574174 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84910674216{&}partnerID=40{&}md5=789f358c6577de7782bb128cf3>>.

ZHANG, C.; PAN, H. A novel hybrid model based on EMD-BPNN for forecasting US and UK stock indices. In: L., X.; Y., W. (Ed.). **3rd IEEE International Conference on Progress in Informatics and Computing, PIC 2015**. School of Management and Economics, University of Electronic Science and Technology of China, Chengdu, China: Institute of Electrical and Electronics Engineers Inc., 2015. p. 113–117. ISBN 9781467380867 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84979651445{&}partnerID=40{&}md5=b6d2c56a49c71edfa75db38487>>.

ZHAO, L.; WANG, L. Price Trend Prediction of Stock Market Using Outlier Data Mining Algorithm. In: H., Q. et al. (Ed.). **5th IEEE International Conference on Big Data and Cloud Computing, BDCloud 2015**. Baylor University, Japan: Institute of Electrical and Electronics Engineers Inc., 2015. p. 93–98. ISBN 9781467371834 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962734580{&}partnerID=40{&}md5=30daa784a60b3d0d321d927161>>.

ZHEN, L. Z. et al. Forecasting FTSE Bursa Malaysia KLCI trend with hybrid particle swarm optimization and support vector machine technique. In: **2013 World Congress on Nature and Biologically Inspired Computing, NaBIC 2013**. Faculty of Information and Communication Technology, Universiti Teknikal Malaysia Melaka (UTeM), Durian Tunggal, Melaka, Malaysia: IEEE, 2013. p. 169–174. ISBN 9781479914159 (ISBN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84887835844{&}partnerID=40{&}md5=33948b4aff9f895f45376ced4a>>.

ZHENG, X.; CHEN, B. M. Modeling and forecasting of stock markets under a system adaptation framework. **Journal of Systems Science and Complexity**, The Department of Electrical and Computer Engineering, The National University of Singapore, Singapore 117576, Singapore, v. 25, n. 4, p. 641–674, 2012. ISSN 10096124 (ISSN). Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84865559898{&}partnerID=40{&}md5=6db20a29a142a8d1a5a62a3abe>>.

ZLIOBAITE, I. Learning under concept drift: an overview. **CoRR**, v. 1010.4784, 2010. Disponível em: <<http://arxiv.org/abs/1010.4784>>.

## APÊNDICE A – Revisão Sistemática da Literatura

### A.1 Resumo

Esta revisão da literatura objetivou verificar o estado da arte na utilização de algoritmos computacionais para previsão de comportamento de ativos do mercado acionário. Buscou-se sintetizar os algoritmos de inteligência computacional mais empregados, bem como verificar as características utilizadas nas estratégias de previsão e negociação propostas. Para alcance do objetivo definido, foi utilizada a técnica de Revisão Sistemática da Literatura. Como resultado, de 2012 à agosto de 2016, foram identificadas 702 publicações relacionadas ao tema, destas, após as etapas de seleção primária e secundária da revisão sistemática, 145 referências foram utilizadas para coleta de dados. Ao todo, 15 tipos de informações foram extraídas e analisadas a partir da leitura completa das 145 referências consideradas. Desta maneira, foi possível identificar as principais características das estratégias mais recentes que se utilizam de algoritmos computacionais para previsão de comportamento de ativos no mercado acionário.

### A.2 Introdução

Revisão Sistemática da Literatura (SLR - *Systematic Literature Review*) consiste em uma técnica que especifica de forma objetiva, meios para identificar, avaliar e interpretar toda a informação relevante relativa a uma questão de pesquisa, área ou fenômeno de interesse (KITCHENHAM, 2004). Esta revisão permitiu verificar as principais características dos algoritmos mais recentes utilizados para previsão comportamental de ativos do mercado de ações. Foi possível identificar as tendências na utilização de algoritmos de inteligência computacional, e tratamentos especiais em etapas de pré-processamento.

### A.3 Metodologia

A SLR foi iniciada em agosto de 2016, e utilizou a base de dados bibliográfica Scopus® como plataforma de pesquisa. Em agosto de 2016, a base Scopus® possuía mais de 60 milhões de documentos cadastrados. A cada dia, em média, são incluídos 5.500 novas publicações (SCOPUS, 2016). Além de cadastro próprio, a base Scopus® indexa conteúdo de outras bases, como a IEEExplore® (IEEE, 2016) e Elsevier® (ELSEVIER, 2016). A base Scopus® é,

segundo SCOPUS (2016) e Elsevier (2016), a maior base de dados bibliográfica de resumos e citações da literatura *peer-reviewed* (*scientific journals, books and conference proceedings*).

Esta revisão foi iniciada pela definição das seguintes questões de pesquisa:

1. *Quais as características dos algoritmos utilizados para previsão de comportamento de ativos no mercado acionário?*
2. *Quais os algoritmos de inteligência computacional mais utilizados para previsão de comportamento de ativos no mercado acionário?*

Com base no objetivo e questões de pesquisa, as seguintes palavras-chave, e seus sinônimos, foram definidos:

- *stock market: stock exchange, stock, stocks;*
- *trend: trends, trending, direction, momentum;*
- *forecast: forecasting, detect, detection, predict, prediction, predictive, follow, following.*

A partir das palavras-chave definidas anteriormente, a seguinte busca foi efetuada na base Scopus®: (*Topic = "stock market" OR Topic = "stock exchange" OR Topic = stock OR Topic = stocks*) AND (*Topic = trend OR Topic = trends OR Topic = trending OR Topic = direction OR Topic = momentum*) AND (*Topic = forecast OR Topic = forecasting OR Topic = detect OR Topic = detection OR Topic = predict OR Topic = prediction OR Topic = predictive OR Topic = follow OR Topic = following*). A busca foi restringida aos campos *title, abstract* e *keywords* de artigos (*articles*) e publicações em conferências (*conference papers*). Foram consideradas publicações apenas na língua inglesa, por acreditar ser o idioma mais utilizado em publicações relevantes indexadas em bases de dados bibliográficas eletrônicas.

No intuito de retornar as pesquisas mais recentes na área de pesquisa, o período considerado foi para publicações de 2012 (inclusive) até a data da busca, efetuada em 12/08/2016. Um fator relevante para a busca de trabalhos recentes deve-se à característica adaptativa do mercado acionário, capaz de inviabilizar, após publicados, padrões de comportamento lucrativos. Característica observada por Malkiel (2003).

