CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL

ESTRATÉGIAS DE OPERAÇÃO AUTOMATIZADA EM MERCADO FINANCEIRO BASEADA EM PREVISÕES DE REDES NEURAIS ARTIFICIAIS

RODRIGO COUTO E SILVA

Orientador: Adriano César Machado Pereira
Centro Federal de Educação Tecnológica de Minas Gerais

BELO HORIZONTE
JANEIRO DE 2018

RODRIGO COUTO E SILVA

ESTRATÉGIAS DE OPERAÇÃO AUTOMATIZADA EM MERCADO FINANCEIRO BASEADA EM PREVISÕES DE REDES NEURAIS ARTIFICIAIS

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Matemática e Computacional do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para a obtenção do título de Mestre em Modelagem Matemática e Computacional.

Área de concentração: Modelagem Matemática e Computacional

Linha de pesquisa: Métodos Matemáticos Aplicados

Orientador: Adriano César Machado Pereira
Centro Federal de Educação Tecnológica de Minas Gerais

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA E COMPUTACIONAL
BELO HORIZONTE
JANEIRO DE 2018

Esta folha deverá ser substituída pela cópia digitalizada da folha de aprovação fornecida.

Dedico este trabalho à Ana Clara, minha filha querida, para lembrá-la que em sua liberdade haverá a opção do caminho do conhecimento.

Agradecimentos

À Cíntia, esposa e mãe dedicada, e à minha filha Ana Clara, pela compreensão e apoio nas muitas vezes em que precisei dedicar o tempo aos estudos quando poderia estar com elas.

Aos meus pais, Marília e Hermes (*in memorian*), que dedicaram suas vidas para que eu encontrasse o caminho do conhecimento e da descoberta constante, mesmo quando fui resistente.

Aos meus irmãos, Anderson e Vanessa, que em suas crenças, sempre sólidas, expressam grandes valores familiares, mesmo que às vezes eu demore a compreendê-los. Frequentemente entendem meus erros e limitações e motivam-me a refletir sobre humildade.

Aos meus Amigos Ítalo, Flávio e principalmente o Alexandre que nas discussões filosóficas e práticas de estudo cotidianas me apoiaram e ajudaram a encontrar motivações para trilhar essa jornada até o fim.

À Júlia Assis (*in memorian*), colega de estudos esforçada, pelas suas muitas contribuições em várias reuniões que fizemos durante o ano de 2016, nas quais pude aprender muito com o seu trabalho e sua força. E ao novo colega, Lucas Machado, que tive a oportunidade de conhecer e ter o apoio na reta final do trabalho, muito empenhado e prestativo.

Ao meu Orientador Adriano César Machado Pereira pela disponibilidade e por ter feito mais que orientar, proporcionando a minha inserção em grupos de estudo de alta qualidade e desempenho em Finanças Computacionais (FICO).

Ao corpo docente do programa de pós-graduação em Modelagem Matemática Computacional do Centro Federal de Educação Tecnológica - CEFET-MG por proporcionarem aos alunos um excelente curso de mestrado.

“A incerteza foi sempre o chão familiar da escolha.” (Zygmunt Bauman)

Resumo

A aplicação de algoritmos em investimentos é bastante pertinente, considerando que é comum o desejo dos investidores em adotar critérios objetivos para embasar suas decisões em operações financeiras. Recentemente há um crescente interesse pela automatização de estratégias de operação (*algotrading*). O emprego de Redes Neurais Artificiais (RNAs) do tipo *Extreme Machine Learning* (ELM) mostra-se propício, principalmente para estratégias de operação de curto prazo, dada sua maior eficiência demonstrada no treinamento. Porém, há uma carência de estudos na aplicação de ELM no mercado financeiro. O objetivo deste trabalho foi desenvolver uma estratégia de operação inteligente, baseada nas previsões geradas por um conjunto (*Ensemble*) de RNAs do tipo ELM. Cada RNA tem a responsabilidade de realizar previsões de tendência no retorno dos Preço e Volume com base em dados históricos dispostos em janelas temporais deslizantes de preço, retorno, volume e indicadores de análise técnica. A estratégia então determina os momentos de abertura e fechamento de posições considerando os sinais das previsões das RNAs. Uma validação do tipo *backtesting* simulado foi realizada nos ativos VALE3, ITUB4, PETR4 e BOVA11, com periodicidades variadas durante o ano de 2017, comparando os resultados financeiros com as estratégias *Buy and Hold* e Randômica, e entre a Estratégia RNA Price e o *Ensemble* Price and Volume. Os resultados encontrados mostram que o uso de RNAs do tipo ELM são adequadas para estratégias de operações de curto prazo. o *Enslemble* de RNA Preço e Volume causou melhoras nos indicadores financeiros Fator de Lucro e reduziu o *Maxdrawdown* em todos os casos apresentados, melhorando a relação risco retorno da estratégia. Além disso, reduziu o número de operações para quase metade quando comparada com a estratégia que utilizava apenas previsões da RNA Preço.

Palavras-chave: Finanças Computacionais, Negociação automatizada, Algotrading, Rede Neural Artificial, RNA, Extreme Learning Machine, ELM, *Ensemble*, Mercado Financeiro.

Abstract

The application of algorithms in investments is quite pertinent, considering that it is common the investors desire to adopt objective criteria to support their decisions in financial operations. Recently there is a growing interest in the automation of operating strategies (algotrading). The use of Extreme Machine Learning (ELM) Artificial Neural Networks (ANN) appears to be conducive, especially to short-term operational strategies, given their greater demonstrated training efficiency. However, there is a lack of studies in the application of ELM in the financial market. The objective of this work was to develop an intelligent operation strategy, based on the predictions generated by an ensemble of ELM (ANN). Each ANN has the responsibility of forecasting return price and volume trends based on historical data arranged in time-slice windows of price, return, volume and technical analysis indicators. The strategy determines the opening and closing moments of positions considering the signals of ANN forecasts. A simulated backtesting type validation was performed on assets VALE3, ITUB4, PETR4 and BOVA11 (B3), with varying periodicities during the year 2017, comparing the financial results with the Buy and Hold and random strategies and between Simple ANN Price and Ensemble Price Volume. The results show that the use of ELM ANN are adequate for short-term operations strategies. The ANN enslemble Price and Volume caused improvements in Profit Factor financial indicator and reduced the Maxdrawdown in all cases presented, improving the risk return ratio of strategy. In addition, it reduced the number of operations to almost half when compared to the strategy that used only ANN Price forecasts.

Keywords: Financial Computing, Automated Negotiations, Algotrading, Artificial Neural Network, ANN, Extreme Learning Machines, ELM, *Ensemble*, Financial Markets.

Lista de Figuras

Figura 1 – Evolução de Valores Negociados Bovespa 2
Figura 2 – Relatório Pesquisa ELM WoS 10
Figura 3 – Evolução do Número de Citações Top 10 artigos 11
Figura 4 – Artigos ELM WoS exportados pelo CiteSpace para Google Earth 12
Figura 5 – Esquema Metodológico - Modelo e Estratégia 28
Figura 6 – Bandas de Bollinger 33
Figura 7 – Janelas de Tempo na Previsão 33
Figura 8 – Arquitetura da Rede 35
Figura 9 – Percentual de *Candles* acima dos Custos Operacionais Ativos x Periodicidades 2017 48
Figura 10 – Variação Retornos (%) Máximos e Mínimos - BOVA11 2017 49
Figura 11 – Variação Retornos (%) - BOVA11 2017 - À esquerda M30 e à direita H1 49
Figura 12 – Variação Retornos (%) Máximos e Mínimos - VALE3 2017 50
Figura 13 – Variação Retornos (%) - VALE3 2017 - À esquerda M30 e à direita H1 . 50
Figura 14 – Variação Retornos (%) Máximos e Mínimos - ITUB4 2017 51
Figura 15 – Variação Retornos (%) - ITUB4 2017 - À esquerda M30 e à direita H1 . 51
Figura 16 – Variação Retornos (%) Máximos e Mínimos - PETR4 2017 52
Figura 17 – Variação Retornos (%) - PETR4 2017 - À esquerda M30 e à direita H1 . 52
Figura 18 – Evolução do Capital COMPRAS BOVA11 H1 - 1º SEM/2017 59
Figura 19 – Evolução do Capital VENDAS BOVA11 H1 - 1º SEM/2017 60
Figura 20 – Evolução do Capital COMPRAS VALE3 M30 - 1º SEM/2017 62
Figura 21 – Evolução do Capital VENDAS VALE3 M30 - 1º SEM/2017 62
Figura 22 – Evolução do Capital COMPRAS ITUB4 H1 - 2º SEM/2017 64
Figura 23 – Evolução do Capital VENDAS ITUB4 H1 - 2º SEM/2017 65
Figura 24 – Evolução do Capital COMPRAS PETR4 M30 - 2º SEM/2017 67
Figura 25 – Evolução do Capital VENDAS PETR4 M30 - 2º SEM/2017 67
Figura 26 – Evolução do Capital COMPRAS VALE3 M30 - 1º SEM/2017 69
Figura 27 – Evolução do Capital COMPRAS VALE3 H1 - 1º SEM/2017 70
Figura 28 – Evolução do Capital COMPRAS ITUB4 M30 - 2º SEM/2017 70
Figura 29 – Evolução do Capital COMPRAS ITUB4 H1 - 2º SEM/2017 72
Figura 30 – Evolução do Capital COMPRAS PETR4 M30 - 2º SEM/2017 72
Figura 31 – Evolução do Capital COMPRAS PETR4 H1 - 2º SEM/2017 74

Lista de Tabelas

Tabela 1 – Participação dos Investidores no segmento BOVESPA da [B][3] 2
Tabela 2 – Plataformas de Investimento com Robôs 5
Tabela 3 – TOP 10 - Publicações sobre ELM na WoS 11
Tabela 4 – Dados de Entrada e Classificação das Redes Neurais 34
Tabela 5 – Percentual de *Candles* acima do Custo Operacional 2017 48
Tabela 6 – Matriz de Confusão BOVA11 - 1º Semestre 2017 54
Tabela 7 – Indicadores RNA BOVA11 - 1º Semestre de 2017 54
Tabela 8 – Matriz de Confusão VALE3 - 1º Semestre 2017 55
Tabela 9 – Indicadores RNA VALE3 - 1º Semestre de 2017 55
Tabela 10 – Matriz de Confusão ITUB4 - 2º Semestre 2017 56
Tabela 11 – Indicadores RNA ITUB4 - 2º Semestre de 2017 56
Tabela 12 – Matriz de Confusão PETR4 2º Semestre de 2017 57
Tabela 13 – Indicadores RNA PETR4 - 2º Semestre de 2017 57
Tabela 14 – Estratégia ELM Simple Price BOVA11 H1 - 1º Semestre de 2017 61
Tabela 15 – Estratégia ELM Simple Price VALE3 M30 - 1º Semestre de 2017 63
Tabela 16 – Estratégia ELM Simple Price ITUB4 H1 - 2º Semestre de 2017 66
Tabela 17 – Estratégia ELM Simple Price PETR4 M30 - 2º Semestre de 2017 68
Tabela 18 – Comparativo Estratégia Simple X PriceVol VALE3 1º Sem/2017 71
Tabela 19 – Comparativo Estratégia Simple X PriceVol ITUB4 2º Sem/2017 73
Tabela 20 – Comparativo Estratégia Simple X PriceVol PETR4 2º Sem/2017 74

Lista de Quadros

Quadro 1 – Matriz de Confusão 36

Lista de Algoritmos

Algoritmo 1 – Cálculo do On Balance Volume (OBV) 31
Algoritmo 2 – Robô Estratégia *Buy and Hold* (B&H) 39
Algoritmo 3 – Robô Estratégia Randômica (RAND) 39
Algoritmo 4 – Estratégia ELM Price (Simple) 40
Algoritmo 5 – Estratégia Ensemble ELM (PriceVol) 42
Algoritmo 6 – MaxDrawDown 46

Lista de Abreviaturas e Siglas

AG	Algoritmo Genético
AI	*Artificial Intelligence*
APT	*Arbitrage Pricing Theory*
ATS	*Automated Trading Systems*
B3	Bolsa Brasil Balcão
BB	*Bollinger Bands*
BOVA11	Ativo Fundo de índice
BP	*Backpropagation*
BM&F	Bolsa de Mercadorias e Futuro
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CAPM	Modelo de Precificação de Ativos Financeiros
CBLC	Companhia Brasileira de Liquidação e Custódia
CCI	*Commodity Channel Index*
CDB	Certificado de Depósito Bancário
CDI	Certificado de Depósito Interbancário
CETIP	Central de Custódia e Liquidação de Títulos Privados
D1	Periodicidade de 1 dia
DS	*Direcional Symmetry*
DMA	*Direct Market Access*
ELM	*Extreme Learning Machine*
H1	Periodicidade de 1 hora
H4	Periodicidade de 4 horas
HFT	*High Frequency Trading*
HME	Hiótese do Mercado Eficiente

IA	Inteligência Artificial
IFR	Índice de Força Relativa
IMD	Índice de Movimento Direcional
ITUB4	Ativo Itau Unibanco Holding S/A
KML	*Keyhole Markup Language*
M1	Periodicidade de 1 minuto
M5	Periodicidade de 5 minuto
M15	Periodicidade de 15 minuto
M30	Periodicidade de 30 minutos
MACD	*Moving Average Convergence / Divergence*
MDD	*Maxdrawdown*
MFI	*Money Flow Index*
MLP	*Multi Layer Perceptron*
MM	Média Móvel
MME	Média Móvel Exponencial
OBV	*On Balance Volume*
OHLC	*Open High Low Close*
PETR4	Ativo Petróleo Brasileiro S/A Petrobras
POCID	*Prediction of Change in Direction*
QIEA	*Algoritmo Evolutivo de Inspiração Quântica*
RNA	Rede Neural Artificial
SAR	*Stop and Reverse Parabólico*
SLFN	*Single-Hidden Layer Feedforward Network*
SVM	*Support Vector Machine*
TC	*Times Cited*
TSE	Bolsa de Tókio

VALE3	Ativo Vale S/A
WoS	*Web of Science*

Lista de Símbolos

$\in$	Pertence
σ	Sigma (Desvio Padrão)

Sumário

1 – Introdução 1
1.1 Contextualização 1
1.1.1 Histórico [B]^3 2
1.1.2 A Nova Era no Mercado Financeiro 4
1.1.3 Redes Neurais Artificiais e *Algotrading* 5
1.2 Desafio - Hipótese do Mercado Eficiente 7
1.3 Justificativa 7
1.4 Motivação 8
1.5 Objetivos 8
1.6 Organização do trabalho 9

2 – Trabalhos Relacionados 10
2.1 Breve Estudo Bibliométrico ELM 10
2.2 Trabalhos Relacionados 13

3 – Fundamentação Teórica 16
3.1 Estratégia Automatizada de Investimento 16
3.1.1 Portfólio 16
3.1.2 Gestão do Capital 17
3.1.3 Tipos de Estratégias de operação 17
3.1.4 Gestão do Risco 17
3.1.5 Otimização da Estratégia 18
3.2 Redes Neurais Artificiais 19
3.2.1 Arquitetura de uma RNA 19
3.2.2 Aprendizado Automático 20
3.2.3 Redes FeedForward 20
3.2.4 Redes ELM 21
3.2.5 Vantagens e Desvantagens 22
3.3 Análise Técnica 23
3.3.1 Indicadores de Tendência 25
3.3.2 Indicadores de Momento - Osciladores 25
3.3.3 Indicadores de Volatilidade 26
3.3.4 Indicadores de Volume (Força de Mercado) 27

4 – Metodologia 28
4.1 Delineamento da pesquisa 28

4.2 Modelo . . . 29
4.2.1 Coleta de Dados . . . 29
4.2.2 Seleção e Cálculo de Indicadores . . . 30
4.2.3 *Algotrading* com RNA . . . 33
4.2.4 Métodos de Avaliação das Previsões das RNAs . . . 36
4.3 Estratégias de Operação . . . 37
4.3.1 Estratégias Automatizadas de Operação (Robôs) . . . 38
4.3.1.1 Robô Estratégia *Buy and Hold* . . . 38
4.3.1.2 Robô Estratégia Randômica . . . 39
4.3.1.3 Robô Estratégia ELM Simple . . . 39
4.3.1.4 Robô Estratégia ELM Ensemble - PriceVol . . . 40
4.3.2 AlgoTrading Aspectos Importantes . . . 42
4.3.2.1 Gerenciamento do Capital . . . 42
4.3.2.2 Gerenciamento do Sinal . . . 43
4.3.2.3 Gerenciamento do Risco . . . 43
4.3.3 Simulação e *Backtesting* . . . 44
4.3.4 Métodos de Avaliação Financeira . . . 44

5 – Resultados . . . 47
5.1 Caracterização dos Dados . . . 47
5.1.1 BOVA11 . . . 48
5.1.2 VALE3 . . . 49
5.1.3 ITUB4 . . . 50
5.1.4 PETR4 . . . 51
5.2 Desempenho da predição das RNAs . . . 52
5.2.1 BOVA11 . . . 53
5.2.2 VALE3 . . . 55
5.2.3 ITUB4 . . . 56
5.2.4 PETR4 . . . 57
5.3 Avaliação Financeiras das Estratégias . . . 58
5.3.1 Estratégia Simple . . . 58
5.3.1.1 BOVA11 . . . 59
5.3.1.2 VALE3 . . . 61
5.3.1.3 ITUB4 . . . 63
5.3.1.4 PETR4 . . . 65
5.3.2 Estratégia ELM Simple x ELM Price & Volume . . . 65
5.3.2.1 VALE3 . . . 67
5.3.2.2 ITUB4 . . . 69
5.3.2.3 PETR4 . . . 71

6 – Conclusão e Trabalhos Futuros 75
6.1 Considerações Finais 75
6.1.1 Rede ELM 75
6.1.2 Estratégias 76
6.2 Trabalhos Futuros 77

Referências 79

1 Introdução

É comum o desejo dos investidores e operadores do mercado financeiro adotarem critérios objetivos para embasar suas decisões em operações financeiras. A utilização da Análise Técnica e da Análise Fundamentalista é muito citada em trabalhos acadêmicos. A aplicação de algoritmos em investimentos é bastante pertinente, considerando que eles podem transformar aquelas análises na automatização de estratégias de operação (*algotrading*).

O emprego de Redes Neurais Artificiais (RNAs) tem se consolidado ao longo do tempo. O surgimento de novos tipos de RNAs como a *Extreme Machine Learning* (ELM) mostra-se propício para continuar avaliando as melhorias oferecidas pelas novas tecnologias, que podem ser aplicadas neste contexto de finanças computacionais. Porém, identifica-se uma carência de estudos na aplicação de ELM no mercado financeiro.

1.1 Contextualização

A [B]^3 S.A. é uma das principais provedoras de infraestrutura de mercado financeiro do mundo e a principal da América Latina em valor de mercado. Criada em março de 2017, é o resultado da fusão entre a BM&FBOVESPA e a CETIP (Central de Custódia e Títulos de Liquidação e Custódia). Ela oferece serviços de negociação (bolsa), pós-negociação (*clearing*), registro de operações de balcão e de financiamento de veículos e imóveis. A [B]^3 está entre as dez maiores bolsas em capitalização de mercado e uma das maiores em valor de mercado do mundo.

O valor de mercado (capitalização bursátil) da BM&FBovespa, das 339 empresas com ações negociadas atingiu R$ 2,58 trilhões, conforme balanço de operações publicado em maio de 2017 no site da [B]^3 [1]. A bolsa NYSE, maior bolsa em capitalização do mundo, apresenta captação de USD$ 20,6 trilhões de dólares. [2] O nível de capitalização da Bovespa é relevante para o mercado financeiro no Brasil e mundial, além de mostrar a importância de estudos com aplicação neste setor.

A Figura 1 evidencia o crescimento do volume financeiro em investimentos e a quantidade de negociações realizadas na BM&FBovespa entre 2003 e 2017. É possível identificar uma redução nos volumes em 2008 e 2012, resultado de crises financeiras recentes. No entanto, os volumes e quantidades negociadas tiveram crescimento significativo quando considerados os volumes negociados desde 2003 até 2017.

[1] http://www.bmfbovespa.com.br/pt_br/institucional/imprensa/ultimos-releases/b3-divulga-balanco-de-operacoes-de-maio-de-2017.htm

[2] http://www.nyxdata.com/nysedata/asp/factbook/viewer_edition.asp?mode=tables&key=333&category=5

Figura 1 – Evolução de Valores Negociados Bovespa

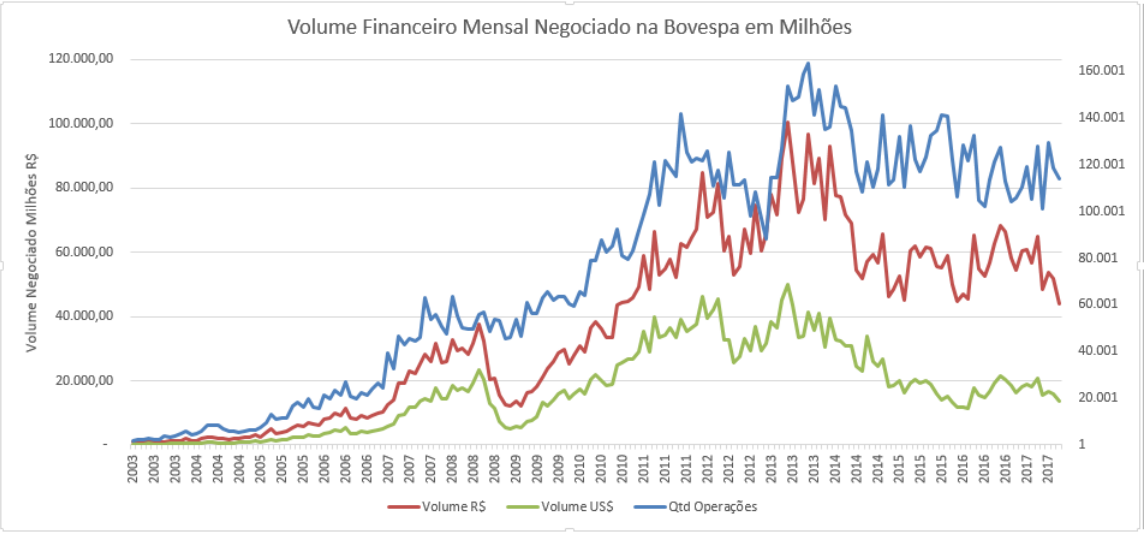

Fonte: Elaborado pelo autor com dados BM&FBovespa [3]

A Tabela 1 mostra que 15,9% dos investidores na [B]^3 são Pessoas Físicas quando apenas 0,7% são Instituições financeiras. Existindo uma parcela significativa de pessoas físicas buscando investimentos deste tipo [4].

Tabela 1 – Participação dos Investidores no segmento BOVESPA da [B]^3

TIPO DE INVESTIDOR [B]3					
Mês	**Pessoas Físicas**	**Estrangeiros**	**Institucionais**	**Instituições Financeiras**	**Empresas**
mai/17	15,9%	26,7%	51,0%	0,7%	5,7%
abr/17	15,5%	26,0%	52,0%	1,0%	5,5%

Fonte: Balanço de Operações Maio/2017 Bovespa

Neste contexto de crescimento da [B]^3, pode-se perceber não apenas o aumento do volume de capital e número de operações no mercado financeiro, mas também a diversificação dos investidores. Assim, estudos como este na área de finanças computacionais, com uso de estratégias automatizadas de investimento, podem atender a uma variedade crescente e diversificada de investidores no Brasil.

1.1.1 Histórico [B]^3

A primeira bolsa de valores brasileira foi fundada no Rio de Janeiro em 1848. A bolsa paulista foi fundada em 1890, mas foi fechada no ano seguinte em decorrência da política de encilhamento aplicada pelo governo. [5]

[4] http://www.bmfbovespa.com.br/pt_br/institucional/imprensa/ultimos-releases/b3-divulga-balanco-de-operacoes-de-maio-de-2017.htm

[5] http://www.investpedia.com.br/artigo/Historia+da+BMFBovespa.aspx

Em 1895, a bolsa foi reaberta com o nome de Bolsa de Fundos Públicos de São Paulo. Naquela época, as bolsas de valores brasileiras eram entidades oficiais corporativas, vinculadas às secretarias de finanças dos governos estaduais e compostas por corretores nomeados pelo poder público. As negociações de títulos públicos e de ações eram registradas em enormes quadros-negros e as cotações gravadas a giz. [6]

Em 1967, após as reformas do sistema financeiro e do mercado de capitais implantadas pelo governo no biênio 1965-1966, as bolsas assumiram a característica institucional de associações civis sem fins lucrativos. Surgiu então a figura da sociedade corretora e do operador de pregão, que substituíram a antiga figura do corretor de fundos públicos e a bolsa passou a ser chamada de Bolsa de Valores de São Paulo – Bovespa.

A partir de 1970 os negócios da bolsa passaram a ser registrados eletronicamente através de cartões perfurados, que substituíram os antigos boletos. Em 1972 os negócios começaram a ser registrados em tempo real, através da implantação do pregão automatizado.

Em 1986, iniciaram-se os pregões da Bolsa de Mercadorias e Futuros - BM&F e de sua *Clearing* de Derivativos. Em 1990 são iniciadas as operações no Sistema de Negociação Eletrônica CATS, em paralelo ao pregão viva-voz.

No ano de 1997, foi implantado o sistema Mega Bolsa, plataforma tecnológica de processamento de informações. A bolsa, dava seu mais importante salto rumo ao crescimento e consolidação com o fim do pregão viva-voz e início dos negócios realizados através do Mega Bolsa.

O sistema *Home Broker* foi lançado em 1999. Por ele, o investidor pôde finalmente transmitir suas ordens de compra e venda diretamente ao Mega Bolsa, através da internet. O acesso às cotações em tempo real e consulta às posições financeiras possibilitaram o crescimento das aplicações. Foi nesse ano que surgiu o *After-Market*, sessão noturna de negociação eletrônica.

Em 2007 a Bovespa deixou de ser uma instituição sem fins lucrativos e se tornou uma sociedade por ações, a Bovespa Holding S/A, que possuía como subsidiárias integrais a Bolsa de Valores de São Paulo e a Companhia Brasileira de Liquidação e Custódia (CBLC). Em 2008 ocorreu a fusão entre Bovespa Holding e BM&F, criando a BM&FBovespa.

Em 2017, foi autorizada a fusão entre a BM&FBovespa e a CETIP S.A.- Central de Custódia e Liquidação de Títulos Privados. A empresa fruto desta fusão foi denominada [B]^3 - Brasil, Bolsa Balcão. No mercado de ações a custódia e liquidação é realizada pela CBLC, no caso de títulos privados, como CDB, CDI e letras de câmbio, esta tarefa cabe à CETIP. A CETIP foi criada em março de 1986 pelas instituições financeiras e pelo Banco Central.

[6] http://ri.bmfbovespa.com.br/ptb/2716/Laudo%20KPMG%20BMFBOVESPA%20e%20Cetip.pdf

1.1.2 A Nova Era no Mercado Financeiro

Com o avanço da negociação eletrônica, o desenvolvimento de sistemas baseados em protocolos internacionalmente reconhecidos e a adoção do modelo de *Direct Market Access* (DMA) começou-se a criar um ambiente propício para a prática do *algorithmic trade* (negociação automatizada baseada em modelos matemáticos).

A adoção de ATS (*Automated Trading Systems*) teve início nos EUA a partir de 1990 quando a *Security and Exchange Comission* (SEC) deu permissão para a combinação de ordens de compra e venda sem intermediários financeiros de títulos e moedas independentes ou comissionados (*dealers* e *brokers*) (ALDRIDGE, 2009).

Na Bovespa, em fevereiro de 2009, teve início uma nova política de preços com faixas progressivas de descontos de acordo com o volume negociado. Houve uma redução do valor cobrado pelas ofertas inseridas no sistema eletrônico de negociação Mega Bolsa que não são fechadas, o que estimulou o desenvolvimento de *algorithmic trading*. A nova política objetivou tornar os produtos mais competitivos e adequados aos participantes e à realidade do mercado, além de estimular a liquidez e a adesão de investidores que utilizam plataforma eletrônica de negociação, em especial os *algorithmic traders*.

Os primeiros *algotraders* representaram 0,45% do volume geral em mar/09, participação que aumentou para 0,53% em abr/09, sendo que, para os contratos de câmbio, estes representaram 1,53% e 1,8% do volume, respectivamente. Em outubro de 2009, 12 *algotraders* já eram responsáveis por 6,0% de todo o volume negociado na BM&FBovespa. [7] Os *Algotraders* representaram 2,1% do volume total no segmento BM&F e 9,6% dos contratos de Índice futuro em julho de 2009. [8]

O momento atual de automação que atingiram as operações nas bolsas de valores é propício para uma nova transição mercado financeiro, a era dos robôs de investimento. No Brasil, algumas empresas já permitem que suas carteiras de investimento sejam administradas por robôs investidores. A Tabela 2, retirada do Estadão [9], apresenta algumas destas empresas com seus respectivos produtos, custos e aplicação mínima. É possível perceber nos produtos administrados que os robôs destas empresas ainda não operam ativos da bolsa de valores diretamente. Robôs que operam ativos em bolsa requerem uma complexidade maior em gestão do portfólio, gestão do risco e uma complexa adequação das operações ao perfil do investidor.

A *Smarttbot* [10] é uma empresa com Tecnologia focada em investimento automatizado na bolsa de valores (*algotrading*). Fundada em 2011, com sede em Belo Horizonte-MG, é

[7] http://ir.bmfbovespa.com.br/enu/543/BMFBovespa3T09Presentation111109_ingles.pdf
[8] http://ri.bmfbovespa.com.br/ptb/641/BMFBovespa2T09Apresentao.pdf
[9] http://economia.estadao.com.br/noticias/geral,nova-geracao-de-robos-de-investimento-comeca-a-conquistar-pessoa-fisica,10000098852
[10] https://smarttbot.com/

Tabela 2 – Plataformas de Investimento com Robôs

Plataforma	Produtos	Custo Anual	Aplicação mínima
Alkanza	ETFs, Tesouro	0,5% mais corretagem	R$ 5 mil
Magnetis	CDBs, ETFs, fundos DI e multimercado, LCIs, LCAs	0,75% (média)	R$ 15 mil
Vérios	ETFs, Tesouro	máximo de 0,95%	R$ 12 mil
Oi Warren	ETFs, fundos DI, Tesouro	máximo de 0,85%	R$ 100

Fonte: Estadão Online, 9 Janeiro de 2017

uma das poucas empresas brasileiras que fornece uma plataforma para criação e execução de robôs investidores para negociação de ativos na [B][3]. A *Smarttbot* faz a gestão de mais de R$ 1 bilhão e mais de 20.000 ordens negociadas na bolsa em um dia. É possível utilizar robôs prontos gratuitamente ou contratá-los por aluguel, que podem chegar a R$ 699,00 por mês, dependendo da estratégia e *setup* selecionados.

Na Bolsa de Tokyo (TSE), onde é possível contratar planos para alocação de computadores servidores ao lado dos mesmos onde ficam os sistemas de transação da própria TSE, desde 2010 o valor das ações negociadas via robôs investidores triplicou para aproximadamente 270 trilhões de ienes. O número de transações feitas via negociação algorítmica também cresceu, sendo que em 2010 representavam 10% de todas as ordens. Já em 2014 este registro foi de 72% (NAKAMURA, 2015).

Já no Brasil, de 2011 a 2013, segundo dados da BM&F Bovespa (2013), o uso de *High Frequency Trade* (HFT) cresceu 47,1%, chegando a representar 10,6% de todas as negociações realizadas na bolsa no primeiro semestre de 2013 e 9,5% no segundo.

Em meio a esta evolução tecnológica apresentada nas bolsas de valores mundiais e especificamente no Brasil, aumentou a procura por ferramentas que pudessem apoiar as decisões do investidor no mercado de capitais. Técnicas que pudessem melhorar a gestão do risco e alcançar retornos financeiros mais previsíveis, com probabilidades melhores que as da distribuição normal encontrada em um jogo de moeda (cara 50% / coroa 50%). Estudos como este, em que se propõe um método preditivo automatizado de operação com base nas previsões com o objetivo de reduzir as incertezas e controlar os riscos inerentes ao tipo de operação, estão se tornando cada vez mais relevantes para o mercado financeiro.

1.1.3 Redes Neurais Artificiais e *Algotrading*

Os mercados acionários são afetados por muitos fatores correlacionados, tais como a economia, política e mesmo fatores psicológicos como medo, euforia, pessimismo ou otimismo (YAO; TAN; POH, 1999). A influência do comportamento dos agentes econômicos na complexidade do mercado foi objeto de estudo de ATMAN; GONÇALVES (2012), evidenciando que a complexidade de interação dos fatores reais torna a previsão de séries

temporais do mercado financeiro uma tarefa bastante difícil.

Por muitos anos, a previsão em séries temporais com o uso de Redes Neurais Artificiais (RNAs) tem sido objeto de estudo em várias segmentos, tais como, previsão do tempo, reconhecimento de padrões, econometria, matemática financeira, dentre outros.

Dada a complexidade do mercado de ações não é possível antecipar todas as mudanças ao longo do tempo. Portanto, ferramentas de aprendizado automático, como as RNAs, são adequadas para a função, devido à sua capacidade de adaptação ao contexto e às mudanças do ambiente (NORVIG; RUSSELL, 2014).

Nas décadas de 1990 e 2000 RNAs foram utilizadas com sucesso para realizar previsões em séries temporais. Segundo NETO et al. (2010), o modelo de RNA mais utilizado foi o *MultiLayer Perceptron* (MLP) ou Perceptron de Multicamadas, embora não seja o único modelo adotado.

As redes neurais *Multi Layer Perceptron* (MLP) e *Suporte Vector Machines* (SVM) tradicionais enfrentam questões desafiadoras, tais como: (1) velocidade de aprendizagem lenta, (2) intervenção humana trivial, e/ou (3) escalabilidade computacional deficiente. A rede *Extreme Learning Machine* (ELM) é uma tecnologia emergente que supera alguns destes desafios. A ELM funciona para redes de *feedforward* de camada única escondida generalizada *Single Layer Feedforward Network* (SLFNs). A essência da ELM é que a camada oculta de SLFNs não precisa ser ajustada. A ELM proporciona um melhor desempenho que as técnicas tradicionais (HUANG; WANG; LAN, 2011).

Nos últimos anos, a evolução das pesquisas em previsão de séries temporais com uso de RNA caminhou no sentido de adotar soluções híbridas. O trabalho de DONG; ZHANG (2014), no qual mesclaram RNA e Lógica Fuzzy, é um indício desta evolução. O estudo de PULIDO; MELIN; CASTILLO (2011), no qual foi apresentado um modelo de RNA com Algoritmo Genéticos, é outro exemplo. E por fim, o conjunto de técnicas computacionais inteligentes com *Ensembles* de RNAs nos trabalhos de HAYASHI et al. (2015) e SILVA et al. (2015). Estas técnicas foram utilizadas para melhorar a acurácia ou a precisão das previsões através de soluções hibridas e conjuntas.

Os analistas financeiros e investidores utilizam os seguintes métodos de predição para realizar suas operações: Análise Técnica, Análise Fundamentalista, Análise de Séries Temporais e Técnicas de Inteligência Computacional com aprendizado automatizado (OLIVEIRA; NOBRE; ZARATE, 2013).

As técnicas de inteligência computacional adotadas nesta pesquisa são um conjunto (*ensemble*) de RNAs do tipo ELM para realizar previsões e apoiar a decisão de estratégias de operação automatizadas, seguindo no mesmo sentido das pesquisas recentes. Acredita-se que estes métodos poderão se mostrar eficientes para reduzir a incerteza, aprimorando a gestão de riscos e o retorno de investimentos no mercado de capitais.

1.2 Desafio - Hipótese do Mercado Eficiente

A Hipótese dos Mercados Eficientes (HME) tem se mostrado uma das mais influentes teorias no campo das finanças, sendo base para inúmeros modelos de precificação de ativos, com aplicações que vão desde modelos tradicionais utilizados em Finanças Corporativas até avançadas teorias utilizadas na identificação do preço "justo" de derivativos financeiros.