Para responder às questões de pesquisa propostas, os seguintes tópicos foram definidos para extração por meio da leitura completa de cada publicação:

1. meio de publicação: podendo ser revista (*Journal*), ou Conferência (*Conference*);

2. ano em que o trabalho foi publicado;
3. tipo de algoritmo utilizado para previsão ou detecção da tendência;
4. algoritmo para pré-processamento: caso tenha utilizado algum algoritmo ou método em especial para pré-processamento dos dados;
5. tipos de dados utilizados como entrada para o algoritmo de previsão ou detecção de tendência. Os dados podem ser dos tipos:
  - Análise Fundamentalista (AF): como por exemplo: fluxo de caixa, patrimônio líquido, etc;
  - Análise Técnica (AT): como por exemplo: indicadores técnicos e gráficos;
  - Análise de Sentimentos (AS): extração de significados sentimentais a partir, principalmente, de dados coletados em textos publicados na *internet*, como micro-blogs (*Twitter, Sina Weibo*, etc.), notícias, ou até alguma interpretação subjetiva sobre algum indicador técnico;
  - Macro: dados de movimentação de outros mercados (indicadores macroeconômicos), como por exemplo: cotação do ouro, cotação da prata, variação do dólar, cotação do barril de petróleo, outros índices acionários, etc.
6. horizonte de previsão: intradiário, diário, semanal, mensal, trimestral ou anual;
7. tipo de estratégia: HFT ou LFT;
8. tipo de ativo utilizado nas simulações: Ação, Índice, Contrato Futuro, ETF (*Exchange Traded Funds*), *Commodity*, ou FOREX (*Foreign Exchange*);
9. país ou países de origem dos dados de entrada utilizados pelo algoritmo;
10. período de treinamento;
11. período de teste fora da amostra;
12. medidas de desempenho;
13. quanto à contabilização de custos operacionais: caso tenham sido efetuadas simulações de operação do algoritmo (*backtesting*), se foram considerados custos financeiros operacionais;

14. quanto à consideração de *bid-ask spread*: caso tenha efetuado algum *backtesting*, se o fator *bid-ask spread* foi considerado;
15. quanto à Hipótese do Mercado Eficiente (HME): caso a HME tenha sido considerada pelos autores, se afirmam tê-la superado.

#### A.4 Desenvolvimento

Com a submissão da busca à ferramenta de pesquisa avançada (*Advanced search*) da base Scopus®, 702 publicações foram retornadas. Os metadados ("autores", "ano", "tipo de documento", "título", "resumo" e "palavras-chave"), de todos os registros foram exportados em formato *RIS (Research Information Systems)*, e posteriormente importados ao *software* de gerenciamento de referências Mendeley®.

No processo de seleção preliminar, a primeira tarefa desempenhada foi a busca por duplicatas, o Mendeley® conseguiu identificar 4 destes casos. Após leitura e comparação do "título", "autores" e "resumo" das 8 publicações listadas como duplicatas, 4 delas foram removidas. O próximo passo da seleção preliminar foi a análise do título dos 698 registros restantes, neste processo foi possível eliminar 155 publicações, pois claramente não tinham relação com o objetivo e questões de pesquisa definidos.

O próximo passo foi a execução do processo de seleção final, com a leitura do "resumo" de todos os 543 trabalhos restantes. Os artigos sem relação com o objetivo e questões de pesquisa foram eliminados. Em caso de dúvida quanto à exclusão do artigo, o mesmo foi mantido. Nesta etapa, 305 publicações foram eliminadas. Desta maneira, 238 trabalhos foram mantidos para leitura completa.

Um dos critérios de exclusão considerado foi quanto à impossibilidade de acesso sem custo financeiro ao documento completo. Não foi possível acessar 64 trabalhos, pois o meio de publicação só disponibilizaria tais documentos mediante pagamento financeiro, estes trabalhos foram desconsiderados. Desta maneira, foi possível ter acesso completo à 174 publicações.

No processo de leitura completa foram identificados mais 2 casos de duplicatas, resultando em 3 referências eliminadas. Em um dos casos foi mantido o trabalho de Chen e Chen (2015b), sendo desconsiderados outros dois (CHEN et al., 2013; CHEN; CHEN, 2015a). Já em outra situação, foi mantido o trabalho de Wu, Wu e Lee (2014), e desconsiderado Wu, Wu e Lee (2012). A ferramenta para detecção de duplicatas do Mendeley® não conseguiu rastrear tais casos pois o título e resumo possuem diferenças significativas, porém na leitura completa



foi possível perceber que os dados e resultados eram equivalentes. Quanto ao tratamento de duplicatas por meio da leitura completa, o primeiro critério de avaliação foi quanto ao meio de publicação, com favorecimento às publicações em *Journals*. E o segundo critério foi relativo ao ano de publicação, com manutenção dos trabalhos mais recentes.

Das 171 publicações lidas na íntegra, 26 foram desconsideradas, pois não abordavam diretamente aspectos relativos ao objetivo e questões de pesquisa definidos. Desta maneira, 145 trabalhos foram utilizados para coleta de dados.

## A.5 Resultados e Discussão


No intuito de responder às questões de pesquisa desta revisão, a seguir são apresentados e discutidos os resultados alcançados com a leitura e coleta de dados dos 145 trabalhos considerados. Os Quadros A.1, A.2, A.3, A.4 e A.5, da Seção A.6, apresentam respectivamente os trabalhos publicados em 2012, 2013, 2014, 2015 e 2016. Devido a quantidade de informações, os quadros apresentam somente parte dos dados coletados. Os seguintes tópicos são apresentados pelos quadros: (i) meio de publicação ("Meio"); (ii) tipo de algoritmo utilizado ("Algoritmo"); (iii) tipos de dados utilizados como entrada para o algoritmo ("Dados"); (iv) tipo de ativo utilizado ("Tipo\_Ativo"); e (v) país de origem dos dados ("País").

A Figura 1 exibe um gráfico com a quantidade de trabalhos por tipo de algoritmo. A soma é superior ao total de trabalhos analisados pois uma mesma publicação pode fazer uso de mais de um tipo de algoritmo. Como é o caso de Patel et al. (2015), que utilizam ANN, SVM, RF e BC.