Um dos pilares da HME é a possibilidade da arbitragem como mecanismo de correção de possíveis desvios que o mercado possa sofrer de sua forma eficiente. Pela teoria clássica dos mercados eficientes, mesmo em um ambiente caracterizado pela presença de alguns investidores não totalmente racionais, a possibilidade de arbitragem anularia o efeito destes nos preços dos ativos negociados, trazendo-os de volta ao seu valor fundamental.

Para JUNIOR; SARAIVA; IKEDA (2004), o campo das Finanças Comportamentais tem mostrado, entretanto, que nos mercados reais a possibilidade de arbitragem é, muitas vezes, custosa e não passível de realização, comprometendo sua utilização como ferramenta reguladora do mercado. Até mesmo, a definição clássica de sua eficiência, que é a de refletir corretamente nos preços as informações existentes sobre os ativos financeiros.

Quando se assume que o comportamento dos preços de um ativo segue a hipótese de *Random Walk*, diz-se que ele obedece ao Processo de Markov, um processo estocástico em que o comportamento de uma variável durante um período de tempo depende somente do valor da variável no início do período, e não de seu histórico (HULL; BASU, 2016). Se o preço das ações é Markoviano, as previsões sobre o futuro dos títulos não devem ser afetadas pelos preços dos mesmos há semanas, dias ou mesmo há minutos. Previsões para o futuro são incertas e devem ser expressas em termos de distribuições de probabilidade.

1.3 Justificativa

Esta pesquisa justifica-se pela sua contribuição para a tomada de decisão em negociações tentando fornecer meios para reduzir a incerteza, assim como melhorar a relação de risco e retorno constante em aplicações no mercado de capitais. Espera-se ainda que este trabalho auxilie no desenvolvimento de novas técnicas de previsão e predição com a utilização das novas redes neurais e modelos aqui aplicados.

O uso de previsão com Redes Neurais Artificiais pode reduzir a incerteza em vários aspectos das estratégias de investimento financeiro, como a melhor gestão de capital aplicada à estratégia, a melhor gestão do portfólio ou a gestão do risco. Neste trabalho será abordado, principalmente, a identificação da melhor oportunidade de operações com base na previsão de tendências de retornos e volume fornecidos pelas Redes Neurais, com avaliação financeira dos impactos no retorno e no risco das operações realizados pelas estratégias automatizadas.

1.4 Motivação

O investimento no mercado de capitais é uma atividade de alto risco, que requer controle sobre muitas variáveis para que não se tenha prejuízo financeiro. Ainda que exista alto risco e complexidade inerentes a este tipo de aplicação, existe um volume significativo de investidores que tem optado por este tipo de investimento.

O interesse em reduzir os riscos, sem afetar o retorno, é latente na maioria dos perfis de investidores, bem como o desejo destes em aumentar os retornos nas operações sem aumentar, necessária e proporcionamento, o risco. Assim, a melhoria das técnicas de previsão, de gestão de risco e controle dos retornos pode reduzir a incerteza, auxiliando na tomada de decisão.

O estudo de previsão com uso de RNAs do tipo ELM, tecnologia recente mas promissora, aplicada a finanças computacionais torna este trabalho relevante devido a carência de estudos nesta área no Brasil.

As tecnologias de robôs com inteligência artificial para predição em séries de dados nos mercados financeiros pode ser adaptada a diferentes áreas e contextos. Assim, o método aqui não se limitaria somente a aplicação em séries financeiras, mas também, a qualquer série que tenha características semelhantes independentemente de sua origem. Por este motivo é também justificável o estudo, pois este poderia, com poucas adaptações, contribuir em outras áreas.

Nesse sentido, uma pequena contribuição que venha a diminuir a lacuna entre teoria e experimentação neste campo é válida, dado que o comportamento do mercado é um problema muito complexo. Assim, tem por motivação a dúvida se seria possível reduzir os riscos em relação às quedas de capital (MaxDraDown) e a relação de lucro e perda, inerentes à este tipo de investimento de renda variável, ou ainda, aumentar os retornos com a construção de um *algotrading* baseado em predições de um conjunto de Redes Neurais ELM.

1.5 Objetivos

O objetivo geral desta pesquisa é construir uma estratégia de operação para o mercado financeiro baseada na predição de retornos financeiros de redes neurais artificiais. Com isso será possível controlar melhor a relação risco/retorno em investimentos do mercado de capitais.

Nesta pesquisa são aproveitadas oportunidades relatadas em trabalhos futuros de CORREA (2017), mas com uso de um *Ensemble* de RNA do tipo ELM, novas entradas para treinamento das redes, além de alterações na estratégia de operação automatizada com janelas de tempo deslizantes para a predição. São adotados novos indicadores técnicos

como MACD, OBV e *Bollinger Bands* como entrada para o treinamento das Redes. A avaliação financeira das estratégias adota novos indicadores como o Fator de Lucro e *Maxdrawdown* (MDD).

Alguns dos objetivos específicos e principais diferenciais deste trabalho são:

- Construir o modelo dinâmico de previsão de preço e Volume;
- Comparar periodicidades de tempo diferentes para medir os resultados de predição e resultados financeiros;
- Comparar resultados de *Backtesting* simulado com outros *benchmarks* de investimento;
- Avaliar o desempenho financeiro do *Ensemble* de Redes ELM frente à estratégia com uma RNA simples.

1.6 Organização do trabalho

Esta dissertação está organizada em seis capítulos. Neste primeiro capítulo apresenta-se uma introdução ao tema, no qual são expostos a relevância, uma contextualização histórica do estado-da-arte, a motivação e os objetivos deste projeto. No Capítulo 2 são apresentados os trabalhos relacionados, com um estudo bibliométrico referente ao tema de previsão em RNA aplicados ao mercado financeiro. A fundamentação teórica é exposta no Capítulo 3, com subseções específicas para discorrer sobre Redes Neurais Artificiais, análise técnica e estratégias de investimento. No Capítulo 4 é apresentada a metodologia proposta (materiais e métodos), evidenciando o sequenciamento das atividades e a justificativa das escolhas da pesquisa. Os resultados do trabalho são apresentados no Capítulo 5 e, por fim, a conclusão e trabalhos futuros da pesquisa são descritos no Capítulo 6.

2 Trabalhos Relacionados

Um breve estudo bibliométrico com dados de uma pesquisa da Web of Science (WoS) e a utilização do *software CiteSpace* (CHEN, 2006) foi construído nesta seção. Trata-se de uma seleção internacional de trabalhos que lidam com o tema de Redes Neurais Artificiais do tipo ELM. O *CiteSpace* possibilita estudar aspectos geográficos, históricos e de impacto que inter-relacionam estes trabalhos. Assim, é possível apresentar o estado-da-arte de forma mais objetiva. Posteriormente são apresentados alguns trabalhos específicos sobre previsão com RNA, com *ensemble*, híbridos e, por fim, os trabalhos que apresentam estratégias de investimento automatizado.

2.1 Breve Estudo Bibliométrico ELM

Uma pesquisa com os termos "*Extreme Machine Learning*" foi realizada na base *Web of Science* (WoS) acessado e autenticado através site de periódicos da CAPES [1]. A pesquisa sobre ELM retornou 3.249 publicações, dentre as quais foi possível identificar os primeiros artigos escritos sobre o assunto (HUANG; SIEW, 2004) e (ZHU; HUANG; SIEW, 2004), que, curiosamente, ainda hoje apresentam poucas citações. Porém, o artigo (HUANG; ZHU; SIEW, 2004), escrito no mesmo ano, já apresenta grande número de citações, em relação aos demais artigos da pesquisa.

Os artigos mais citados sobre o assunto desde então foram (HUANG; ZHU; SIEW, 2006), (HUANG et al., 2012) e (HUANG et al., 2006), demonstrando os principais autores envolvidos na pesquisa. A Figura 2 apresenta o total de publicações sobre o ELM e artigos que fizeram as citações na base da WoS. Ainda é possível perceber que trata-se de um assunto recente, pois os primeiros artigos foram apresentados a partir de 2004. Outra detalhe importante é o crescente número de publicações do assunto, chegando, em 2016, a serem publicadas 896 trabalhos sobre o tópico.

Figura 2 – Relatório Pesquisa ELM WoS

Das publicações listadas na pesquisados foram filtradas apenas os artigos, totalizando 2.049 registros. Um relatório no site da WoS foi construído para se buscar todos os

[1] http://www.periodicos.capes.gov.br/

artigos que fizeram as citações. O relatório foi exportado para arquivos texto sem formação para que fossem utilizados como base de dados para o software *CiteSpace*.

A Tabela 3 mostra os 10 trabalhos mais citados referentes ao tema *Extreme Learning Machine* (ELM), o ano da publicação e o número total de citações - *Time Cited* (TC).

Tabela 3 – TOP 10 - Publicações sobre ELM na WoS

Nº	**Título**	**Ano**	**TC**
1	*Extreme Learning Machine: Theory and Applications*	2006	2.849
2	*Extreme Learning Machine for Regression and Multiclass Classification*	2012	1.327
3	*Universal Approximation using Incremental Constructive Feedforward Networks with Random Hidden nodes*	2006	914
4	*Extreme Learning Machine: A New Learning Scheme of feedforward neural networks*	2004	744
5	*Extreme Learning Machines: A Survey*	2011	665
6	*A Fast and Accurate Online Sequential Learning Algorithm for Feedforward Networks*	2006	644
7	*Convex Incremental Extreme Learning Machine*	2007	461
8	*Enhanced Random Search Based Incremental Extreme Learning Machine*	2008	380
9	*Optimization Method Based Extreme Learning Machine for Classification*	2010	344
10	*OP-ELM: Optimally Pruned Extreme Learning Machine*	2010	310

O Gráfico apresentado na Figura 3 mostra a evolução do número de citações ao longo dos anos de cada um dos 10 artigos mais citados, listados na Tabela 3. É possível inferir desta evolução de citações que há uma tendência crescente por pesquisas com a tecnologia ELM.

Figura 3 – Evolução do Número de Citações Top 10 artigos

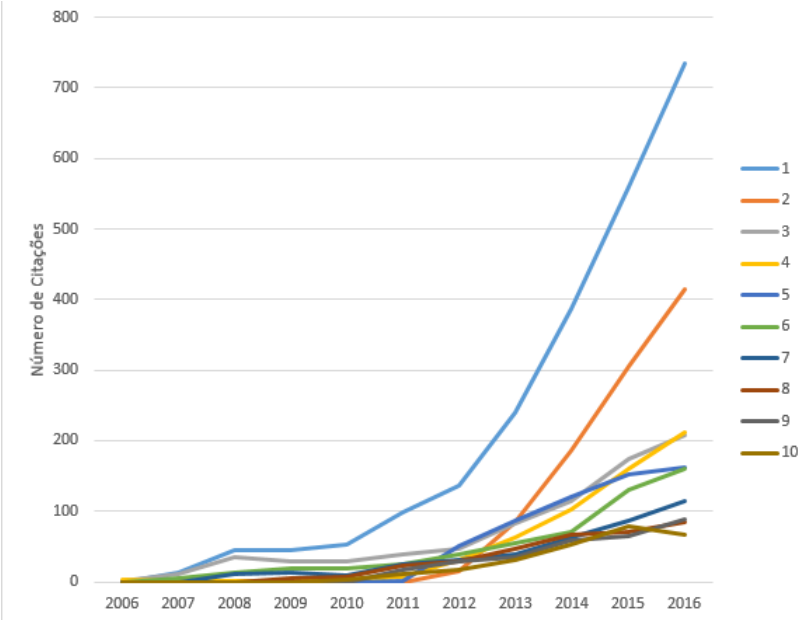

Elaborado pelo autor com dados da WoS até 2016

O processo de criação do projeto no *CiteSpace* para construção de um estudo bibliométrico inicia-se com a configuração de alguns parâmetros e posterior carga da base de artigos. O primeiro é relativo à quantidade de anos por fatia de tempo para que o gráfico classifique os artigos no tempo. Assim, foi definido o período de 2 anos por fatia no período de 2003 a 2016. Este é o período em que foram encontrados artigos com o tema pesquisado. Posteriormente foram gerados *clusters* com os termos do título, do resumo e das palavras chave de cada artigo. Critérios de seleção adotados foram os 50 maiores por fatia anual (*TOP Fifty slice*), LRF = 2 e LBY = 8 e e=2.0. *Network* = 248 and *Pruning* = None.

Na Figura 4 são exibidos artigos referenciados geograficamente, exportado do software *CiteSpace* em formato *Keyhole Markup Language* (KML). O arquivo KML aberto no Google Earth possibilitou a geração desta imagem com os artigos georreferenciados. Os pontos representam o local da publicação do artigo e as arestas são citações entre os artigos. Pode-se observar que são poucos trabalhos relacionados ao tema no Brasil. Embora um dos primeiros e mais citados trabalhos, (HUANG; ZHU; SIEW, 2006), tenha sido apresentado no "*8th Brazilian Symposium on Neural Networks*", que ocorreu em São Luís do Maranhão em 2004.

Figura 4 – Artigos ELM WoS exportados pelo CiteSpace para Google Earth

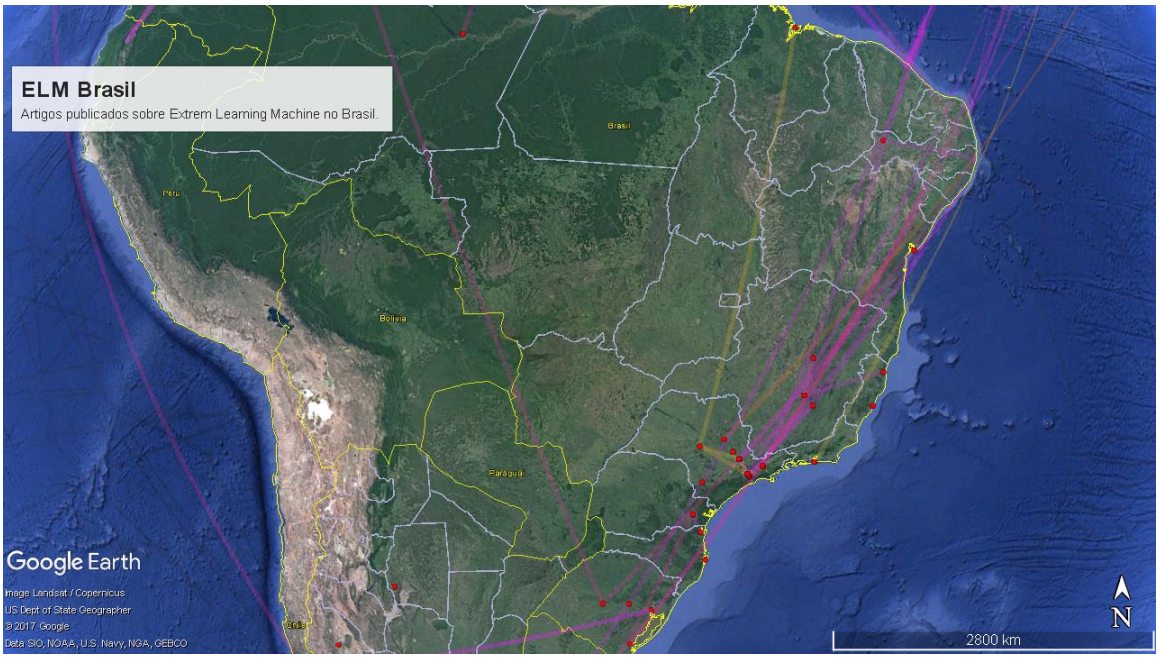

Elaborado pelo autor com uso de WoS, CiteSpace e Google Earth

Considerando o tamanho e relevância da bolsa de valores e do mercado financeiro no Brasil, bem como a carência de estudos em redes potencialmente relevante como as ELMs, torna-se interessante unir estes temas em novas pesquisas como a apresentada neste trabalho.

A velocidade da aprendizagem das redes neurais *feedforward* é, em geral, muito lenta e tem sido um grande gargalo em suas aplicações (HUANG; ZHU; SIEW, 2006). Se-

gundo o autor, as principais razões para isso são (1) os algoritmos de aprendizado baseados em gradientes e descendentes amplamente utilizados para treinar redes neurais são lentos e (2) todos os parâmetros das redes são atualizados iterativamente nesses algoritmos de aprendizado. HUANG; ZHU; SIEW (2006) propõe um novo algoritmo de aprendizagem chamado máquina de aprendizagem extrema, *Extreme Learning Machine* (ELM), para redes neurais *feedforward* de camada unidimensional, *Single Layer Feedforward Neural Networks* (SLFNs). Esta nova técnica escolhe aleatoriamente nós ocultos e determinam analiticamente os pesos de saída de SLFNs. Os resultados experimentais baseados em alguns problemas de aproximação e classificação de funções de *benchmark*, incluindo aplicações complexas muito amplas, evidenciaram que a ELM pode produzir um bom desempenho de generalização na maioria dos casos e pode aprender milhares de vezes mais rápido do que os algoritmos de aprendizagem populares convencionais.

2.2 Trabalhos Relacionados

Embora as RNAs estejam sendo usadas há muito tempo para conseguir boas previsões em séries temporais de acordo com AZOFF (1994) e ZHANG (2003), trabalhos recentes têm explorado os *ensembles* de RNAs com intuito de melhorar a sua capacidade de precisão na previsão. O trabalho de HAYASHI et al. (2015), é uma evidência desta tendência, onde foi construído o Algoritmo *Three-MLP Ensemble Re-RX* e classificadores para avaliação de risco de crédito.

Na pesquisa de CAO; TAY (2001) onde foi realizado um estudo comparativo entre as técnicas de *Support Vector Machines* (SVMs) e *Multi-Layer Perceptron* (MLP) treinada por um algoritmo de *Back Propagation* (BP). Os algoritmos foram aplicados sobre o índice S&P 500 diário do mercado financeiro norte americano. No experimento realizado, as SVMs previram melhor que a MLP com BP nas métricas de Erro Médio Quadrático Normalizado (NMSE), Erro Médio Absoluto (MAE), Simetria Direcional (DS) e na quantidade de acertos corretos nas previsões de tendência de alta e baixa. A análise dos resultados neste experimento demonstraram que é mais vantajoso utilizar SVMs para prever as séries temporais financeiras.

As pesquisas de PULIDO; MELIN; CASTILLO (2011) e BARROW; CRONE (2013), apresentaram *Crogging* (agregação de validação cruzada) para previsão, um novo algoritmo de conjuntos de redes neurais em subamostras de séries temporais, também deram ênfase na utilização de conjutos de RNAs. Já no trabalho de ESCOVEDO et al. (2013) foi apresentado uma pesquisa entitulada ”Usando Conjuntos para Aprendizagem Adaptativa: Uma abordagem Comparativa”, no qual também é explorado um *esemble* para aprendizagem adaptativa.

As redes neurais e os algoritmos AdaBoost basearam modelos de conjuntos para

uma melhor previsão de séries temporais não lineares, gerando assim poderosos sistemas de suporte à decisão (DONG; ZHANG, 2014).

O trabalho de ESCOVEDO et al. (2013) descreve o uso de um conjunto de classificadores baseados em redes neurais ponderadas com aprendizagem adaptativa. As redes neurais foram treinadas por meio de um algoritmo evolutivo de inspiração quântica (QIEA). Este algoritmo também foi usado para determinar os melhores pesos para cada classificador pertencente ao conjunto quando um novo bloco de dados chega. Os Classificadores neuro-evolucionários foram capazes de aprender o conjunto de dados e responder rapidamente aos movimentos direcionais.

No trabalho de OLIVEIRA; NOBRE; ZARATE (2013) foi construída uma RNA para o mercado financeiro. O modelo permite analisar o comportamento futuro dos preços de fechamento e prever as mudanças de tendência na direção do preço no ativo PETR4 (Petrobras ON BM&FBOVESPA). Usando a teoria econômica e financeira, combinaram indicadores de análise técnica, análise fundamentalista e análise de séries temporais como entrada para a RNA do tipo *Multi Layer Perceptron* (MLP), na qual foi possível atingir um nível no indicador de predição de mudança de direção *Prediction of Change in Direction* (POCID) de 93,62% para a fase de teste e 87,50% para a fase de validação da rede.

Na pesquisa de PAIVA (2014), foi construído um modelo de compra e venda de ações do mercado brasileiro com gatilhos baseados em previsões de RNAs. Uma combinação de 50 redes neurais diferentes foram estruturadas em uma matriz, na qual o número de neurônios e o banco de dados de entrada foram alterados. O banco de dados utilizado contém informações obtidas de indicadores técnicos. Finalmente, em uma das simulações do teste, o modelo atingiu uma rentabilidade superior a 70%.

Um sistema de negociação de ativos foi desenvolvido por JAMES (2015) com uso de sinais de operação baseados na previsão de redes neurais do tipo KABAN Cell. Este trabalho avalia 49 dias de negociação, alcançando até 67% em termos de retorno de investimento anuais.

O trabalho de NAMETALA (2017) apresenta uma estratégia de negociação automatizada (*algotrading*) que combina previsões feitas por redes neurais artificiais e preditores econométricos por meio de seletores inteligentes e comitês de decisão diversos que, progressivamente no tempo, são otimizados gerando cenários lucrativos. Foi desenvolvida uma metodologia para seleção de ações que possuam histórico de alta liquidez e, aliado a isso, um algoritmo negociador que possui gestão de risco também otimizada temporalmente. Todos os dados das séries que serviram de base à pesquisa são reais. Contudo, o processo de negociação foi feito com capital simulado. Nos experimentos realizados o robô investidor utilizou um histórico de 3 anos para gerar estratégias de investimento aplicadas a dez ações de companhias nacionais e ao índice Bovespa simultaneamente. Em pregões ocorridos entre 2012 e 2013 foram obtidos resultados estatisticamente significantes tanto para taxa de

acerto quanto para rendimento financeiro frente a todos os *benchmarks* utilizados, mesmo considerando-se custos de corretagem. Propõe ainda uma combinação de técnicas que modelam a volatilidade dos retornos e que, para encontrar parametrizações ótimas nos métodos, tomam por mecanismo principal técnicas clássicas de inteligência artificial e otimização.

CORREA (2017) propõe a validação de estratégias de *algorithmic trading* (*algo-trading*), baseadas na combinação de RNAs. Foram utilizados diferentes conjuntos de entrada de treinamento como preço, volume e indicadores técnicos. O estudo consistiu principalmente no estudo das Redes Neurais *Feedforward*, *Cascade Forward* e *Elman*. As redes foram combinadas com 10 algoritmos de treinamento diferentes, oferecendo uma avaliação de 30 redes neurais. Um ranking foi gerado mês a mês, que encontrava os 5 melhores classificadores. Com base nas melhores RNAs do mês foram construídas três estratégias de operação as quais, deveriam combinar com o sinal de operação 3 ou mais RNAs, 4 ou mais RNAs ou as 5 RNAs. Um estudo estatístico avaliando algumas variações de *stops loss* também foi construído. As estratégias foram analisadas para diferentes ações de diferentes setores da BM&FBovespa (VALE5, ITUB4, BOVA11 e CIEL3).

Os trabalhos referenciados anteriormente são similares a este no que tange à utilização de RNAs para construir previsões em séries no mercado de capitais. Entretanto, esta pesquisa segue na direção de melhorar a estratégia de investimento com base em um conjunto de previsões de RNA do tipo ELM, as quais, por serem recentes, apresentam poucos estudos aplicados em finanças. Adotando o *ensemble* de redes neurais ELM específico para apresentar previsões de tendência nos preços e volume podem se mostrar mais eficientes para reduzir a incerteza, melhorando a relação de riscos e retorno de investimentos em estratégias de operações automatizadas.

3 Fundamentação Teórica

Este capítulo está organizado em três seções principais, que apresentarão um referencial teórico de trabalhos para contextualizar primeiramente as estratégias de investimento, posteriormente, as redes neurais artificiais e, finalmente, a análise técnica e financeira automatizada de ativos no mercado de capitais.

3.1 Estratégia Automatizada de Investimento

O investimento é definido como o comprometimento de recursos presentes com a expectativa de se obter preferencialmente ganhos futuros de forma inseparável de perdas igualmente prováveis (XAVIER, 2017). A estratégia de investimento no contexto de finanças computacionais pode ser considerada a arte de se aplicar os recursos disponíveis (capital), em condições favoráveis, com eficácia para atingir o objetivo de otimização do rendimento financeiro e a contenção do risco inerente às operações financeiras.

Uma Estratégia de Investimento Automatizada é uma Estratégia de Investimento que é executada de forma automática, por um Robô Investidor, sem a necessidade de nenhum tipo de intervenção humana.

O intuito de um Robô Investidor é executar, com total fidelidade, a Estratégia de Investimento para qual ele foi programado. Dessa forma, o Robô assume os papéis de tomada de decisão e de operacionalização da Estratégia, retirando do investidor a obrigação de acompanhamento do mercado e a responsabilidade de efetivação das negociações dos papeis.

Um algoritmo é uma sequência de instruções objetivas que podem ser escritas em uma linguagem de programação para serem interpretadas por um computador, permitindo assim a execução das tarefas descritas em tais instruções de forma automática.

Algotrading é a sigla para *Algorithmic Trading*, em Português: negociação algorítmica. *Algotrading* pode ser considerado como o uso de Plataformas de Negociação eletrônicas para negociar em Bolsa de Valores executando ordens de forma automática baseadas em algoritmos. Outra nomenclatura comumente utilizadas para se referir aos robôs investidores é *Algoritimic Trading System* (ATS).

3.1.1 Portfólio

Gestão do portfólio preocupa-se principalmente com o(s) ativo(s) nos quais ocorrerão as operações e no balanceamento da distribuição do capital disponível entre estes ativos.

A gestão de portfólio para investidores racionais se preocupa em utilizar o princípio da diversificação para otimizar a carteira de investimento. A otimização pode ser multi-objetivo, buscando tanto a maximização dos retornos quanto a redução dos riscos.

3.1.2 Gestão do Capital

O gerenciamento do capital é o processo de orçamentação, poupança, investimento, gasto ou supervisão do uso de capital. Tratar-se-á aqui, no contexto de aplicações em ativos financeiros, basicamente do quanto de capital será destinado a cada operação ativo, ou cada posição (*trade*). Também está altamente relacionado com a sua gestão de portfólio e o gerenciamento de risco. Podem existir Estratégias com entradas ou saídas parciais, considerando investir parcialmente e não a totalidade do capital. Quando a previsão indica que a tendência para o próximo período permanece, realiza-se novas compras no mesmo ativo, o que também é conhecido no mercado financeiro como "aumentar a mão". Este é um exemplo de gestão do capital.

3.1.3 Tipos de Estratégias de operação

Para investimentos de compra e venda de ações na bolsa de valores o prazo com que se termina uma operação caracteriza o tipo de investidor. Assim, a janela de tempo utilizada para a duração das operações carateriza a operação (XAVIER, 2017), que é costumeiramente descrita pelos seguintes termos:

- *Intraday*: quando a operação é concretizada inteiramente no intervalo de tempo de um pregão;
- *Swing Trade*: por exemplo, compra e venda de ações em, no máximo 3 a 5 dias;
- *Position Trade*: compra e venda de ações em um intervalo que pode durar algumas semanas;

Em geral, o termo investidor é utilizado para designar indivíduos que realizam operações em intervalos de tempo superiores a um ano. No contexto apresentado por (XAVIER, 2017) as operações curtas são executadas por especuladores. E especulação significa aposta no futuro, na esperança de retorno compatível com o tempo de uso do dinheiro abdicado no negócio.

3.1.4 Gestão do Risco

No contexto de investimento, o risco (R) pode ser considerado a medida do grau de incerteza no retorno de um investimento (XAVIER, 2017). Quando a incerteza é baixa, o retorno é quase certo (embora pequeno) e o risco é baixo. Ao contrário, quando a incerteza é alta, o retorno é incerto e o risco é consequentemente mais alto.

Os investidores investem com expectativa de obter risco futuro, mas estes retornos raramente podem ser previstos com precisão. Quase sempre haverá um risco inerente ao investimento (BODIE; KANE; MARCUS, 2012). Mostrando que existe um *trade-off* entre o risco e retorno.

Este *trade-off* é exposto por (XAVIER, 2017) como a lei fundamenta de retorno como função do risco, definindo que o Retorno de um investimento (I), qualquer que seja ele, é diretamente proporcional ao Risco (R).

O Modelo de precificação de ativos financeiros (CAPM) confirma essa ideia, postulando que o prêmio de risco do título é diretamente proporcional tanto ao *beta* (risco do título) quanto ao prêmio de risco da carteira de mercado (BODIE; KANE; MARCUS, 2012). A teoria de Markowitz e o Modelo CAPM de Sharpe explicam a construção de carteiras eficientes de ativos, embora o modelo *Arbitrage Pricing Theory* (APT) ao invés de verificar se uma carteira é eficiente, presume que o retorno de cada título depende, em parte de fatores macroeconômicos e, em parte, de eventos peculiares em cada empresa (TOSTES, 2007).

É comum colocar em estratégias de investimento automatizadas um *stop loss*. Trata-se de um recurso que está estritamente associada à contenção do risco de perda de capital. Assim, a amplitude definida para o *stop loss* é fator determinante para que a estratégia seja bem sucedida. Se o mercado estiver em alta, amplitudes maiores do limite do *stop loss* podem ser utilizadas, pois a probabilidade de se atingi-lo são menores, embora as reduções no risco incorram diretamente na redução dos ganhos (XAVIER, 2017).

3.1.5 Otimização da Estratégia

Pode existir uma quantidade muito grande de parâmetros envolvidos na configuração de uma estratégia. Como a combinação das suas possibilidades de configuração tende ao infinito, torna-se um problema de otimização combinatória que normalmente é tratado em pesquisas específicas. Este conjunto de configurações é chamado de *setup* de uma estratégia. Aqui será feito apenas uma breve apresentação do funcionamento da otimização da estratégia e será colocada como sugestão de trabalhos futuros.

Alguns trabalhos recentes tem adotado Algoritmos Genéticos para realizar este tipo de otimização da estratégia em tempo hábil para aplicação da estratégia em tempo real. O Software MetaTrader 5[1] oferece uma funcionalidade de realizar este tipo de otimização com algoritmo genético.

[1] https://www.metatrader5.com/

3.2 Redes Neurais Artificiais

Um sistema projetado para prever um comportamento dos preços no mercado de ações deve ter a capacidade de se adaptar quando as condições mudam de um súbito crescimento a quedas drásticas (RUSSELL et al., 2003).

As RNAs são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (BRAGA, 2007). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e serve para ponderar a entrada recebida por cada neurônio da rede.

As RNAs têm características intrínsecas interessantes de universalidade nas aproximações de funções, robustez e tolerância a falhas. Por estas razões, elas são consideradas úteis para construir modelos de previsão em séries temporais não-estacionárias, conforme explicado por NETO et al. (2010). Além disso, a RNA trata bem os dados de ruído e é capaz de prever sistemas não-lineares como as séries temporais do mercado de capitais.

3.2.1 Arquitetura de uma RNA

Conforme apresentado por BRAGA (2007), os neurônios artificiais são unidades de processamento simples de uma rede neural artificial. Conexões entre neurônios possuem pesos associados que são ponderados à entrada recebida através de uma função matemática. A saída da função é a resposta do neurônio para a entrada apresentada a rede. De acordo com FERNEDA (2006) os pesos simulam o comportamento das conexões e assim podem assumir valores positivos (comportamento excitatório) ou negativos (comportamento inibitório) e ainda zero, caso não exista conexão.

Uma função de ativação avalia o resultado obtido de acordo com os limites definidos e valida o teste, para depois calcular as saídas desejadas (MARANGONI et al., 2010). Existem três principais tipos dessas funções: linear, limiar e sigmoidal. A primeira é frequentemente utilizada para aproximação linear. Já na segunda, o valor do limiar define quando o resultado da função será igual a 0 ou 1, sendo mais utilizada para problemas de classificação e reconhecimento de padrões. A última função é comumente utilizada em redes com retropropagação (KRIESEL, 2007).

A topologia de uma rede neural artificial é definida pelo número de camadas, grau de conectividade entre os neurônios e a presença de retropropagação (FERNEDA, 2006). A escolha da arquitetura da rede é o fator determinante no desempenho da RNA (MARANGONI et al., 2010).

Quando os neurônios estão em duas ou mais camadas, a RNA é chamada de

rede multicamadas (OLIVEIRA et al., 2010). Neste tipo de rede, pode-se ocorrer diferentes tipos de conexões, entre as camadas de neurônios. Além disso, as redes podem possuir conexões de retroalimentação ou *feedback*, nas quais o neurônio pode receber a saída de outros da mesma camada (ou posteriores) ou de si próprio (FERNEDA, 2006). Essas redes são importantes quando precisa-se processar informações sequenciais e em simulações de sistemas dinâmicos. Redes sem retropropagação são chamadas de *feedforward*.

3.2.2 Aprendizado Automático

Em RNAs o procedimento na solução de um dado problema passa, inicialmente, por uma fase de aprendizagem, na qual um conjunto de dados é apresentado à rede e essa retira as características necessárias para representar a informação fornecida (BRAGA, 2007). As redes aprendem a partir de experiências e não através de programação, por este motivo, o conjunto de treinamento deve ser obtido a partir de dados históricos, ou experiências e fatos ocorridos no passado (MELLO, 2005). Dessa forma, a RNA é capaz de oferecer respostas coerentes para dados não conhecidos.

Os algoritmos de treinamento, que definem quando e como deve ser alterado o valor de cada peso, podem seguir os seguintes paradigmas: supervisionado e não supervisionado. No primeiro caso é usado um agente externo que indica uma resposta desejada e o ajuste dos pesos ocorre na comparação entre saída e a resposta definida. Já o segundo, a rede utiliza os neurônios como classificadores e a entrada é classificada mediante um critério de semelhança (BRAGA, 2007).

Dois conceitos importantes em treinamento são convergência e generalização. O primeiro relaciona-se ao aprendizado em reconhecer padrões. Este fator é importante, pois se a rede não aprendeu as relações existentes, significa que não convergiu e não atingirá bons resultados. Já o segundo tema, trata sobre reconhecimento de padrões não existentes nos dados de treinamento e assim identificar valores fora do padrão.

3.2.3 Redes FeedForward

As redes *feedforward* formam a base para muitas redes neurais e vem sendo utilizadas até hoje em vários estudos, tais como Redes Neurais Convolucionais (CNN), usadas extensivamente em Visão Computacional, Redes Neurais Recorrentes, amplamente utilizadas no processamento de linguagem natural, entre outras.

Para (KRIESEL, 2007), a saída de uma rede *feedforward*, para qualquer entrada, é calculada passando o sinal, a partir da camada de entrada até a camada de saída, somente uma vez, ou seja, cada neurônio em uma camada possui conexão direta, somente, com os neurônios da próxima camada.

Segundo (LIMA, 2014), esse tipo de RNA pode ser construída com uma ou mais

camadas e ele ainda corrobora o conceito acima citado, dizendo que essas redes são alimentadas adiante: a saída de um neurônio é a entrada do seguinte e a saída da rede é o mesmo que a saída da última camada. As redes *feedforward* de duas camadas pode aprender virtualmente qualquer relação de entrada e saída, quando possuem mais camadas pode aprender relacionamentos complexos mais rapidamente.

São dois tipos principais de abordagem para problemas de aprendizado máquina, a Classificação e a Regressão. A Classificação é um método de aprendizado supervisionado no qual a tarefa consiste em dividir os dados em classes predefinidas. Pode ser um problema de classificação binário, onde existem apenas duas classes, como o apresentado neste trabalho, ou muti-classe, onde existem várias classes.

3.2.4 Redes ELM

A utilização de métodos gradiente descendente são amplamente utilizados em algoritmos de treinamento como o *Backpropagation* (BP) com o objetivo de ajustar os pesos da rede neural. A questão é que este tipo de técnica de ajuste consome muito tempo no processo de treinamento da rede, devido ao ajuste iterativo dos parâmetros.

Quando a taxa de aprendizado é muito pequena, o algoritmo converge muito lentamente e quando a taxa é alta a rede se torna instável e pode divergir, encontrando um mínimo local distante do mínimo global.

A utilização do BP pode causar *overfitting*, redes super treinada que funcionam apenas para um conjunto específico de dados prejudicando a generalização.

A Extreme Machine Learning (ELM) foi desenvolvida com intuito de preencher estas lacunas apresentadas nos algoritmos baseados em gradiente descendente como o BP. Foi criada inicialmente apenas com duas camadas, a camada de entrada e a camada escondida, embora já existam implementações com mais camadas. Os pesos das camadas de entrada e os bias da camada escondida são escolhidos aleatoriamente. Os pesos da camada de saída são determinados analiticamente, ou seja, não há ciclos iterativos para ajuste dos parâmetros (HUANG; ZHU; SIEW, 2006).