A seguir, é feita a descrição das siglas dos algoritmos exibidos pela Figura 1, e também listados na coluna "Algoritmo" dos quadros da Seção A.6:

- *Artificial Neural Network* (ANN). Tipo de algoritmo utilizado nos seguintes trabalhos: (ABHISHEK et al., 2012; AHMED; SRIRAM; SINGH, 2014; Alexandre MacEdo et al., 2013; ARIAS; ARRATIA; XURIGUERA, 2013; AZIMIFAR; ARAABI; MORADI, 2015; BEKIROS, 2013; BHAT; KAMATH, 2013; BISOI; DASH, 2014; De Oliveira; NOBRE; ZÁRATE, 2013; HUANG; CHEN; PAN, 2012; MA et al., 2013), dentre outros;
- *Support Vector Machine* (SVM). Utilizado nos seguintes trabalhos: (ARIAS; ARRATIA; XURIGUERA, 2013; CHANG; WU, 2015; CHEN; CHEN, 2013; DUONG; NGUYEN; DANG, 2016; GONZALEZ; PADILHA; BARONE, 2015; HU et al., 2013; HUANG et

Figura 1 – Quantidade de publicações por tipo de algoritmo.



al., 2015; IACOMIN, 2016; IACOMIN, 2015; LI; QIU; ZHANG, 2013; LIN; GUO; HU, 2013; MEESAD; LI, 2014; NAYAK; MISHRA; RATH, 2015; PATEL et al., 2015), dentre outros. Nesta categoria inclui-se também a variante *Support Vector Regression* (SVR) (SMOLA et al., 1996), empregada pelos seguintes trabalhos: (AZIMIFAR; ARAABI; MORADI, 2015; LI et al., 2014; LIU et al., 2015; MEESAD; RASEL, 2013; NIE; JIN, 2016; PANIGRAHI; MANTRI, 2015a; QU; ZHANG, 2016; WANG et al., 2013; WU; CHANG, 2012; WU; YU; CHANG, 2014), dentre outros;

- *Evolutionary Algorithm* (EA) (FOGEL, 1995). Consiste em uma classe de algoritmos bioinspirados, como os Algoritmos Genéticos (AG), utilizados pelos seguintes trabalhos: (Bodas Sagi et al., 2012; BODAS-SAGI et al., 2013; CHEN; CHEN, 2013; Do Nascimento et al., 2015; GÖÇKEN et al., 2016; GONZALEZ; PADILHA; BARONE, 2015; ISHII; TAKEYASU, 2014; LUO; SI; FONG, 2012; MACHADO; NEVES; HORTA, 2015; SAHIN; OZBAYOGLU, 2014; SU; HADZIKADIC, 2015; WEI, 2013; YANG; WU; LIN, 2012). E o algoritmo *eXtended Classifier Systems* (XCS), utilizado por Hu et al. (2015);
- *Regression* (R). Trabalhos que utilizam algum tipo de regressão, como por exemplo: Regressão Linear (ARIAS; ARRATIA; XURIGUERA, 2013; BIJL et al., 2016; SIEW; NORDIN, 2012; SON; NOH; LEE, 2012); Regressão Logística (ATTIGERI et al., 2016; CHEVAPATRAKUL, 2013; SON; NOH; LEE, 2012; XU; LAN; JIANG, 2016); *Autoregressive Integrated Moving Average* (ARIMA) (De La Fuente-Mella et al., 2016;

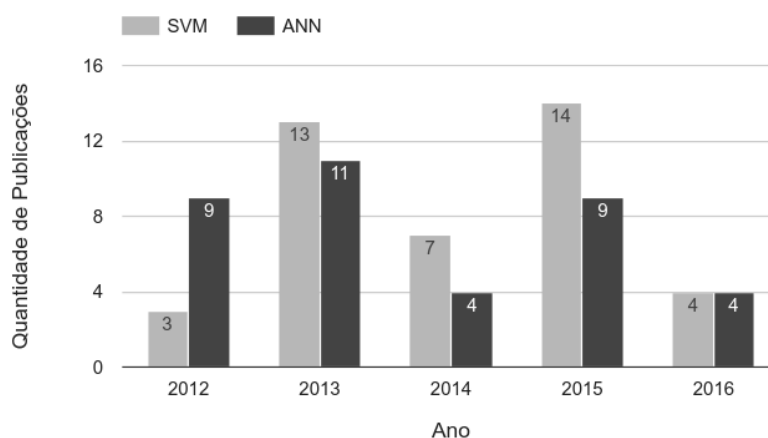
- WICHAIDIT; KITTITORNKUN, 2015); *Autoregressive Conditional Heteroskedasticity* (ARCH) (De La Fuente-Mella et al., 2016); *Generalized ARCH* (GARCH) (De La Fuente-Mella et al., 2016); *Autoregressive Moving Average* (ARMA) (ISHII; TAKEYASU, 2014); *Ridge Regression*(KAMP; BOLEY; GÄRTNER, 2014); e *Stepwise Regression* (LIU et al., 2012);
- *Swarm Intelligence* (*Swarm*) (BONABEAU; DORIGO; THERAULAZ, 1999). São também uma classe de algoritmos bioinspirados, mas com foco na inteligência de enxames, como por exemplo: *Particle Swarm Optimization* (PSO) (CHIANG et al., 2016; DENG et al., 2016; FENG; CHOU, 2012; PRASANNA; MARAN, 2015; SANDS et al., 2015); *Ant Colony Optimization* (ACO) (BOUKTIF; AWAD, 2015); *Artificial Bee Colony* (ABC) (BRASILEIRO et al., 2013); *Artificial Fish Swarm Algorithm* (AFSA) (HUANG; CHEN; PAN, 2012); *Bat Algorithm* e *Firefly Algorithm*, ambas empregadas por Prasanna e Maran (2015);
  - *Lógica Fuzzy* (*Fuzzy*) (ZADEH, 1965). Utilizada pelos seguintes trabalhos: (AGUIAR, 2012; CHEN; CHEN, 2015b; DENG et al., 2016; FENG; CHOU, 2012; FONG; SI; TAI, 2012; FONG; TAI; PICHAPPAN, 2012; SADAIEI et al., 2016; SADHU et al., 2014; SHAKERI et al., 2015);
  - *Neuro-Fuzzy*. Conceito introduzido por Jang (1993), trata-se de um modelo híbrido que busca reunir a capacidade de mapeamento não linear de ANNs, com a representação de conhecimento impreciso da lógica *fuzzy*. Os seguintes algoritmos pertencem a esta classe: *Adaptive Network-Based Fuzzy Inference System* (ANFIS) (ATSALAKIS; PROTOPAPADAKIS; VALAVANIS, 2016; CHEN et al., 2013; WEI, 2013; WEI; CHENG; WU, 2014); *Self-Organizing Fuzzy Neural Network* (SOFNN) (AHUJA et al., 2015); e *Recurrent Error Based Neuro-Fuzzy System With Momentum* (RENFSM) (MAHMUD; MEESAD, 2014);
  - *Naive Bayes Classifier* (BC) (MURPHY, 2006). Este tipo de classificador é utilizado pelos seguintes trabalhos como parte do modelo proposto: (BOUKTIF; AWAD, 2015; GUNDUZ; CATALTEPE, 2015; RAO; SRIVASTAVA, 2013). E por Chen e Chen (2013), Nie e Jin (2016), Paliyawan (2015), e Patel et al. (2015), na comparação de desempenho com outros algoritmos;