Existem muitos tipo de *Single Layer Feedforward Neural Networks* (SLFNs), incluindo redes *feedforward*, redes RBF, SVM (considerada um tipo especial de SLFNs), redes polinomiais, Séries de Fourier, wavelet, dentre outras. A ELM preenche a lacuna entre as SLFNs ao propor que elas não precisem ter diferentes algoritmos de aprendizado para diferentes SLFNs se forem consideradas a aproximação universal e as capacidades de classificação (HINTON; SALAKHUTDINOV, 2006).

A ELM preenche a lacuna entre diferentes teorias de aprendizado. A teoria da regressão de Ridge (HOERL; KENNARD, 1970), a estabilidade do sistema linear, a estabilidade da matriz, a teoria do desempenho da generalização da rede neural (BARTLETT, 1998)

e a margem máxima do SVM, geralmente eram consideradas diferentes antes do ELM. A ELM adota a teoria de Bartlett para garantir sua performance de generalização. As teorias e a filosofia de ELM mostram que essas teorias anteriores são realmente consistentes no aprendizado de máquinas (HUANG; ZHU; SIEW, 2006).

Segundo (AKUSOK et al., 2015), a técnica emergente *Extreme Learning Machines* (ELMs) consegue abordar o problema aberto que confunde as redes neurais, o aprendizado de máquina e a neurociência há 60 anos, que é identificar se os neurônios da camada escondida precisam ser realmente ajustados no aprendizado. Mais que isso provar esta descoberta que está em contraste com o conhecimento comum e convencional dos princípios de aprendizado em redes neurais. Os neurônios da camada escondida não precisam ser iterativamente ajustados na maioria dos tipos de rede neural e modelos de aprendizado (Séries *Fourier*, *biological learning*, dentre outros). A Teoria da ELM propõe uma rede neural *feedforward* com nós escondidos randômicos.

3.2.5 Vantagens e Desvantagens

Uma rede neural artificial é formada por diversos elementos processadores simples, os quais têm a plena capacidade de executar uma função de caráter simples. Porém, a importância da RNA é dada principalmente por causa de sua capacidade computacional para a resolução de problemas matemáticos de elevado grau de complexidade e solução (CARVALHO; AMAZONAS, 2010).

As RNAs podem ter neurônios lineares ou não lineares. Quando possuem no mínimo um neurônio não-linear, a rede é classificada como não-linear. Esta propriedade é bastante útil para problemas como a predição no mercado financeiro, pois este é não-linear (POMMERANZENBAUM, 2014).

Para CALÔBA (2000) o funcionamento das redes é muito robusto. Pois, como o conjunto de neurônios e sinapses é grande, quando há ausência de algumas sinapses, ou de alguns neurônios, distorções nos dados de entrada e até mesmo a falta de algum dado, o funcionamento da rede não é comprometido. A RNA não pára de funcionar por isso, agindo assim, diferente de um algoritmo comum. Isso é corroborado por CARVALHO; AMAZONAS (2010), que explica: a forma como as respostas para certos problemas são representadas internamente na RNA e o paralelismo natural inerente das conexões criam a possibilidade de um desempenho superior aos métodos tradicionais.

As Redes Neurais Artificiais possuem capacidade natural de adaptação dos pesos de seus neurônios de acordo com modificações no ambiente, dessa forma, podem ser facilmente retreinadas. Em adicional, as RNAs são capazes de generalizar, mesmo em situações com a presença de ruído (HAYKIN, 2001).

Várias características de RNAs são interessantes para predição de séries temporais.

Como já foi dito, sua capacidade de abordar o problema em busca de padrões não-lineares oferece vantagem nessa área. Ademais, as redes neurais são capazes de identificar padrões de ordem superior à linear ou estrutura subjacente dentro de uma série temporal, mesmo quando a lei de formação que a rege seja desconhecida ou complexa demais para descrever (POMMERANZENBAUM, 2014).

O que torna as redes atrativas para utilizá-las como apoio sobre o mercado financeiro, é sua capacidade de capturar relações, mesmo quando essas são desconhecidas ou difícil de descrever, ou seja, as redes neurais possuem boa performance para problemas cujo as soluções requerem conhecimento para aquilo que é difícil de especificar, entretanto existindo dados o suficiente para observar. O autor ainda afirma que utilizar esta técnica para analisar o mercado financeiro é muito importante de forma a obter resultados mais satisfatórios para possíveis decisões ou metas de investidores, como minimizar riscos e maximizar lucros. (CARVALHO; AMAZONAS, 2010).

Para BRAGA (2007), sem dúvidas, a capacidade das RNAs de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal da solução de problemas através da utilização dessa técnica.

Conforme POMMERANZENBAUM (2014), a principal desvantagem é a inviabilidade de se criar um método perfeito para qualquer aplicação, já que para todo modelo existe uma amostra de dados em que a RNA apresentará resultados ruins.

LIMA (2014) aponta diversas desvantagens das Redes Neurais Artificiais como: o treino da RNA pode demorar muito, algumas vezes elas podem alcançar respostas que contrariam teorias já estabelecidas, podem considerar dados irrelevantes como importantes e básicos, é difícil compreender o que a RNA aprendeu por causa da forma implícita como os dados são armazenados, é necessário uma base de dados grande para um bom desempenho e além disso, essas informações podem necessitar de tratamento, como normalização, para que a rede faça o aprendizado corretamente.

3.3 Análise Técnica

Embora existam várias escolas de análise de mercado, como Análise Técnica e Análise fundamentalista e outras mais recentes como *tape reading*, este estudo focará na utilização de análise técnica pois é nela que serão extraídos dados e informações necessárias para o treinamento das redes neurais deste trabalho.

A análise técnica pode ser definida como o estudo da ação do mercado, primariamente por meio de uso de gráficos, com o objetivo de prever comportamento ou tendências futuras (LEMOS, 2015). Assim, são utilizados ferramentas como indicadores para interpretação das ações do mercado. Os Indicadores são fórmulas matemáticas utilizadas para

alertar que um comportamento tem probabilidade de ocorrer, **confirmar** as informações fornecidas por outros indicadores ou mesmo **prever** um comportamento futuro de uma série histórica do ativo.

A análise técnica se baseia no trabalho de Dow, no qual alguns de seus princípios são elencados a seguir (EDWARDS; BASSETTI; MAGEE, 2012):

1. As médias descontam tudo: Porque elas refletem as atividades de investidores, incluindo aqueles possuidores de grandes previsões e melhores informações nas tendências dos eventos;
2. O preço se move em Tendências: O preço das ações se move em tendências, nas quais a mais importante é tendência Primária, de longo prazo. A segunda tendência são as correções que podem ocorrem em sentido contrário ao movimento primário. E a terceira é compostas por tendências menores de curto prazo, dia a dia.
3. A história se repete: Os estudos apresentados por Dow consistem na crença de que os padrões identificados nas tendências e nas médias se repetem ao longo do tempo.

Para medir o mercado, Dow construiu 2 índices, a Média industrial (Dow Jones) composta na época por 12 ações e uma combinação de 20 ações de companhias ferroviárias, que ficou conhecida como média ferroviária. Seu objetivo era identificar tendências de longo prazo nos preços das ações. Embora alguns analistas atualmente considerem a teoria ultrapassada ela é muito utilizada nos dias atuais (SACHETIM, 2006).

Para os analistas técnicos, as diversas variáveis fundamentais, políticas, psicológicas ou de qualquer outra ordem estão refletidas nos preços de mercado, por isso dizer que o preço refletem todos os fatores envolvidos no mercado.

O propósito de representar a ação dos preços em um gráfico é identificar tendências. Uma tendência em vigência teria maior probabilidade de permanecer em vigência que de reverter (LEMOS, 2015). Assim, para Dow sinais poderiam ser percebidos no comportamento dos preços e volume antes que ocorresse a reversão.

Os indicadores da análise técnicas são utilizados para identificar padrões de comportamento dos preços e aplicá-los, acreditando-se que eles se repetirão no futuro, ao contrário do que explica (SORNETTE, 2004) com a Teoria do Mercado Eficiente, em que os preços seguiriam o comportamento aleatório como o *Random Walk*.

Um indicador técnico é uma série de dados que são derivados pela aplicação de uma fórmula para os dados referentes a um título. Os dados utilizados em indicadores são preços de abertura, máxima, mínima e fechamento e ainda podem conter informações de volume ou contratos em aberto em suas fórmulas. Existem vários tipos de classificações de indicadores, será adotada a taxonomia não exaustiva encontrada em (LEMOS, 2015), e explicada nas sessões subsequentes:

- Indicadores de Tendência;

- Indicadores de Momento (Osciladores);
- Indicadores de Volatilidade;
- Indicadores de Volume (Força de Mercado).

3.3.1 Indicadores de Tendência

A tendência é um valor central ou valor típico para uma distribuição de probabilidade (SILVA, 2009). A tendência dos preços no mercado de ações é verificada por meio do histórico de preços no período. Pode-se verificar a tendência de alta por exemplo pela média aritmética do histórico de preços do ativo quando ela é positiva.

Os rastreadores de tendência são confiáveis durante períodos de tendência, não captam nem o começo nem o fim das tendências perdendo, em média, um terço do comprimento total das tendências (SACHETIM, 2006).

Indicadores de tendência são ferramentas utilizadas para identificar movimentos dos preços (alta ou baixa). Alguns exemplos são:

- *Adaptative Moving Average*;
- Índice de Movimento Direcional;
- Índice de Movimento Direcional Willian;
- Média Móvel Exponencial;
- Média Móvel;
- Média Móvel Adaptativa Fractal;
- SAR Parabólico;

As médias móveis consideram os preços de períodos anteriores para suavizar os movimentos dos preços atuais, para assim apontar um movimento menos volátil no comportamento dos ativos. As médias móveis são *lagging indicators* (indicadores atrasados), ou seja, consideram um histórico de preços. Seguem a tendência com perfeição mas não são indicadores rápidos. Seu uso é ideal para mercados em forte tendência, porém podem ser bastante limitados e dar falsos sinais quando o mercado opera sem uma tendência definida ou em tendência lateral, ou mesmo quando está próximo de uma reversão, conforme descrito (SACHETIM, 2006).

3.3.2 Indicadores de Momento - Osciladores

Um oscilador é um indicador que flutua acima e abaixo do centro, ou entre níveis preestabelecidos - por exemplo 0-100% (SACHETIM, 2006). Podem permanecer em níveis extremos (sobrecomprado ou sobrevendido). Tem a característica de não sustentarem a mesma tendência por um longo período, por isso são denominados osciladores.

A categoria de indicadores de momento, também classificada por osciladores são mais rápidos que os de tendência e são adotados frequentemente para verificar se é um

bom momento para entrar na operação (comprado ou vendido), ou seja, se a tendência está começando ou terminando.

Indicadores de momento fornecem pontos ou momentos de entrada e saída da operação. Exemplos:

- *Avarege True Range*;
- Poder Compradores (Bulls Power);
- Poder Vendedores (Bears Power);
- Commodity Channel Index (CCI) - é baseado na suposição que o preço da ação se move através de ciclos, com altas e baixas se sucedendo através de intervalos regulares;
- Moving Average Convergence / Divergence (MACD) - Convergência e Divergência de Médias Móveis;
- Momentum - Mede em porcentagem a variação entre o preço hoje e o preço em determinado período n dias atrás;
- Índice de Força Relativa (IFR);
- Estocástico Lento e Rápido (%K, %D);

3.3.3 Indicadores de Volatilidade

A Volatilidade é uma medida de dispersão dos preços de uma ação. Pode ser medida pela diferença entre o maior e o menor preço em um período, ou o grau médio de variação das cotações em um período, ou ainda pela variância. A variância expressa o quão longe em geral os seus valores se encontram do valor esperado. Serve para medir a intensidade e a frequência das oscilações nas cotações. A volatilidade pode ser utilizada como uma medida do risco.

As empresas e os mercados passam por épocas turbulentas com mais incertezas e por momentos de maior certeza. Estes fatores afetam as oscilações do preço das ações de modo que há períodos onde os preços podem variar 10%, enquanto há períodos onde o preço pode oscilar 1%.

O indicadores de análise técnica que consideram essas oscilações estão na categoria dos indicadores de volatilidade. Eles ajudam o investidor da análise técnica a determinar o que esperar no comportamento dos preços de determinada ação com base no comportamento recente. São comumente utilizados para auxiliar a identificar quais movimentos estão fora do padrão normal e até definir em qual valor um *stop-loss* deve ser posicionado.

Alguns exemplos de indicadores de volatilidade são:

- Bandas de Bollinger;
- Amplitude de Variação (ATR);
- Canais de Keltner;

- Canais de Preço.

3.3.4 Indicadores de Volume (Força de Mercado)

O Volume de negociações ou de capital investido evidencia a força do mercado. É utilizado para medir a força compradora (*bulls power*) ou a força vendedora (*bears power*).

Quando existem variações de preço com volume crescente de negociações e capital investido é sinal de consistência na variação do preço naquele sentido. Isso faz com que a reversão da tendência do preço seja mais difícil de ocorrer.

O preço de uma ação pode variar acima de 10% em um dia, porém, se o volume não for significativo, esta alteração no valor pode ser decorrente de alguma operação pontual e não por uma real alteração na percepção de valor da empresa. Estes indicadores São especialmente utilizados para identificar se a alteração do preço é relevante. Assim, alterações no preço com volume significativo são mais difíceis de serem revertidas.

Os indicadores de análise técnica nesta categoria buscam avaliar a quantidade de dinheiro que entra ou sai de uma ação, medindo a força compradora e vendedora.

- Acumulação/Distribuição(ADL);
- Money Flow index (MFI);
- On Balance Volume (OBV);

Existem vários outros tipos de indicadores no mercado financeiro. Existem ainda outras categorias de indicadores que não farão parte desta pesquisa, como por exemplo os indicadores de fôlego de mercado, onde uma fórmula é aplicada aos dados de preços e volume de vários ativos. Outra categoria de indicadores fora deste escopo são os indicadores de sentimentos, que são indicadores psicológicos que tentam medir o grau de otimismo ou pessimismo em um mercado.

4 Metodologia

O objetivo desta pesquisa foi criar uma estratégia de operação automática e computacionalmente inteligente com capacidade de emitir sinais de comportamentos futuros para identificação de bons momentos de operação no mercado financeiro.

A inteligência da ferramenta proposta foi baseada no aprendizado de máquina extraído de um conjunto de RNAs que reconhecem padrões de comportamento nos dados históricos de preço, volume e indicadores técnicos. Além disso, procurou-se avaliar os impactos da estratégia de *ensemble* nos resultados de retorno e risco financeiro.

Este capítulo está organizado em três seções. Na Seção 4.1 está o delineamento da pesquisa com uma visão geral do esquema metodológico. A Seção 4.2 contém os detalhes da construção do modelo de previsão enquanto a Seção 4.3 contempla a construção das estratégias de negociação baseadas nas previsões do modelo.

4.1 Delineamento da pesquisa

Uma visão geral da metodologia experimental que exibe as fases desta pesquisa é exibido na Figura 5. O trabalho consiste em duas partes principais. A primeira trata da criação do Modelo de RNAs para realizar as previsões, que contém 4 fases. A segunda constrói as Estratégias de Negociação, realiza o *backtesting* e mostra os resultados e análises.

Figura 5 – Esquema Metodológico - Modelo e Estratégia

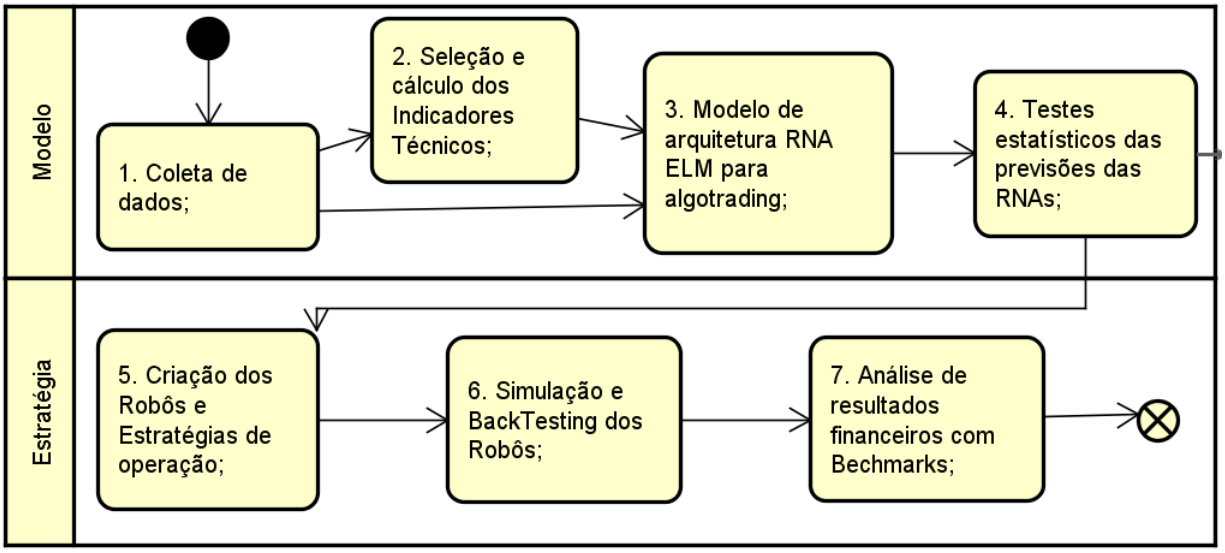

Fonte: Criada pelo autor com uso do Software Astah Community

4.2 Modelo

4.2.1 Coleta de Dados

Na fase inicial de coleta de dados foram selecionados os ativos VALE3, PETR4, ITUB4, BOVA11. Os três primeiros são, frequentemente, os ativos mais líquidos do mercado brasileiro. Esta alta liquidez pode reduzir, mas não eliminar, os problemas relacionados com *slippage* decorrentes da execução simulada de ordens. Já o ativo BOVA11 é um fundo de índice com comportamento similar o IBOVESPA, principal índice da [B]^3.

Além disso, os ativos VALE3, PETR4 e ITUB4 são classificados pela [B]^3 [1] com Nível 1 de Governança Corporativa. As empresas listadas no Nível 1 devem adotar práticas que favoreçam a transparência e o acesso às informações pelos investidores. Assim, divulgam informações adicionais às exigidas em lei, como por exemplo, um calendário anual de eventos corporativos. Outra prática exigida é o *free float* mínimo de 25%, ou seja, a empresa se compromete a manter no mínimo 25% das ações em circulação no mercado.

Para os ativos selecionados definiu-se o período em que serão avaliados o comportamento dos ativos. Neste caso, selecionou-se o período entre 01 de janeiro de 2017 e 31 de dezembro de 2017. Isso torna possível aos algoritmos de aprendizagem identificar padrões sazonais diários, semanais ou mensais de acordo com a janela de tempo aplicada às RNAs e adequados às necessidade de operações de curto prazo.

As periodicidades ou granularidades coletadas para execução do experimento em cada ativo foram: 1 minuto (M1), 5 minutos (M5), 15 minutos (M15), 30 minutos (M30), 1 hora (H1), 4 horas (H4) e 1 dia (D1). Assim, os dados de preço de abertura, fechamento, máximo e mínimo, formam um *candle* para cada uma destas periodicidades. Além dos volumes e os indicadores técnicos calculados no mesmo intervalo de tempo. No decorrer do experimento, principalmente após a caracterização dos dados, foram selecionadas as periodicidades de operação mais adequadas para as estratégias aqui apresentadas.

Estas periodicidades são adequadas para simulação de estratégias de operação do tipo *Day Trade* e *Swing Trade*, ou seja, estratégias de curta duração e seguidoras de tendências curtas. Porém, precisariam ser revalidadas para estratégias do tipo *High Frequency Trade* (HFT), diferenciando-se, neste ponto, da pesquisa de SILVA et al. (2015), ou mesmo em estratégias de longo prazo (*Long Positions*), como no trabalho de OLIVEIRA; NOBRE; ZARATE (2013).

Foi criado um código na plataforma MetaTrader 5 que exporta para cada um dos ativos selecionados, em cada uma das periodicidades, os dados de preço de abertura (*open*), fechamento (*close*), máxima (*high*) e mínima (*low*), o volume real monetário movimentado

[1] http://www.bmfbovespa.com.br/pt_br/produtos/listados-a-vista-e-derivativos/renda-variavel/acoes/classificacao-setorial/ acessado em 12/2016.

(R$), o volume em número de negócio realizado e os indicadores da análise técnica selecionados.

4.2.2 Seleção e Cálculo de Indicadores

Na segunda fase da pesquisa foi escolhido um indicador de Análise Técnica para cada categoria elencado na Seção 3.3 com intuito de serem utilizados como entrada para o treinamento de cada RNA. Sendo definidos os seguintes indicadores:

1. Categoria Tendência - *Moving Average Convergence* / *Divergence* (MACD);
2. Categoria Momento - *Relative Strength Index* (RSI);
3. Categoria Volume - *On Balance Volume* (OBV);
4. Categoria Volatilidade - *Bollinger Bands*;

Os indicadores MACD e RSI foram analisados no trabalho de CHONG; NG (2008) para verificar se estas regras eram lucrativas. Usando 60 anos de dados do índice - *London Stock Exchange FT30 Index*, da bolsa de Londres. Concluiu-se que tanto o RSI quanto o MACD podem gerar retornos maiores que as estratégias *Buy and Hold* na maioria dos casos.

No estudo de SACHETIM (2006), apesar da conclusão de que um único indicador de análise técnica não possa oferecer ao investidor ganhos anormais que superem os custos de transação e a estratégia *Buy and Hold*, corroborando a Hipótese do Mercado Eficiente, houve indicação de uso dos indicadores IFR (RSI) e MACD em suas operações de mercado. A utilização de um em detrimento de outro é facultativo ao investidor e dependerá da estratégia de investimento e da aversão ao risco de cada operador.

O cálculo da linha MACD é formada pela diferença entre duas médias móveis exponenciais (MME), sendo uma de longo prazo, com mais períodos considerados na janela temporal, e outra de curto prazo, com menos períodos considerados (CHONG; NG, 2008). A linha MACD aplicada a esta pesquisa é gerada subtraindo-se a MME lenta da MME rápida em um instante t de tempo, que é o mesmo da periodicidade, conforme indicado na Fórmula 2. Os preços de fechamento de cada período são utilizados para o cálculo das médias móveis.

$$\begin{aligned} MME_{[n]} &= [Preco_{(atual)} - MME_{(anterior)}] \times K + MME_{(anterior)} \\ K &= \frac{2}{n+1} \end{aligned} \tag{1}$$

onde:
n = número de períodos; k

$$MACD = MME_{[26]} - MME_{[12]} \tag{2}$$

O Índice de Força Relativa (IFR) ou, do inglês, *Relative Strenght Index* (RSI) é calculado conforme Equação 3, desenvolvida por WILDER (1978). Foi aplicado o RSI no experimento de KANNAN et al. (2010), no qual foram analisados 400 sinais gerados pelo indicador, com retorno de 56,04% .

$$RSI = 100 - \left(\frac{100}{1 + \frac{U}{D}} \right) \tag{3}$$

Onde:
U = Média de altas no período;
D = Média de baixas no período;

A conclusão a que chegou ŻBIKOWSKI (2015) em seu estudo foi que a ampliação da amostra de treinamento combinada com a seleção de características e a incorporação do volume à função de penalidade SVM resultam em uma melhoria significativa do desempenho da estratégia de operação proposta. Assim, torna-se importante a utilização de volumes e indicadores de volume que corroborem a decisão no processo de construção das estratégias de operação automatizadas.

O OBV soma o volume negociado nos períodos de alta e subtrai o volume negociado nos períodos de baixa, o que resulta no saldo de Volume (ŻBIKOWSKI, 2015). O volume negociado no último período é somado ao volume acumulado quando o fechamento é superior a abertura ou subtraído quando o fechamento é inferior à abertura, conforme apresentado no Algoritmo 1.

O indicador OBV também foi utilizado como entrada para uma rede SVM no experimento de (CAO; TAY, 2001). O OBV move na mesma direção do preço, relacionando assim o volume com o preço.

Algoritmo 1: Cálculo do On Balance Volume (OBV)

if *(preço fechamento > preço abertura)* **then**
    OBV (atual) = OBV (anterior) + Volume ;
if *(preço fechamento < preço abertura)* **then**
    OBV (atual) = OBV (anterior) - Volume ;

A fórmula do OBV relaciona o volume com o movimento do preço no período, determinando a força da pressão compradora e da pressão vendedora no preço da ação. Este indicador é comumente utilizado para medir a força de uma tendência ou sinalizar reversões.

As Bandas de Bollinger (BB) são duas linhas calculadas somando-se ou subtraindo-se 2 desvios padrão de uma média móvel simples ou aritmética (MMS). O principal objetivo da MMS é fornecer o valor médio da cotação dentro de um determinado período, conforme é evidenciado no cálculo do MMS na Equação 4.

O BB é um dos conceitos mais poderosos disponível para o investidor tecnicamente embasado, como observa John Bollinger (BOLLINGER, 1992). Esta técnica não apresenta diretamente sinais de compra e venda absolutos, mas se os preços estão altos ou baixos em uma base relativa. *Bollinger Bands* são comumente utilizadas por investidores para confirmar outros indicadores (KANNAN et al., 2010). A BB pode confirmar o movimento do preço apresentando sinais de alta ou baixa nos preços que podem ajudar na identificação de tendências nos padrões de retornos que é identificado pelas redes neurais deste trabalho.

$$MMS[n] = \frac{\$Fecham(P0) + \$Fecham(P-1) + \ldots + \$Fecham(P-(n-1))]}{n} \quad (4)$$

Onde:
P = índice referente ao período em que foi verificado o preço de fechamento.
n = número de períodos.

Assim, as bandas de Bollinger são criadas com a soma de 2 desvios padrão à MMS, para a banda superior, e 2 desvios padrão a menos que a MMS para a banda inferior, conforme evidenciado na Fórmula 5 e na Figura 6.

$$\begin{aligned} Banda_{(Superior)} &= MMS_{(n)} + (2\sigma) \\ Banda_{(Inferior)} &= MMS_{(n)} - (2\sigma) \end{aligned} \quad (5)$$

Onde:
n = Número de períodos aplicado à média móvel;
σ = é o desvio padrão;

Os indicadores que não resultam em dados já normalizados, bem como o valor dos preços, passam pela normalização informada na Equação 6 antes de serem informados às redes neurais.

$$Norm(X) = \frac{X_i - Min(X)}{Max(X) - Min(X)} \quad (6)$$

Os indicadores técnicos foram calculados e exportados para todo o período, mas são coletados e informados dinamicamente às RNAs em janelas de tempo deslizantes com relação ao período atual da previsão. A Figura 7 apresenta um exemplo de janelas de tempo de 30 períodos, ou seja, os últimos 30 períodos de tempo de cada indicador e preço são coletados, normalizados e informados à cada RNA.

Figura 6 – Bandas de Bollinger

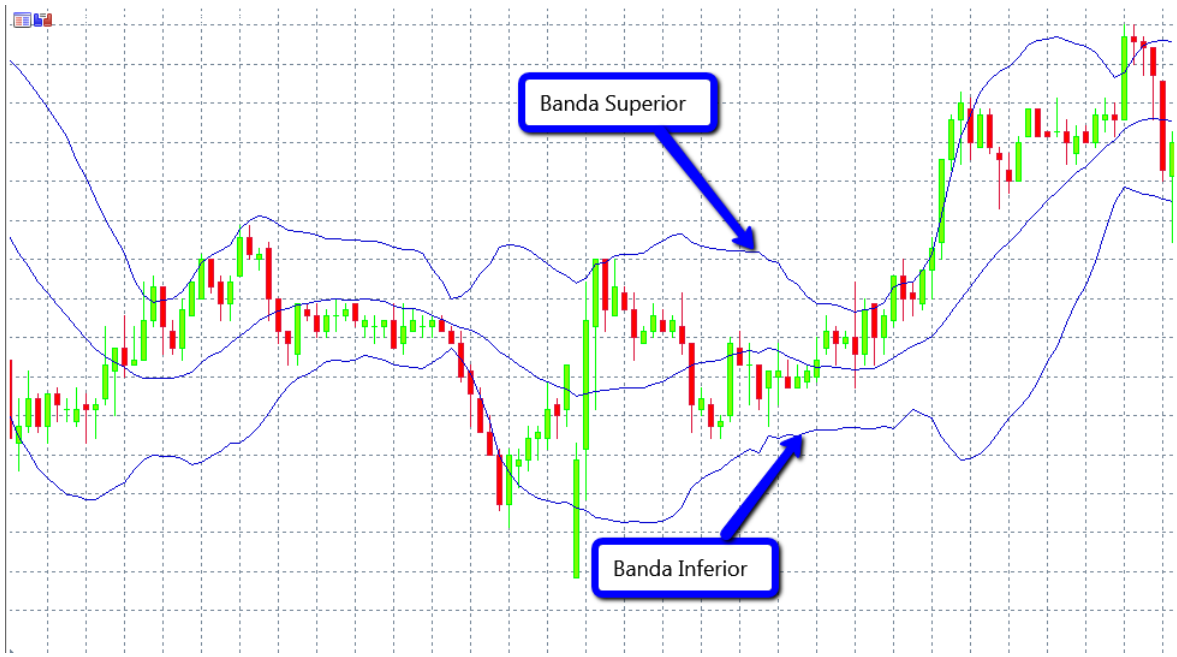

Fonte: Criado pelo autor com uso do Software Metatrader 5

Figura 7 – Janelas de Tempo na Previsão

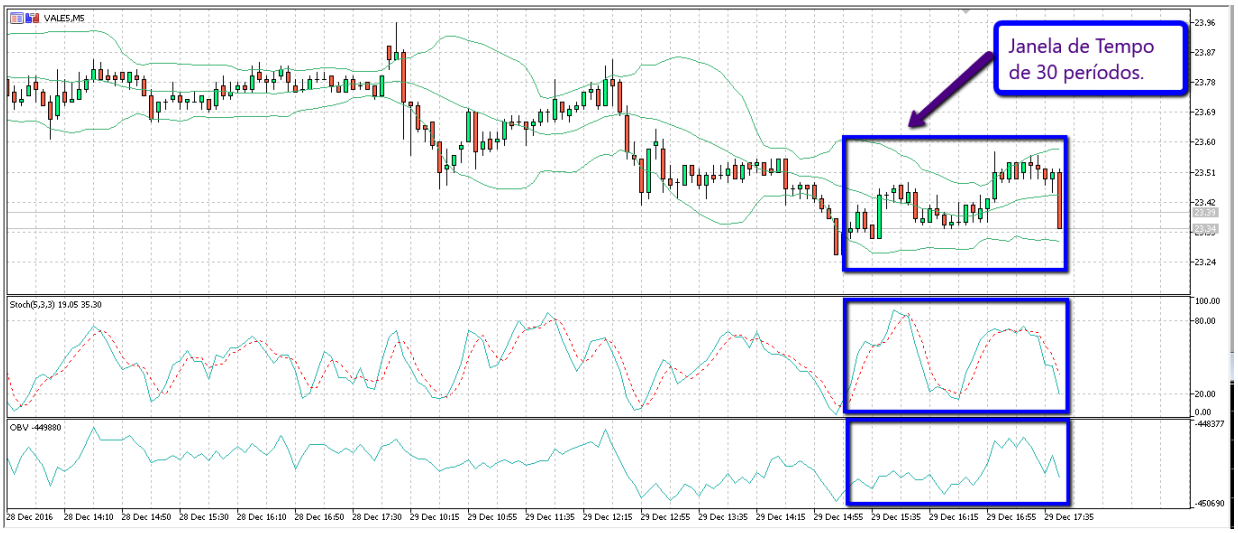

Fonte: Criado pelo autor com uso do Software Metatrader 5

4.2.3 *Algotrading* com RNA

Na terceira fase desta pesquisa as RNAs foram modeladas. Duas redes *Feedforward* com camada única escondida generalizada (SLFNs), com tecnologia *Extreme Learning Machine* (ELM), são configuradas. A essência do ELM é que a camada oculta de SLFNs não precisa ser ajustada, proporcionando um melhor desempenho do que as técnicas tradicionais (HUANG; WANG; LAN, 2011).

As RNAs têm por responsabilidade prever tendência no Retorno do Preços e no Volume. Para tanto, recebe como entrada os dados de preços de abertura, fechamento,

máxima, mínima, RSI, MACD, *Bollinger Bands*, o logaritmo na base 10 do retorno do preço, o volume monetário de negócios no período, o volume em número de negócios realizados e o logaritmo na base 10 do retorno do OBV. Um exemplo dos dados que são informados como entrada para as redes é mostrado na tabela 4. As redes têm a seguinte característica:

- ELM Price: Tem por objetivo apresentar previsões de tendência do retorno financeiro (positivo ou negativo). Assim, quando o sinal da tendência de retorno é positivo (alta) a direção da posição a ser aberta na estratégia é comprada, por outro lado, quando a previsão de tendência do retorno é negativo (baixa) a direção da posição a ser aberta é vendida;
- ELM Volume: Tem por objetivo apresentar previsões de tendência de volume financeiro de negócios. É usada para confirmar a abertura de posições na estratégia. Assim, as operações somente são abertas ou fechadas quando a previsão de tendência do volume está aumentando;

As ELMs fornecem sinais classificadores binários de tendência. Ambas, ELM Price e ELM Volume, são treinadas com os dados de entradas descritas na tabela 4. Porém, a ELM Price recebe a coluna Classe Preço como dado de treinamento da classificação, enquanto a ELM Volume recebe a coluna Classe Volume para treinar sua classificação.

Na tabela 4, a Classe Preço é 1 quando o Log(Retorno) do próximo *candle* (t+1) é positivo e 0 quando Log(Retorno) do próximo *candle* (t+1) é negativo. A Classe Volume é 1 quando o volume real (R$) do próximo *candle* (t+1) é crescente e 0 quando é decrescente, ou seja, é 1 quando volume real em t+1 menos o volume em t é positivo e 0 quando este resultado é negativo. Nos casos em que o valor do Log(Retorno) e a diferença de volume são iguais a zero, a classe afetada é classificado como 0. Essa classificação é mais apropriada para que os sinais de operação não sejam emitidos nestes casos, pois se a rede acerta a previsão de Log(Retorno) igual a 0 os custos operacionais inviabilizariam a operação.

Tabela 4 – Dados de Entrada e Classificação das Redes Neurais

VALE3 - M30 10 Candles Samples JAN 2017														
Date Time	**Open**	**Close**	**High**	**Low**	**Volume Real**	**Volume Negócios**	**RSI**	**MACD**	**BANDS**	**Log (Return)**	**Ret (OBV)**	**Log (Ret(OBV))**	**Classe Preço**	**Classe Volume**
02/01/2017 10:00	24,59	24,53	24,6	24,41	118.600	204	22,88	-0,2285	25,3	-0,001061	1,279412	0,10701034	1	1
02/01/2017 10:30	24,52	24,62	24,65	24,5	114.000	261	27,61	-0,2451	25,23	0,001768	0,881226	-0,054912671	1	0
02/01/2017 11:00	24,62	24,76	24,79	24,62	89.700	230	34,35	-0,2442	25,17	0,002463	0,900000	-0,045757491	0	0
02/01/2017 11:30	24,75	24,71	24,78	24,66	61.800	207	33,17	-0,2446	25,12	-0,000702	0,864734	-0,063117314	0	0
02/01/2017 12:00	24,71	24,71	24,73	24,63	29.200	179	33,17	-0,2422	25,06	0,000000	0,972067	-0,012303783	1	0
02/01/2017 12:30	24,71	24,73	24,75	24,67	22.200	174	34,22	-0,2359	25,01	0,000351	1,229885	0,089864525	0	1
02/01/2017 13:00	24,72	24,67	24,72	24,61	40.700	214	32,56	-0,2331	24,96	-0,000879	0,822430	-0,084901106	1	0
02/01/2017 13:30	24,67	24,7	24,74	24,66	27.700	176	34,28	-0,2258	24,9	0,000528	0,693182	-0,159152837	1	0
02/01/2017 14:00	24,72	24,74	24,74	24,69	32.900	122	36,6	-0,2144	24,88	0,000351	1,500000	0,176091259	0	1
02/01/2017 14:30	24,74	24,69	24,77	24,69	26.700	183	34,94	-0,207	24,85	-0,000879	0,590164	-0,229027334	1	0

O logaritmo dos retornos foi calculado conforme descrito na equação 7. Se o preço de abertura da ação em t+1 foi de, por exemplo, R$ 10 e o preço de fechamento foi de R$ 11, utilizando a fórmula, o Log(11/10) resultaria em 0,414 (positivo), assim, a Classe Preço receberia ”1”. De outro modo, caso o preço de abertura da ação em t+1 tivesse sido de R$ 10 e o preço de fechamento R$ 9, o Log(9/10) resultaria em -0,457 (negativo), definido a

Classe preço com o valor ”0”.

$$log_{10}(Retorno) = log_{10}(\frac{Close_Price}{Open_Price}) \tag{7}$$

O modelo da rede foi esboçado na Figura 8. Se a janela temporal de treinamento é definida por 10 registros, as 10 linhas exemplificadas na tabela 4 são fornecidos como entrada para a ELM.