- *k-Nearest Neighbor* (k-NN) (HAN; PEI; KAMBER, 2011). É um método de classificação e regressão, sendo utilizado como parte do modelo proposto nos trabalhos de Brasileiro et al. (2013), Lahmiri, Boukadoum e Chartier (2013) e Subha e Nambi (2012). E por Nayak, Mishra e Rath (2015) e Paliyawan (2015), na comparação com outros algoritmos;
- *Decision-Tree* (DT) (QUINLAN, 1987; HAN; PEI; KAMBER, 2011). Tipo de algoritmo utilizado por Panigrahi e Mantri (2015b) na tarefa de classificação. Já no trabalho de Wang, Liu e Wang (2013), árvores de decisão (*Decision-Tree*) são utilizadas na remoção de ruídos, para posterior classificação com SVM. Nos trabalhos de Paliyawan (2015) e Panigrahi e Mantri (2015a), árvores de decisão tiveram o seu desempenho comparados com ANN e SVM respectivamente, os resultados mostram desempenhos similares nas comparações;
- *Data-Mining* (DM) (HAN; PEI; KAMBER, 2011). Alguns dos trabalhos utilizam técnicas de mineração de dados (*Data-Mining*). Por exemplo, Widiputra e Pahlevi (2012) utilizam a técnica *Association Rule-Mining Algorithm*. Já nos trabalhos de Wu, Wu e Lee (2014), Xue et al. (2015) e Zhao e Wang (2015), é utilizado o algoritmo de agrupamento *k-means*;
- *Random-Forest* (RF). Algoritmo de aprendizagem do tipo *Ensemble Learning* — termo referente à utilização de um conjunto de algoritmos de aprendizagem para obtenção de um resultado superior àquela alcançada com apenas um algoritmo (ROKACH, 2010). RFs são utilizadas por Manojlović e Štajduhar (2015) e Patel et al. (2015). Na comparação com SVM, ANN e *Naive Bayes* feita por Patel et al. (2015), RF consegue melhor desempenho. Já no trabalho de Xu, Li e Luo (2013), SVM alcança melhores resultados que RF;
- *Hypergraph* (SCHÖLKOPF; PLATT; HOFMANN, 2007). Este tipo de algoritmo é utilizado por Shen et al. (2012) e Luo et al. (2014);
- *Multiple-Kernel-Learning* (MKL) (GÖNEN; ALPAYDIN, 2011). Tipo de algoritmo que combina vários tipos de *kernels* para solução de um problema de otimização. Este tipo de algoritmo é utilizado por Sirohi, Mahato e Attar (2014) e Shynkevich et al. (2015);
- Outros. Além dos tipos de algoritmos listados anteriormente, 13 outros trabalhos utilizam tipos únicos de algoritmos ou estratégias, listados a seguir: *Directional Change Trading*

(DCT) (ALLOUD, 2016); *Factorization Machine* (FM) (CHEN et al., 2014); *Template Matching* (TM) (CHEN; CHEN, 2016); *Mean variance analysis* (MVA) (CHEN; SZETO, 2012); *Dynamic Mode Decomposition* (DD) (CUI; LONG, 2016); indicadores técnicos (AT) (IMAN; KEMIN, 2015); *Tensor-based learning* (TBL) (LI et al., 2016); *Relevance Vector Machine* (RVM) (MARKOVIĆ; STOJANOVIĆ; BOŽIĆ, 2015); *Dictionary Learning* (DL) (ROSAS-ROMERO; DÍAZ-TORRES; ETCHEVERRY, 2016); *Bayesian Factor Graph* (BFG) (WANG et al., 2015); *Content-Based Image Retrieval* (CBIR) (TSAI; QUAN, 2014); *Hidden Markov Model* (HMM) (XING et al., 2013); e *System Adaptation Framework* (SAF) (ZHENG; CHEN, 2012).


No total, os 145 trabalhos avaliados utilizaram 27 tipos de algoritmos distintos. Dos 27 tipos de algoritmos, 41 (28,2%) correspondem a SVM, e 37 (25,5%), ANN, que somados são empregados por mais da metade dos trabalhos (53,8%). A Figura 2 exibe um gráfico com a quantidade anual utilizada dos algoritmos SVM e ANN pelos trabalhos publicados. Em 2012 ANN foi mais utilizado que SVM. Pode-se observar que a partir de 2013, SVMs tornaram-se mais populares. Em 2016 o uso de SVM e ANN mostra-se igualitária, com 4 trabalhos cada.

Figura 2 – Utilização anual dos algoritmos SVM e ANN.



A coluna "Dados" dos quadros do Apêndice A, diz respeito aos tipos de dados utilizados como entrada para os algoritmos. Dados provenientes da análise técnica são utilizados em 86,2% das publicações. Como pode ser observado pelo gráfico da Figura 3, 125, de um total de 145 publicações, utilizam AT. Análise de sentimentos é o segundo tipo mais utilizado, com 16,5%. Dados macroeconômicos e análise fundamentalista aparecem empatados com 9,6% de utilização.

Figura 3 – Quantidade total e percentual de publicações por tipo de dado.



Quanto ao horizonte de previsão, doze referências (ALOUND, 2016; De La Fuente-Mella et al., 2016; FONG; SI; TAI, 2012; FONG; TAI; PICHAPPAN, 2012; LI et al., 2016; LI et al., 2014; LOUWERSE; ROTHKRANTZ, 2014; SON; NOH; LEE, 2012; QU; ZHANG, 2016; WANG; LIU; WANG, 2013; XING et al., 2013; ZHAO; WANG, 2015), 8,3%, trabalham com dados intradiários, sendo que quatro destas (ALOUND, 2016; SON; NOH; LEE, 2012; QU; ZHANG, 2016; ZHAO; WANG, 2015), 2,7%, atuam com estratégias HFT. A maioria das publicações, 87,6%, atua com dados diários, semanais, trimestrais, mensais, ou anuais, sendo a grande maioria exclusivamente a nível diário. Alguns trabalhos atuam em mais de um horizonte, por exemplo: Bodas Sagi et al. (2012), Bodas-Sagi et al. (2013) e Nayak, Mishra e Rath (2015) utilizam dados a nível diário, semanal e mensal; Feng e Chou (2012) e Wei e Chaudhary (2015) atuam a nível diário e semanal; e Xing et al. (2013) trabalham com dados diários e intradiários. Seis publicações (CHEN; CHEN, 2016; CHEN; SZETO, 2012; CHEN; CHEN, 2013; LIU et al., 2012; WU; HE, 2014; XU; LAN; JIANG, 2016), 4,1%, não informam o horizonte de atuação do modelo proposto. Considerando que 2,7% das publicações tratam-se de propostas de algoritmos de HFT, o restante, 97,3%, são propostas LFT com atuação um passo à frente (*one-step-ahead*).

No total, 11 trabalhos (ATTIGERI et al., 2016; CHEN; CHEN, 2013; IUHASZ; TIREA; NEGRU, 2012; ROSAS-ROMERO; DÍAZ-TORRES; ETCHEVERRY, 2016; RYOTA; TOMOHARU, 2012; SADHU et al., 2014; SIROHI; MAHATO; ATTAR, 2014; TIREA; TANDA; NEGRU, 2012; XU; LAN; JIANG, 2016; YANG; ZHANG, 2015; ZHEN et al., 2013), 7,6%, não informam o período utilizado para treinamento, sendo que algumas destas referências (CHEN; CHEN, 2013; ROSAS-ROMERO; DÍAZ-TORRES; ETCHEVERRY, 2016; RYOTA;

TOMOHARU, 2012; SADHU et al., 2014; TIREA; TANDAU; NEGRU, 2012; YANG; ZHANG, 2015) também não informam detalhes sobre o período de teste fora da amostra, enquanto outras limitam-se a dizer apenas o percentual utilizado, por exemplo: Attigeri et al. (2016), Iuhasz, Tirea e Negru (2012) e Xu, Lan e Jiang (2016) informam utilizar 50%, 30% e 10% dos dados para teste, respectivamente. Já no trabalho de Zhen et al. (2013), embora não seja informado o período considerado, dizem utilizar *cross-validation* com 10 *folds* para treinamento e teste.

Outras 35 referências, 24%, não especificam o período de teste fora da amostra. Alguns dos trabalhos que se enquadram neste grupo são: (ABHISHEK et al., 2012; AGUIAR, 2012; AHMED; SRIRAM; SINGH, 2014; ALOUD, 2016; BIJL et al., 2016; Bodas Sagi et al., 2012; BODAS-SAGI et al., 2013; CAO; HU; CAO, 2015; CUI; LONG, 2016; ROSAS-ROMERO; DÍAZ-TORRES; ETCHEVERRY, 2016; WICHAIDIT; KITTITORNKUN, 2015; XING et al., 2013; ZHAO; WANG, 2015), dentre outros.

Quanto às estratégias utilizadas no teste do modelo com dados fora da amostra de treinamento, 11 trabalhos (BOUKTIF; AWAD, 2015; GONZALEZ; PADILHA; BARONE, 2015; HUANG; CHEN; PAN, 2012; LAHMIRI; BOUKADOUM; CHARTIER, 2013; MANOJLOVIĆ; ŠTAJDUHAR, 2015; MEESAD; LI, 2014; PALIYAWAN, 2015; PANIGRAHI; MANTRI, 2015b; PANIGRAHI; MANTRI, 2015a; SANDS et al., 2015; ZHEN et al., 2013), 7,6%, afirmam utilizar a técnica *cross-validation* com 10 *folds*. Já nos trabalhos de Chen et al. (2013), Chen e Chen (2015b), Deng et al. (2016), Sadaei et al. (2016), Wei (2013), Wei e Cheng (2012) e Wei, Cheng e Wu (2014), é feito o treinamento do modelo com os 10 primeiros meses de cada ano, testando com os últimos 2 meses.

A maior parcela dos trabalhos não seguem um padrão definido para divisão da base entre treinamento e teste. Muitas referências utilizam percentual, como nos casos de Bhat e Kamath (2013), Azimifar, Araabi e Moradi (2015) e Xu, Li e Luo (2013), que afirmam utilizar respectivamente 15%, 20% e 30% dos dados para o teste fora da amostra. Enquanto outras referências afirmam utilizar quantidade fixa de dados para o teste, como nos caso de Chen et al. (2014), Dabhi e Chaudhary (2016) e Hafezi, Shahrabi e Hadavandi (2015), que utilizam 100, 160 e 32 registros, respectivamente.

O problema relativo ao *Concept-Drift* (TSYMBAL, 2004; ZLIOBAITE, 2010) exige o emprego de estratégias e algoritmos adaptativos. E o treinamento com dados recentes contribui para a capacidade adaptativa do modelo. Ao todo, 15 trabalhos (AHUJA et al., 2015; BRASILEIRO et al., 2013; CHANG; WU, 2015; CHEN; CHEN, 2016; CHEVAPATRAKUL, 2013;

CHIANG et al., 2016; HU et al., 2013; HU et al., 2015; LIANG; NG, 2012; MACHADO; NEVES; HORTA, 2015; NIE; JIN, 2016; SIROHI; MAHATO; ATTAR, 2014; SON; NOH; LEE, 2012; XUE et al., 2015; ZBIKOWSKI, 2015), 10,3%, utilizam métodos de treino e teste condizentes com uma abordagem progressiva, embora utilizem denominações e configurações diferentes. Ahuja et al. (2015) utilizam uma técnica de treinamento e teste denominada *k-fold sequential cross validation* (k-SCV), onde um tamanho inicial é definido para a base de treinamento, sendo esta incrementada com os registros utilizados para o teste fora da amostra na etapa anterior. Nos trabalhos de Brasileiro et al. (2013) e Chang e Wu (2015) são utilizados blocos fechados contínuos divididos em treinamento, validação e teste, onde o bloco de teste utilizado no experimento  $k$ , passa a fazer parte da base de treinamento no experimento  $k + 1$ . Brasileiro et al. (2013) referenciam o método como *walk-forward*, enquanto Chang e Wu (2015) como *slide-window*. Já no trabalho publicado por Sirohi, Mahato e Attar (2014), é feita a progressão da janela de treinamento diariamente, a cada nova previsão, e o método é denominado *walk-forward*. Outros exemplos de configurações utilizadas em estratégias de treinamento e teste progressivos são: 7 anos para a base de treinamento, com teste no ano seguinte (CHEN; CHEN, 2016); 2 anos para a base de treinamento, com teste no ano seguinte (CHIANG et al., 2016); 4 anos para o treinamento, e teste com o ano seguinte (HU et al., 2013); 1 ano de treinamento, para 1 ano de teste (HU et al., 2015; LIANG; NG, 2012).

Apenas os trabalhos de Chevapatrakul (2013) e Sirohi, Mahato e Attar (2014), 1,38% do total, atualizam a base de treinamento a cada nova previsão, o que aparentemente mostra-se mais coerente do ponto de vista do problema de *Concept-Drift*.

Quanto às medidas de desempenho empregadas pelos trabalhos, as mais comuns utilizadas foram: ARR; ROI; HR; *Profit*; *Precision*; *F-measure*; *Mean Absolute Percentage Error* (MAPE); *Mean Square Error* (MSE); *Mean Absolute Error* (MAE); *Root Mean Square Error* (RMSE); e *Theil's U*.

A medida desempenho *Hit-Ratio* (HR) refere-se à taxa de acerto de direção alcançada pelo modelo, sendo muitas vezes utilizadas nomenclaturas distintas, a depender da referência, por exemplo: Gunduz e Cataltepe (2015), Manojlović e Štajduhar (2015) e Panigrahi e Mantri (2015b) utilizam o termo *Accuracy*; Já Paliyawan (2015) utiliza o termo *Direction Accuracy* (DAC).