O número de neurônios na camada escondida (*hidden layer*) foi considerado com o mesmo tamanho da janela de tempo. Deste modo, quando a janela é de 64 candles as redes são criadas com 64 nodos na *hidden layer*. O tamanho dos dados de treinamento da rede foi definido como sendo de 4 (quatro) dias. Assim, para cada periodicidade há uma quantidade diferente de *candles* para treinamento das redes. Para H1, por exemplo, são 32 *candles* a janela de treino, enquanto para M30, são 64 *candles*. A função de ativação adotada é do tipo tangente hiperbólica (tanh), que possibilita a ativação dos neurônios com dados entre (-1, 1). O estado randômico (random state) foi setado para 0. RBF width=0.01 e alpha=0.05.

A implementação da rede ELM adotada é de camada única escondida. O modelo e arquitetura similares às RNAs ELM adotadas são esboçados na figura 8.

Figura 8 – Arquitetura da Rede

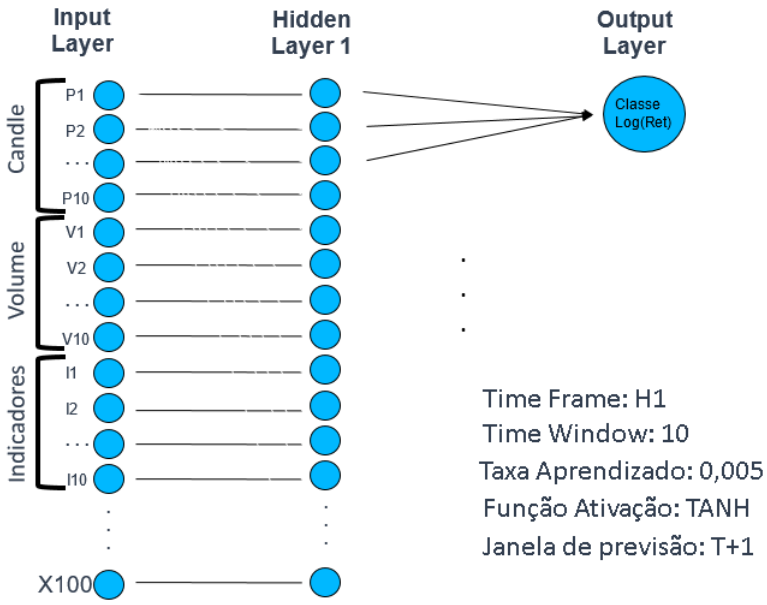

Fonte: Elaborado pelo autor

Para executar o primeiro experimento, foi definido o período de execução, com início em 01 de janeiro de 2017 e fim em 30 de junho de 2017. Posteriormente para o segundo experimento, foi definido o período entre 01 de julho de 2017 e 31 de dezembro de 2017. Os dados são selecionados neste período, normalizados e informados às redes neurais,

janela por janela e solicitada uma previsão da tendência de retorno do preço e volume no *candle* seguinte (t+1).

Os sinais de tendência de retorno do preço e volume são utilizados pelos robôs para realizar as operações, *candle* a *candle*, em janela deslizante, durante os 6 meses definidos para o período do experimento.

Os dados de previsão utilizados para cálculo dos indicadores de predição das redes estão fora do treinamento (*out of sample*), pois são dados sempre de (t+1), e os dados utilizados para treinamento estão localizados sempre nos tempo anteriores a (t) na janela deslizante. Assim, no caso H1, a janela deslizante dos 32 últimos *candles* é rolada durante os 6 meses. aproximadamente 960 *candles*. Ao final da execução, tem-se 960 menos 32, ou seja, 928 previsões no período, que são utilizadas para calcular os indicadores de predição.

4.2.4 Métodos de Avaliação das Previsões das RNAs

Na quarta fase da metodologia desta pesquisa foram calculados os indicadores de avaliação da predição dos modelos. Para tomar decisões na estratégia de operação com base em previsões é importante considerar os aspectos dinâmicos do problema e modelá-los.

Com as mudanças constantes no cenário como as informações de preço e volume sendo apresentadas em janelas de tempo para as redes, é interessante trabalhar com a incerteza da previsão de forma estocástica. A Matriz de Confusão apresentada na Tabela 1 é a primeira métrica adotada para avaliação destes modelos de predição.

Quadro 1 – Matriz de Confusão

		Previsto	
		Positivo	**Negativo**
Real	**Positivo**	*Verdadeiro Positivo (VP)*	*Falso Positivo (FP)*
	Negativo	*Falso Negativo(FN)*	*Verdadeiro Negativo (VN)*

Para tornar possível a comparação e análise dos resultados das RNAs, serão construídas matrizes de confusão. Considerando o “Verdadeiro Preditivo Positivo (VP)” quando a previsão positiva coincidiu com o real positivo. E o “Verdadeiro Preditivo Negativo (VN)” quando a previsão negativa coincide com o valor real negativo, ou seja, quando a rede previu valores condizentes com os valores reais. A classificação de falsos positivo e negativo (FN e FP) ocorrem quando a RNA erra na previsão.

O segundo indicador adotado é o *Precision* para classificações de *Alta* e *Baixa* para as Redes RNA Price e RNA Volume. Para verificar a frequência de acerto das classificações

conforme descrito nas equações 8 e 9, respectivamente.

$$Precision(Alta) = \frac{VP}{VP + FP} \tag{8}$$

$$Precision(Baixa) = \frac{VN}{VN + FN} \tag{9}$$

Completando a avaliação do poder de classificação das redes também serão calculados os indicadores *Recall* e *F1-Score* para cada rede. O *Recall* mede a frequência de uma predição e também é medido para as tendências de alta e baixa conforme apresentado nas Equações 10 e 11.

$$Recall(Alta) = \frac{VP}{VP + FN} \tag{10}$$

$$Recall(Baixa) = \frac{VN}{VN + FP} \tag{11}$$

O *F1-Score* apresentado nas equações 12 e 13 é o indicador que revela a média harmônica entre os indicadores *Precision* e *Recall*.

$$F1_Score(Alta) = 2 \times \frac{Precision_{(ALTA)} \times Recall_{(ALTA)}}{Precision_{(ALTA)} + Recall_{(ALTA)}} \tag{12}$$

$$F1_Score(Baixa) = 2 \times \frac{Precision_{(BAIXA)} \times Recall_{(BAIXA)}}{Precision_{(BAIXA)} + Recall_{(BAIXA)}} \tag{13}$$

E finalmente é utilizada a acurácia apresentada na equação 14 que fornece uma visão geral da frequência em que o classificador acerta na previsão.

$$Acuracia = \frac{VP + VN}{VP + FP + VN + FN} \tag{14}$$

4.3 Estratégias de Operação

Embora este trabalho seja fundamentado principalmente em previsões com reconhecimento de padrões com o uso de redes neurais, o desempenho passado não oferece garantias do desempenho futuro e não deve ser o único fator em consideração ao definir uma estratégia de investimento.

Dessa forma, acredita-se que ao utilizar a previsão em situações específicas para abrir, conduzir e fechar as operações, as estratégias de negociação de ativos poderão apresentar melhores resultados nos indicadores financeiros, reduzindo a incerteza e melhorando a relação risco/retorno. Assim, pode-se analisar na estratégia de operação, com base

nas previsões, variáveis como o melhor ponto de compra, a gestão do capital, a gestão do risco, a melhor hora de sair da operação e mesmo quando trocar de ativo, levando em consideração o objetivo do portfólio.

4.3.1 Estratégias Automatizadas de Operação (Robôs)

Os itens elencados abaixo são aspectos importantes na construção das estratégias de operação automatizada que serão abordadas e explicado o seu funcionamento em cada uma das estratégias desenvolvidas nesta pesquisa. As principais características a serem observadas são:

- Conceito da Estratégia
- Portfólio (carteira de ativos selecionados para operação)
- Abertura de Posição (*Trade Entry*)
- Fechamento de Posição (*Trade Exit*)
- Regras de Gestão do Capital (*Money Management*)
- Restrições de Operação (*Trade Filter*)

Neste experimento são apresentados 4 (quatro) Robôs implementados para executar as seguintes estratégias de investimento:

1. Robô - *Buy and Hold* (B&H)
2. Robô - Randômico (RAND)
3. Robô - Sinal ELM Simple Price (Simple)
4. Robô - Sinal *Ensemble* ELM Price/Volume (PriceVol)

4.3.1.1 Robô Estratégia *Buy and Hold*

O Robô que implementa a estratégia de *Buy and Hold* tem um conceito bem simples, mas um importante *benchmark* para utilizar na comparação com o desempenho dos outros robôs. A abertura da operação (*Trade Entry*) no *Buy and Hold* é definida pelo preço de abertura do *candle* inicial do período avaliado. O saída da operação (*Trade Exit*) é feita pelo preço de fechamento do *candle* do final do período avaliado, assim como expresso no algoritmo 2. Não existem restrições de operação (*Trade Filters*), uma vez que existe apenas

uma operação executada por período/ativo avaliado.

Algoritmo 2: Robô Estratégia *Buy and Hold* (B&H)

Entrada: CandleInicial, CandleFinal
Saída:
início
    numeroDeLotes = getPoderCompraEmLotes(openPrice)
    abrePosicao('COMPRA', numeroLotes, openPrice) ;
    fechaPosicao('COMPRA', numeroLotes, closePrice) ;
fim

4.3.1.2 Robô Estratégia Randômica

O Conceito da Estratégia Randômica ou aleatória é a geração de um sinal aleatório binário, o qual é utilizado para indicar a direção da posição a ser aberta (Compra ou Venda). A operação é aberta e fechada em cada *candle* do período. Portanto, a estratégia não adota restrições de operação (*Trade Filters*).

O robô faz a gestão do capital verificando a disponibilidade de saldo para aplicação e o poder de compra de ações no momento de cada operação. As operações são sempre abertas utilizando-se o preço de abertura do *candle* para entrada na operação e o preço de fechamento do *candle* para o fechamento da operação.

Algoritmo 3: Robô Estratégia Randômica (RAND)

Entrada: candleAtual
Saída:
início
    sinalRand = randomico(0 , 1) ;
    numeroDeLotes = getPoderCompraEmLotes(openPrice)
    if *(numeroDeLotes > 0)* **then**
        if *(sinalRand == 1)* **then**
            abrePosicao('COMPRA', numeroDeLotes, openPrice) ;
            fechaPosicao('COMPRA', numeroDeLotes, closePrice) ;
        else if *(sinalRand == 0)* **then**
            abrePosicao('VENDA', numeroDeLotes, openPrice);
            fechaPosicao('VENDA', numeroDeLotes, closePrice);
fim

4.3.1.3 Robô Estratégia ELM Simple

A Estratégia Simple ELM Price (Simple), apresentada no Algoritmo 4, recebe o Sinal de previsão apenas da RNA Price. O robô utiliza o sinal de previsão para decidir a respeito

da abertura das operações de compra, caso sinal seja de tendência de retorno alta, ou venda, caso sinal de tendência no retorno seja baixa.

A abertura de posição (*Trade Entry*) é definida com o sinal de previsão do preço determinando a direção da entrada. É importante observar que, diferentemente da estratégia randômica, aqui não existe uma operação em cada *candle*. As operações são abertas em um *candle* e fechadas em outro *candle*, considerando o preço de abertura em ambos.

A gestão de capital utilizada nas outras estratégias também é utilizada aqui. A estratégia opera com todo o capital disponível no momento e não realiza operações caso não tenha saldo, ou ainda, caso o robô apresente com operação aberta utilizando seu capital.

Algoritmo 4: Estratégia ELM Price (Simple)

```
Entrada: sinalPreco, candle
Saída: posicao_Compra_Venda
início
    numeroDeLotes = getPoderCompraEmLotes(candle.openPrice)
    if (temPosicaoAberta == FALSE) E (numeroDeLotes > 0) then
        if (sinalPreco == 'ALTA') then
            abrePosicao('COMPRA', numeroDeLotes, candle.openPrice) ;
        else if (sinalPreco == BAIXA) then
            abrePosicao('VENDA', numeroDeLotes, candle.openPrice) ;
    else if (temPosicaoAberta == TRUE) then
        if (sinalPreco == 'ALTA') E (getPosicaoAberta.TIPO == 'VENDA') then
            fechaPosicao('VENDA', numeroDeLotes, candle.openPrice);
        else if (sinalPreco == 'BAIXA') E (getPosicaoAberta.TIPO == 'COMPRA')
         then
            abrePosicao('COMPRA', numeroDeLotes, candle.openPrice) ;
    return position ;
fim
```

4.3.1.4 Robô Estratégia ELM Ensemble - PriceVol

A Estratégia de *Ensemble* de ELM PriceVol recebe o Sinal de previsão da tendência de retorno da RNA Price e o sinal de previsão de tendência da RNA Volume. O robô utiliza destes dois sinais de previsão para decidir a respeito da abertura das operações de compra e venda. O sinal de preço é utilizado para definir a direção da operação (comprada ou vendida), enquanto o sinal de Volume é utilizado como confirmação da operação. Assim, apenas são abertas operações caso o sinal de volume indique previsão de aumento no volume.

A abertura de posição é definida com o sinal de previsão do retorno do preço

determinando a direção da entrada e a operação apenas é aberta (*Trade Entry*) caso o sinal da segunda rede neural faça previsão do crescimento do volume. É importante salientar que, diferentemente da estratégia randômica, aqui não existe uma operação em cada *candle*. As operações são abertas em um *candle* e fechadas em outro *candle*, por isso é utilizado o preço de abertura, tanto na abertura da operação quanto no fechamento.

A gestão de capital utilizada nas outras estratégias também é utilizada aqui. A fórmula que calcula o poder de compra de ações é utilizada aqui, assim, o robô opera com todo o capital disponível no momento e não realiza operações caso não tem saldo, ou ainda, caso o robô estiver com operação aberta utilizando seu capital.

Dessa forma, o robô PriceVol difere do Robô Simple apenas por considerar o sinal da RNA Volume para confirmar a abertura de operações, apresentando o restante da sua implementação igual ao Simple.

O fechamento da posição (*Trade Exit*) é determinado pelos sinais de preço indicando sentido contrário ao da posição aberta com sinal de volume indicando crescimento de volume. A estratégia ELM Ensemble é também uma estratégia seguidora da tendência com base nas predições. Assim, se os sinais indicam compra e aumento de volume sucessivas vezes é aberta uma ordem no início do período, que apenas é fechada quando os sinais de previsão de preço e volume indicarem reversão com relação à ordem aberta. Este também é um fator positivo no desempenho financeiro do robô pois evita que várias operações sejam abertas sucessivamente, funcionando como um *Trade Filter* e reduzindo os custos

de operacionais e de corretagem.

Algoritmo 5: Estratégia Ensemble ELM (PriceVol)

```
Entrada: sinalPreco, sinalVolume, candle
Saída: posicao_Compra_Venda
início
    numeroDeLotes = getPoderCompraEmLotes(candle.openPrice)
    if (temPosicaoAberta == FALSE) E (numeroDeLotes > 0) then
        if (sinalPreco == 'ALTA') E (sinalVolume == 'AUMENTANDO') then
            abrePosicao('COMPRA', numeroDeLotes, candle.openPrice) ;
        else if (sinalPreco == BAIXA) E (sinalVolume == 'AUMENTANDO') then
            abrePosicao('VENDA', numeroDeLotes, candle.openPrice) ;
    else if (temPosicaoAberta == TRUE) then
        if (sinalPreco == 'ALTA') E (sinalVolume == 'AUMENTANDO') E
         (getPosicaoAberta.TIPO == 'VENDA') then
            fechaPosicao('VENDA', numeroDeLotes, candle.openPrice);
        else if (sinalPreco == 'BAIXA') E (sinalVolume == 'AUMENTANDO') E
         (getPosicaoAberta.TIPO == 'COMPRA') then
            abrePosicao('COMPRA', numeroDeLotes, candle.openPrice) ;
    return position ;
fim
```

4.3.2 AlgoTrading Aspectos Importantes

Existem alguns pontos importantes considerados nas estratégias de investimento, que são os seguintes:

- Gerenciamento do Sinal
- Gerenciamento do Capital
- Gerenciamento do Risco

A seguir explicamos como cada um deles foi considerado neste trabalho.

4.3.2.1 Gerenciamento do Capital

O Capital investido: R$ 10.000,00 (dez mil reais). Várias empresas no mercado que utilizam Robôs de investimento exigem o aporte inicial próximos a este valor. Outra motivo da escolha é que é um valor mínimo adequado para que operações do tipo *Day Trade* e *Swing Trade* possam ser lucrativas, considerando que o custo da corretagem deve ser inferior aos lucros obtidos nas negociações. Assim, o custo da corretagem de aproximadamente R$ 20,00 (vinte reais) é equivalente à 0,2% deste capital investido.

Para que as operações sejam feitas com valores próximos ao total do capital disponível utilizamos a Equação 15 para retornar o poder de compra em ações no momento.