A contabilização de custos transacionais é importante para avaliação de desempenho nas simulações de operação do modelo proposto. Das medidas de desempenho listadas anteri-



ormente, a contabilização de custos pode ser considerada para as medidas ARR, *Profit*, e ROI, onde são feitas simulações de operações financeiras no mercado. Apenas 16 (37,2%), das 43 referências que utilizam tais medidas de desempenho, afirmam considerar custos transacionais nas simulações de operação do modelo.

O *bid-ask spread* é outro fator que pode interferir nos resultados financeiros, e da mesma forma que os custos, é importante que seja considerado. Apenas os trabalhos de Aloud (2016), Bijl et al. (2016), Fong, Si e Tai (2012) e Fong, Tai e Pichappan (2012) consideram a existência de *bid-ask spread* nas simulações de negociação.

Apenas no trabalho de Bijl et al. (2016) (0,69% do total) é considerada a existência de custos transacionais e *bid-ask spread* simultaneamente.

Alguns trabalhos comentam sobre eficiência de mercado, bem como sua validade, como nas publicações de Fazli e Lebraty (2013), Brasileiro et al. (2013), Dunis et al. (2013), Chen et al. (2014), Iman e Kemin (2015), Attigeri et al. (2016) e Bijl et al. (2016). No entanto, apenas Bijl et al. (2016) fazem simulações de operação no mercado, levando-se em conta a existência de custos transacionais e *bid-ask spread* ao mesmo tempo, não conseguindo superar uma estratégia *Buy-and-Hold* simples.

### A.5.1 Questões Metodológicas

Foi observado que diversos trabalhos apresentam metodologias incompletas ou falhas, situação que pode comprometer a veracidade de informações apresentadas. Por exemplo, os trabalhos de Aguiar (2012), Hafezi, Shahrabi e Hadavandi (2015) e Deng et al. (2016) não especificam de forma clara quais foram os dados utilizados como entrada para o algoritmo.

Como já mencionado, vários trabalhos não informam o período utilizado para treinamento e ou teste dos algoritmos propostos, impossibilitando a reprodução dos experimentos.

Os trabalhos de Hu et al. (2013), Lin, Guo e Hu (2013), Louwerse e Rothkrantz (2014), Rosillo, Giner e De La Fuente (2014), Iman e Kemin (2015), Xue et al. (2015), Zbikowski (2015) e Chen e Chen (2016), comparam o desempenho com uma estratégia B&H simples, dizem superá-la, mas não consideram a existência de custos transacionais, nem *bid-ask spread*.

Ainda quanto à contabilização de custos transacionais, não é observado um padrão definido. A maioria dos trabalhos aplica a taxa de 0,1% por operação (WANG; YU; CHEUNG, 2012; CHEVAPATRAKUL, 2013; WANG; YU; CHEUNG, 2014b; WANG; YU; CHEUNG, 2014a; MACHADO; NEVES; HORTA, 2015; CUI; LONG, 2016), já nos trabalhos de Bekiros

(2013), Bijl et al. (2016), Bodas Sagi et al. (2012) e Chen e Szeto (2012) são contabilizadas as taxas de 0,05%, 0,02%, 0,5% e 1,0% respectivamente. Hu et al. (2015) contabilizam 0,1% para operações de compra, e 0,2% para operações de venda. Os trabalhos de Wu e Chang (2012) e Wu, Yu e Chang (2014) não informam como os custos foram calculados. E os trabalhos de Brasileiro et al. (2013), Chiang et al. (2016) e Su e Hadzikadic (2015) consideram a existência de custos fixos, nos valores de R\$5,00, \$9,99 e \$10,00 respectivamente, valores que podem não condizer com a realidade. Considerando o caso do trabalho aplicado ao mercado brasileiro (BRASILEIRO et al., 2013), a BM&FBovespa cobrava em janeiro de 2017, por operação, 0,0325% de emolumentos e liquidação, e o custo de corretagem dificilmente ficaria abaixo dos R\$14,90. Como já pontuado, apenas 38,0% das publicações que simularam operações financeiras no mercado consideraram de alguma forma a existência de custos transacionais.

Alguns trabalhos (HONG; ZHANG, 2012; CHEN et al., 2013; AHMED; SRIRAM; SINGH, 2014; CHANDAR; SUMATHI; SIVANADAM, 2016), embora tenham utilizado algoritmos não determinísticos, não especificaram a quantidade de repetições efetuadas nos experimentos.

Quanto aos trabalhos que utilizaram informações coletadas em *sites* de notícias e ou microblogs, é necessário atentar-se ao horário de divulgação da informação. A utilização de informações veiculadas após o fechamento do mercado pode comprometer a utilidade dos resultados obtidos, pois muitas vezes não é possível tirar proveito da movimentação prevista, pois o valor de abertura do ativo será precificado em reação ao impacto da notícia. Alguns trabalhos (MARTIN, 2013; CHEN et al., 2014; GUNDUZ; CATALTEPE, 2015; MEESAD; LI, 2014; SHYNKEVICH et al., 2015; WEI; ZHANG; ZHOU, 2015; DUONG; NGUYEN; DANG, 2016) utilizaram técnicas de análise de sentimentos, minerados de dados de microblogs ou notícias de maneira geral, mas não é informado se consideraram apenas informações postadas até o horário de fechamento do mercado no dia anterior à previsão.

## A.6 Relação de Trabalhos Publicados

Quadro A.1 – Trabalhos publicados em 2012.

Meio	Algoritmo	Dados	País	Tipo_Ativo	Referência
Journal	ANN	AT	Taiwan	Ação	(CHANG; WANG; ZHOU, 2012)
Journal	ANN	AT	Taiwan	Índice	(WEI; CHENG, 2012)
Journal	ANN, Swarm	AT	Taiwan	Ação	(HUANG; CHEN; PAN, 2012)
Journal	Fuzzy	AT	China	Índice	(FONG; SI; TAI, 2012)
Journal	Fuzzy	AT	China	Índice e Ação	(FONG; TAI; PICHAPPAN, 2012)
Journal	Fuzzy, Swarm	AT	Taiwan	Índice	(FENG; CHOU, 2012)
Journal	k-NN	AT	Índia	Índice	(SUBHA; NAMBI, 2012)
Journal	MVA	AT	China	Ação	(CHEN; SZETO, 2012)
Journal	R	AT, Macro	Arábia Saudita	Índice	(ALRASHEEDI, 2012)
Journal	SAF	AT, AS	EUA, China, Singapura	Índice	(ZHENG; CHEN, 2012)
Journal	SVM	AT	EUA	Índice e Ação	(WU; CHANG, 2012)
Journal	SVM, ANN, R	AT, Macro	Coreia do Sul	Índice	(SON; NOH; LEE, 2012)
Conference	EA	AT	EUA	Índice	(Bodas Sagi et al., 2012)
Conference	EA	AT	China	Índice	(LUO; SI; FONG, 2012)
Conference	EA	AT	EUA	Índice e Ação	(RYOTA; TOMOHARU, 2012)
Conference	ANN	AT	EUA	Ação	(ABHISHEK et al., 2012)
Conference	ANN	AT	China	Índice	(HONG; ZHANG, 2012)
Conference	ANN	AT	China	Ação	(LIANG; NG, 2012)
Conference	ANN	AT, AF	Romênia	Índice	(IUHASZ; TIREA; NEGRU, 2012)
Conference	ANN	AT, AF, AS	Romênia	Ação	(TIREA; TANDAU; NEGRU, 2012)
Conference	DM	AT	Indonésia	-	(WIDIPUTRA; PAHLEVI, 2012)
Conference	Fuzzy	AF	EUA	Índice	(AGUIAR, 2012)
Conference	Hypergraph	AT	China	Ação	(SHEN et al., 2012)
Conference	Neuro-Fuzzy, EA	AT	China	Ação	(YANG; WU; LIN, 2012)
Conference	R	AF	Malásia	Ação	(SIEW; NORDIN, 2012)
Conference	R	AS	China	Índice	(LIU et al., 2012)
Conference	SVM	AT	China	Índice	(YANG; DAI, 2012)
Conference	Swarm	AT	EUA	Índice e Ação	(WANG; YU; CHEUNG, 2012)

Quadro A.2 – Trabalhos publicados em 2013.

Meio	Algoritmo	Dados	País	Tipo_Ativo	Referência
Journal	EA	AT	EUA	Índice	(BODAS-SAGI et al., 2013)
Journal	ANN	AT	EUA	Índice	(BEKIROS, 2013)
Journal	ANN	AT	China	Ação	(MA et al., 2013)
Journal	ANN	AT	EUA	Ação	(TICKNOR, 2013)
Journal	ANN	AT, Macro	Brasil	Ação	(De Oliveira; NOBRE; ZÁRATE, 2013)
Journal	ANN, R	AT	Brasil, EUA	Ação	(Alexandre MacEdo et al., 2013)
Journal	Neuro-Fuzzy	Macro	Taiwan	Índice	(CHEN et al., 2013)
Journal	Neuro-Fuzzy, EA	AT	Taiwan	Índice	(WEI, 2013)
Journal	R	AT	Reino Unido	Índice	(CHEVAPATRAKUL, 2013)
Journal	SVM	AT	Espanha	Índice	(DUNIS et al., 2013)
Journal	SVM	AT	China	Ação	(LI; QIU; ZHANG, 2013)
Journal	SVM, ANN, R	AT, AS	EUA	Ação	(ARIAS; ARRATIA; XURIGUERA, 2013)
Conference	ANN	AT	Índia	Índice	(BHAT; KAMATH, 2013)
Conference	ANN	AT	Índia	Índice	(DEVI; SUNDAR; ALLI, 2013)
Conference	ANN	AT	China	Índice	(WU; YONG, 2013)
Conference	ANN	AT, AF, AS	Romênia	Ação	(TIREA; NEGRU, 2013)
Conference	ANN	AT, AS	França	Índice	(MARTIN, 2013)
Conference	BC	AS	EUA	Índice	(RAO; SRIVASTAVA, 2013)
Conference	HMM	AT	China	-	(XING et al., 2013)
Conference	k-NN	AT, Macro, AS	EUA	Índice	(LAHMIRI; BOUKADOUM; CHARTIER, 2013)
Conference	Neuro-Fuzzy	AT, AF	Malásia	Ação	(FAZLI; LEBRATY, 2013)
Conference	SVM	AF	China	Índice	(HU et al., 2013)
Conference	SVM	AF, Macro	EUA	Ação	(HU; ZHU; TSE, 2013)
Conference	SVM	AS	China	Ação	(WANG et al., 2013)
Conference	SVM	AT	Taiwan	Ação	(LIN; GUO; HU, 2013)
Conference	SVM	AT	Bangladesh	Ação	(MEESAD; RASEL, 2013)
Conference	SVM	AT	EUA	Índice	(XIA; LIU; CHEN, 2013)
Conference	SVM, EA, BC	AF	Taiwan	-	(CHEN; CHEN, 2013)
Conference	SVM, RF	AT	China	Ação	(XU; LI; LUO, 2013)
Conference	SVM,DT	AT	China	Contrato Futuro	(WANG; LIU; WANG, 2013)
Conference	SVM,Swarm	AT	Malásia	Índice	(ZHEN et al., 2013)
Conference	Swarm, k-NN	AT	Brasil	Ação	(BRASILEIRO et al., 2013)

Quadro A.3 – Trabalhos publicados em 2014.

Meio	Algoritmo	Dados	País	Tipo_Ativo	Referência
Journal	ANN	AT	Índia	Índice e Ação	(BISOI; DASH, 2014)
Journal	CBIR	AT	EUA	Índice	(TSAI; QUAN, 2014)
Journal	DM	AT	Taiwan	Índice	(WU; WU; LEE, 2014)
Journal	Neuro-Fuzzy	AT	Taiwan	Índice	(WEI; CHENG; WU, 2014)
Journal	SVM	AS	China	Ação	(LI et al., 2014)
Journal	SVM	AT	EUA	Índice	(ROSILLO; GINER; De La Fuente, 2014)
Journal	SVM	AT, AS	Taiwan	Ação	(WU; YU; CHANG, 2014)
Journal	Swarm	AT	EUA	Ação	(WANG; YU; CHEUNG, 2014a)
Conference	EA	AT	EUA	ETF	(SAHIN; OZBAYOGLU, 2014)
Conference	EA, R	AT	Japão	Ação	(ISHII; TAKEYASU, 2014)
Conference	ANN	AT	Alemanha	Ação	(LOUWERSE; ROTHKRANTZ, 2014)
Conference	ANN	AT	China	Índice	(WU; HE, 2014)
Conference	ANN	AT, AS	EUA	Ação	(AHMED; SRIRAM; SINGH, 2014)
Conference	FM	AS	China	Índice	(CHEN et al., 2014)
Conference	Fuzzy	AT	Índia	-	(SADHU et al., 2014)
Conference	Hypergraph	AT	China	Ação	(LUO et al., 2014)
Conference	MKL	AT	Índia	-	(SIROHI; MAHATO; ATTAR, 2014)
Conference	Neuro-Fuzzy	AT	Bangladesh	Ação	(MAHMUD; MEESAD, 2014)
Conference	R	AF	EUA	Ação	(KAMP; BOLEY; GÄRTNER, 2014)
Conference	SVM	AS	EUA	Índice	(MEESAD; LI, 2014)
Conference	SVM	AT	EUA	Ação	(SHYNKEVICH et al., 2014)
Conference	SVM	AT	China	Índice	(WANG; SHANG, 2014)
Conference	SVM	AT	China	Índice	(WEN et al., 2014)
Conference	Swarm	AT	EUA	Ação	(WANG; YU; CHEUNG, 2014b)

Quadro A.4 – Trabalhos publicados em 2015.

Meio	Algoritmo	Dados	País	Tipo_Ativo	Referência
Journal	EA	AT	China	Índice	(HU et al., 2015)
Journal	ANN	AT, AF, Macro	Alemanha	Índice	(HAFEZI; SHAHRABI; HADAVANDI, 2015)
Journal	ANN, SVM, RF, BC	AT	Índia	Índice	(PATEL et al., 2015)
Journal	ANN,DT,BC,k-NN	AT	Tailândia	Índice	(PALIYAWAN, 2015)
Journal	BC	AT, AS	Turquia	Índice	(GUNDUZ; CATALTEPE, 2015)
Journal	BFG	Macro	EUA, China	Índice	(WANG et al., 2015)
Journal	DM	AT	EUA, Canadá, China	Índice e Ação	(XUE et al., 2015)
Journal	Fuzzy	Macro	Taiwan	Índice	(CHEN; CHEN, 2015b)
Journal	SVM	AS	China	Índice	(LIU et al., 2015)
Journal	SVM	AT	EUA	Ação	(ZBIKOWSKI, 2015)
Journal	SVM	AT, Macro	China	Índice	(CHAI et al., 2015)
Journal	SVM, k-NN	AT	Índia	Índice	(NAYAK; MISHRA; RATH, 2015)
Conference	EA	AT	Brasil	-	(Do Nascimento et al., 2015)
Conference	EA	AT	EUA	Índice	(MACHADO; NEVES; HORTA, 2015)
Conference	EA	AT	EUA	Ação	(SU; HADZIKADIC, 2015)
Conference	ANN	AT	EUA, Brasil, Rússia, Índia, China	Índice	(CAO; HU; CAO, 2015)
Conference	ANN	AT	EUA, China	Índice	(DASH; DASH, 2015)
Conference	ANN	AT	EUA	Ação	(WEI; CHAUDHARY, 2015)
Conference	ANN	AT	China	Ação	(YANG; ZHANG, 2015)
Conference	ANN	AT	EUA, Reino Unido	Índice	(ZHANG; PAN, 2015)
Conference	ANN, SVM	AT	Teerã	Ação	(AZIMIFAR; ARAABI; MORADI, 2015)
Conference	AT	AT, Macro	EUA	Índice	(IMAN; KEMIN, 2015)
Conference	DM	AT	China	Ação	(ZHAO; WANG, 2015)
Conference	DT	AT	Índia	Índice	(PANIGRAHI; MANTRI, 2015b)
Conference	Fuzzy	AT	EUA	Ação	(SHAKERI et al., 2015)
Conference	MKL	AS	EUA	Ação	(SHYNKEVICH et al., 2015)
Conference	Neuro-Fuzzy	AS	Índia	-	(AHUJA et al., 2015)
Conference	R	AT	Tailândia	Ação	(WICHADIT; KITTITORNKUN, 2015)
Conference	RF	AT	Croácia	Ações	(MANOJLOVIĆ; ŠTAJDUHAR, 2015)
Conference	RVM	AT	Servia	Índice	(MARKOVIĆ; STOJANOVIĆ; BOŽIĆ, 2015)
Conference	SVM	AT	EUA	Ação	(CHANG; WU, 2015)
Conference	SVM	AT	EUA	Índice	(HUANG et al., 2015)
Conference	SVM	AT	EUA	Ação	(IACOMIN, 2015)
Conference	SVM	AT, AS	China	Índice	(WEI; ZHANG; ZHOU, 2015)
Conference	SVM, EA	AT, Macro	Brasil	Índice	(GONZALEZ; PADILHA; BARONE, 2015)
Conference	SVM, DT	AT	Índia	Índice	(PANIGRAHI; MANTRI, 2015a)
Conference	SVM, Swarm	AT	EUA	Ação	(SANDS et al., 2015)
Conference	SVM, Swarm	AT	China	Índice	(YIN et al., 2015)
Conference	Swarm	AT	Índia	Índice	(PRASANNA; MARAN, 2015)
Conference	Swarm, BC	AS	EUA	Ação	(BOUKTIF; AWAD, 2015)

Quadro A.5 – Trabalhos publicados em 2016.

Meio	Algoritmo	Dados	País	Tipo_Ativo	Referência
Journal	EA	AT	EUA	Ação	(DABHI; CHAUDHARY, 2016)
Journal	ANN	AT	Índia	Ação	(CHANDAR; SUMATHI; SIVANANDAM, 2016)
Journal	ANN	AT, Macro	Índia	Commodity	(CHANDAR; SUMATHI; SIVANADAM, 2016)
Journal	ANN, EA	AT	Turquia	Índice	(GÖÇKEN et al., 2016)
Journal	ANN, Swarm	AT	EUA	Índice	(CHIANG et al., 2016)
Journal	DCT	AT	Arábia Saudita	Índice	(ALLOUD, 2016)
Journal	DD	AT	China	Ação	(CUI; LONG, 2016)
Journal	DL	AT	EUA	Ação	(ROSAS-ROMERO; DÍAZ-TORRES; ETCHEVERRY, 2016)
Journal	Fuzzy, EA	AT	EUA, TAIWAN	Índice	(SADAEI et al., 2016)
Journal	Fuzzy, Swarm	AT	Taiwan	Índice	(DENG et al., 2016)
Journal	Neuro-Fuzzy	AT	EUA	Ação	(ATSALAKIS; PROTOPAPADAKIS; VALAVANIS, 2016)
Journal	R	AT, AS	EUA	Ação	(BIJL et al., 2016)
Journal	SVM	AT	China	Índice	(QU; ZHANG, 2016)
Journal	SVM, BC	AT	EUA	Ação	(NIE; JIN, 2016)
Journal	TBL	AT, AF, AS	China	Ação	(LI et al., 2016)
Journal	TM	AT	Taiwan	Índice	(CHEN; CHEN, 2016)
Conference	R	AF, Macro	China	Ação	(XU; LAN; JIANG, 2016)
Conference	R	AT	Chile	Ação	(De La Fuente-Mella et al., 2016)
Conference	R	AT, AF, AS	-	-	(ATTIGERI et al., 2016)
Conference	SVM	AT	EUA, Inglaterra, Japão	Ação e FOREX	(IACOMIN, 2016)
Conference	SVM	AT, AS	Vietnã	Índice	(DUONG; NGUYEN; DANG, 2016)