Assim, todas as operações só são executadas se houver poder de compra naquele instante e quando há capital disponível para realizar a operação. As estratégias utilizam todo o capital disponível e possível, dada a restrição do tamanho do lote, para realizar a operação. Esta equação é utilizada no método *getPodeDeCompra* utilizado nas estratégias descritas pelos Algoritmos 3 e 5.

$$Lotes = \frac{(\frac{Capital_Disponivel}{Preco_Abertura}) - MOD(\frac{Capital_Disponivel}{Preco_Abertura}, Tamanho_Lote)}{Tamanho_Lote} \quad (15)$$

Exemplificando a fórmula descrita acima, supondo que o capital disponível para a operação seja de R$ 10.000,00 e o preço de abertura da ação seja R$ 21,50. Temos que o capital disponível (10.000) dividido pelo preço de abertura (21,50) é igual a 465,12. O módulo (resto da divisão) de 465,12 por 100, que é o valor padrão do lote de ações, resulta em 65,12. Realizando a subtração de 465,12 - 65,12 temos que é possível comprar 400 ações. Dividindo-se 400 por 100, obtemos o poder de compra de 4 Lotes desta ação. Assim, teremos o número máximo de lotes de ações que é possível operar, dado o capital disponível em determinado momento, que, no exemplo apresentado, é de 4 lotes de 100 ações.

4.3.2.2 Gerenciamento do Sinal

O Gerenciamento do Sinal trata da informação que será obtida para auxiliar na tomada de decisão da compra ou venda de ações. Neste trabalho o sinal é emitido por duas RNAs treinadas para prever tendência nos preços e no volume.

- **RNA - Price**: o histórico de preço, volume e indicadores são informados à RNA que emite previsão de tendência de retorno, variação de preço, futuro como um classificador. Este sinal é utilizado para definir a direção de entrada da posição a ser aberta de COMPRA ou VENDA;
- **RNA - Volume**: recebe o histórico do OBV, o histórico do preço, histórico do volume e realiza uma previsão na tendência do volume; Este sinal emitido é utilizado no algoritmo para validar a entrada da operação. Somente são realizadas aberturas de operações caso o sinal indique um crescimento no volume. Caso esta RNA tenha previsão de volume aumentando, a ordem estará confirmada, caso a RNA faça previsão de volume reduzindo, a ordem não será confirmada.

4.3.2.3 Gerenciamento do Risco

O Risco da Operação aqui considerado é que o preço possa se movimentar no sentido contrário à operação. Assim, outro recurso comumente utilizado para conter rapidamente as perdas neste caso é o uso do *stop loss*. O *stop loss* é um gatilho que dispara uma

ordem no sentido contrário à ordem que está em execução para sair da operação contendo os prejuízos.

São utilizados recursos de *stop loss*, que é um recurso utilizado para conter as perdas, caso a operação siga no sentido contrário à posição de entrada no mercado. O valor configurado para as estratégias foi fixado em 1% do valor do preço de entrada da operação.

4.3.3 Simulação e *Backtesting*

Os principais motivos pelos quais uma estratégia de negociação automatizada ajuda o investidor são a possibilidade de averiguar a sua eficácia através de estudos estatísticos em um experimento executado em dados passados (*backtesting*), que podem quantificar a sua consistência e fornecer resultados objetivos para a sua adoção.

Na quinta fase do experimento é realizado o *backtesting* simulado da estratégia. Neste ponto foram calculados e extraídos os indicadores de previsão da Rede Neural Artificial e a os indicadores de resultados financeiros.

4.3.4 Métodos de Avaliação Financeira

Durante esta fase da pesquisa, são analisados os resultantes financeiros da execução da estratégia de operação, pretende-se alterar a estratégia proposta a fim de compará-las e identificar possíveis estratégias com melhores resultados financeiros.

Os indicadores financeiros selecionados e calculados para comparação da execução da estratégia de operação baseada em previsões de RNAs para as devidas comparações são:

- Quantidade de negociações realizadas (*trades*);
- Nº de operações com lucro;
- Nº de operações com perda;
- Lucro bruto (*Gross Profit*): consiste na soma de todas as operações de lucro em unidades monetárias;
- Perda bruta (*Gross Loss*): consiste na soma de todas as operações de perda em unidades monetárias;
- Lucro Médio por Operação: consistindo na divisão do Lucro Bruto pelo número de ordens com Lucro;
- Perda Média por Operação: consistindo na divisão da Perda Bruta pelo número de ordens com Perda;
- *Net Profit* (Lucro líquido + Capital Investido): capital atingido ao final de todas as operações;
- Fator de Lucro Bruto (*Gross Profit Factor*) – relação entre o lucro bruto e a perda bruta. A unidade indica que a soma dos lucros é igual à soma das perdas;

- Fator de Lucro Líquido (*Profit Factor*) – relação entre o lucro líquido e a perda líquida. Descontas os custos de operação;
- Fator de Lucratividade (*Percent Profitable*): relação entre o nº de ordens com lucro e o nº de ordens com perda;
- Gráfico da Curva de Evolução do Capital - Definido o capital inicialmente aplicado, a curva de evolução do capital mostra o crescimento e/ou rebaixamento do capital ao longo das operações;
- *MaxDrawdown* percentual do capital – Rebaixamento máximo do capital durante expresso percentualmente.

O fator de lucro (*profit factor*) é definido como a divisão do lucro bruto pela perda bruta (incluindo os custos operacionais) para todo o período avaliado. Esta métrica de desempenho relaciona a quantidade de lucro por unidade de risco. Quando apresenta valores maiores que 1 indica que o robô foi lucrativo. A formula do fator de lucro pode ser avaliada na Equação 16.

$$ProfitFactor = \frac{GrossProfit}{GrossLoss} \tag{16}$$

O indicador Percentual de Lucratividade é também conhecido como probabilidade de ganhos. Esta métrica é calculada dividindo o número de trades com lucro pelo numero total de trades em um período específico, conforme a formula 17.

$$PercentualdeLucratividade = \frac{NumeroOperacoesComLucro}{NumeroOperacoesComPerda} \tag{17}$$

O cálculo do *MaxDrawDown* (MDD) é realizado conforme algoritmo 6. A entrada Evolução do capital é um vetor que contém os valores de saldo de capital sempre que uma operação é fechada, durante a execução das operações de cada estratégia. Considerando um Drawdown (DD) um dos rebaixamentos durante a evolução do capital e o MaxDrawDown o rebaixamento percentual máximo, o algoritmo apresenta dois comandos "*for*" aninhados, que percorrem, para cada valor da curva de evolução do capital, todos os valores seguinte da mesma curva, calculando todos os *DrawDowns* identificados até o final da curva. Assim,

sempre que um DD for menor que o MDD ele passa a ser o MDD.

Algoritmo 6: MaxDrawDown

```
Entrada: EvolucaoCapital
Saída: MaxDrawDown (MDD)
início
    DD = 0; MDD = 0;
    for i = 0 → EvolucaoCapital.length() do
        for j = i; → EvolucaoCapital.length() do
            DD = EvolucaoCapital [ j ] / EvolucaoCapital [ i ] - 1 ;
            if ( DD < MDD ) then
                MDD = DD;
        end
    end
    retorna MDD ;
fim
```

Todos os indicadores de predição e financeiros apresentados foram calculados com base na média do resultado das 30 execuções do experimento. Para fornecer uma ideia da variação (volatilidade) do indicador apresentado, foi calculado e colocado logo abaixo de cada indicador o Coeficiente de Variação (CV), em formato percentual. A fórmula utilizada para o CV é apresentada na Equação 18.

$$Coeficiente_Variacao(CV) = \frac{Desvio_Padrao}{Media} \times 100 \tag{18}$$

5 Resultados

Este capítulo está organizado em três seções que permitirão apresentar os principais resultados. A Seção 5.1 apresenta a caracterização dos dados. A Seção 5.2 apresenta os resultados obtidos na predição das redes, enquanto a Seção 5.3 discorre sobre os resultados financeiros da execução da estratégia de operação.

5.1 Caracterização dos Dados

As caracterizações dos dados aqui apresentadas estão concentradas em extrair informações para auxiliar na definição das estratégias de negociação, principalmente no que tange à escolha das periodicidades, ou seja, no tempo em que as operações serão realizadas durante a execução das estratégias. Assim, foi avaliado o comportamento do ativo para escolher a(s) periodicidade(s) na(s) qual(is) os retornos observados pudessem oferecer oportunidade de operações com rendimentos superiores, no mínimo, aos custos de corretagem estimados.

Na execução dos robôs foi utilizado, em todos os casos, o valor de investimento inicial igual a R$ 10.000,00. Para se estimar um valor percentual do custo de corretagem em relação ao investimento inicial, foi previsto inicialmente que seria necessário enviar uma ordem de entrada e outra de saída no valor de R$ 20,00 cada, taxas comuns encontradas nas corretoras nos dias atuais. Assim, calculou-se o valor estimado de custo operacional em 0,40%. Este valor foi colocado em todos os ativos para identificar a quantidade de *candles* com retornos superiores a este limite (*threshold*) de custo operacional estimado.

A Tabela 5 mostra o percentual de *candles* nos quais o retorno financeiro do candle se encontram acima dos custos operacionais estimados de 0,40%, relativamente ao total de *candles* do período, em cada ativo, por periodicidade. Acredita-se que as médias apresentadas por M30 (21,48%) e H1 (34,61%) sejam suficientes para que os robôs consigam realizar uma quantidade significativa de operações com lucro acima dos custos operacionais. As periodicidades M1, M5 e M15 apresentaram um baixo percentual de *candles* com expectativa de retorno acima ou abaixo do *threshold* de custos operacionais.

As periodicidades H4 e D1 foram retiradas do experimento porque os robôs operam em tendência. Isso significa que as ordens podem ficar abertas por mais de um *candle*. Assim, poderiam gerar ordens que ficasse abertas por mais de um dia, o que pode alterar os custos operacionais estimados. Comumente as corretoras têm custo de corretagem diferenciado para operações *DayTrade* e não *DayTrade*. Outro custo que pode alterar é o aluguel de ações que em algumas corretoras é cobrado a partir de quando a ordem fica

aberta por mais de um dia.

Tabela 5 – Percentual de *Candles* acima do Custo Operacional 2017

Periodicidade	BOVA11	VALE3	ITUB4	PETR4	Média
M1	0,05%	0,53%	0,14%	0,28%	0,25%
M5	0,52%	6,17%	1,77%	3,88%	3,09%
M15	3,25%	19,14%	9,10%	13,76%	11,31%
M30	9,69%	31,87%	19,57%	24,77%	21,48%
H1	20,80%	45,45%	33,63%	38,56%	34,61%
H4	39,73%	62,31%	49,12%	60,27%	52,86%
D1	61,89%	85,66%	71,31%	75,41%	73,57%

É importante observar na Tabela 5, que o ativo BOVA11 apresenta o menor percentual de *candles* acima dos custos operacionais em todos as periodicidades. Mostrando uma baixa volatilidade que pode refletir no desempenho dos robôs. Essa informação pode ser melhor observada no Gráfico da Figura 9

Figura 9 – Percentual de *Candles* acima dos Custos Operacionais Ativos x Periodicidades 2017

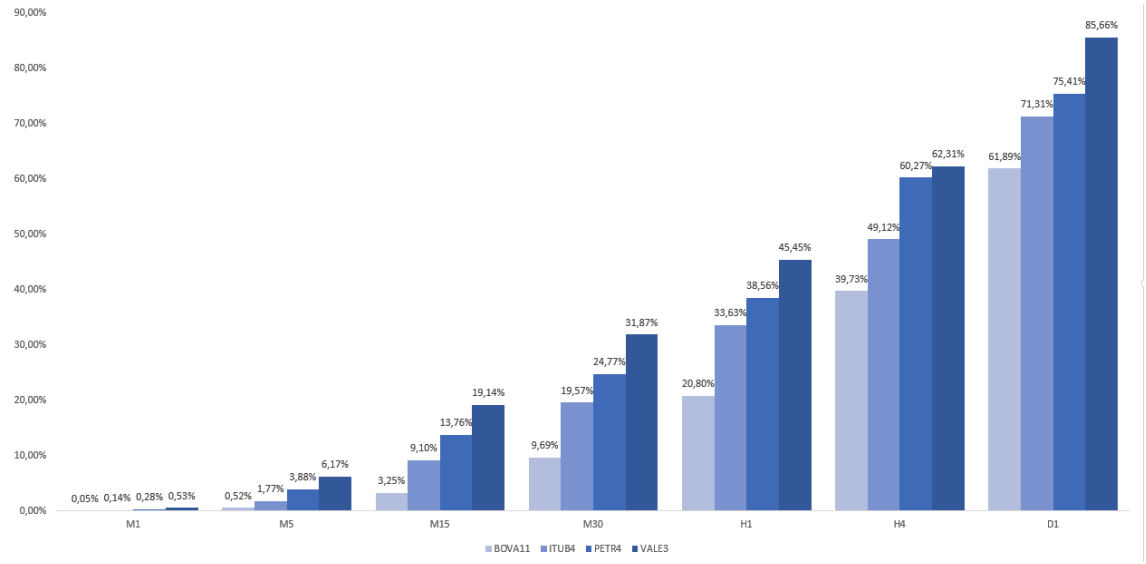

Fonte: Elaborado pelo autor com dados dos ativos

5.1.1 BOVA11

No ativo BOVA11 os valores máximos e mínimos de cotação do ativo foram de R$ 75,41 e R$ 57,51, respectivamente, no ano de 2017. A Figura 16 apresenta as variações percentuais Máximas e Mínimas, por periodicidade (M1, M5, M15, M30, H1, H4 e D1) do ativo BOVA11 no mesmo período, o que fornece indícios dos limites máximo e mínimo de rendimentos esperados de uma operação em cada periodicidade.

A Figura 11 expressa a variação de retornos percentuais do ativo BOVA11, no ano de 2017, nas periodicidade M30 (à esquerda) e H1 (à direita). As linhas vermelhas definem

Figura 10 – Variação Retornos (%) Máximos e Mínimos - BOVA11 2017

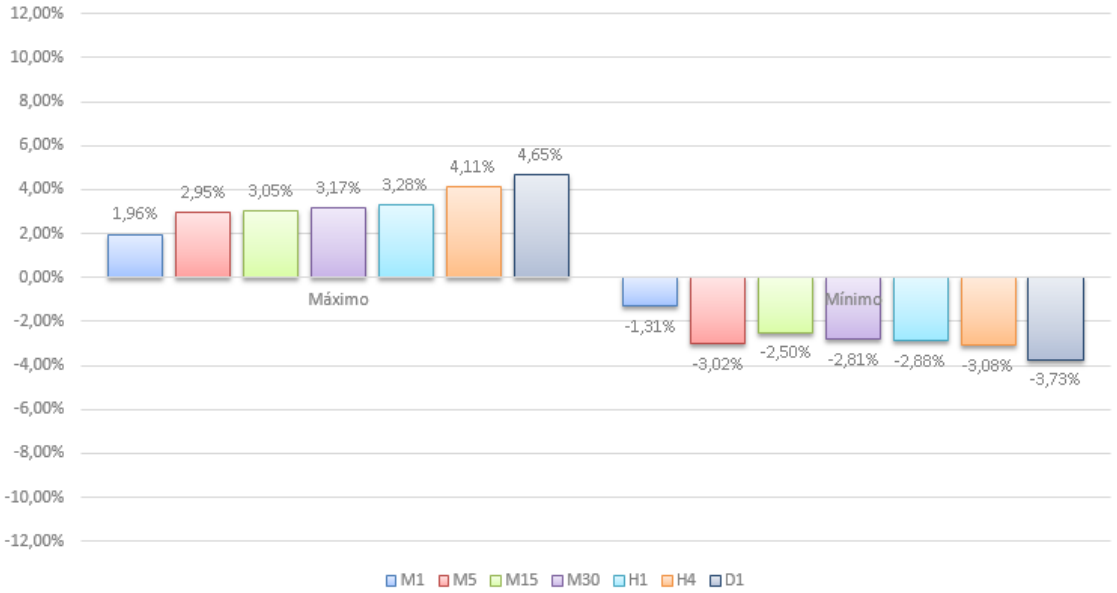

Fonte: Elaborado pelo autor com dados do ativo

o limite de custos operacionais estimados de 0.40%. Visualmente percebe-se a quantidade pequena de retornos percentuais acima e abaixo da linha do *threshod*, principalmente na periodicidade M30.

Figura 11 – Variação Retornos (%) - BOVA11 2017 - À esquerda M30 e à direita H1

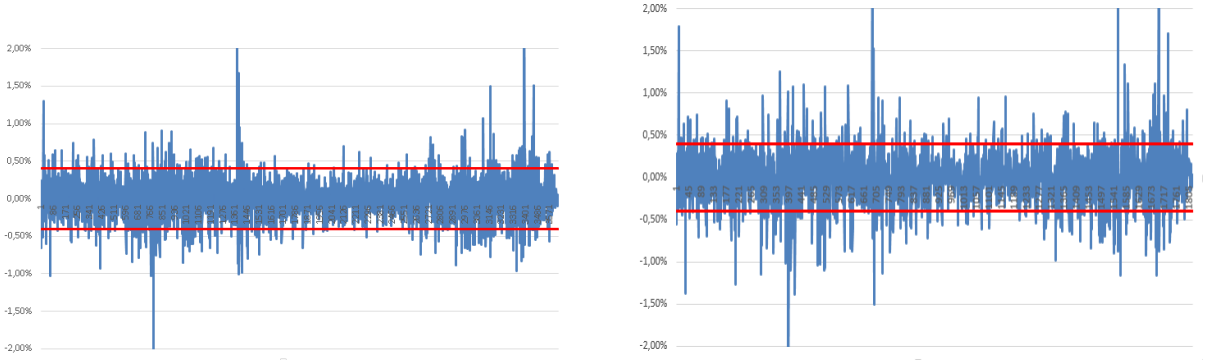

Fonte: Elaborado pelo autor com dados do Ativo

Torna-se interessante observar as volatilidades com intuito de associar ao rendimentos das estratégias de operação nestes ativos no período. Assim, estratégias que foram executadas no período de maior volatilidade podem, consequentemente, apresentarem maior variação financeira no período.

5.1.2 VALE3

A Figura 16 apresenta as variações percentuais Máximas e Mínimas por periodicidade (M1, M5, M15, M30, H1, H4 e D1), do ativo VALE3, no ano de 2017. O que traz

evidências dos limites máximo e mínimo de rendimentos possíveis de operações realizadas em cada periodicidade.

Figura 12 – Variação Retornos (%) Máximos e Mínimos - VALE3 2017

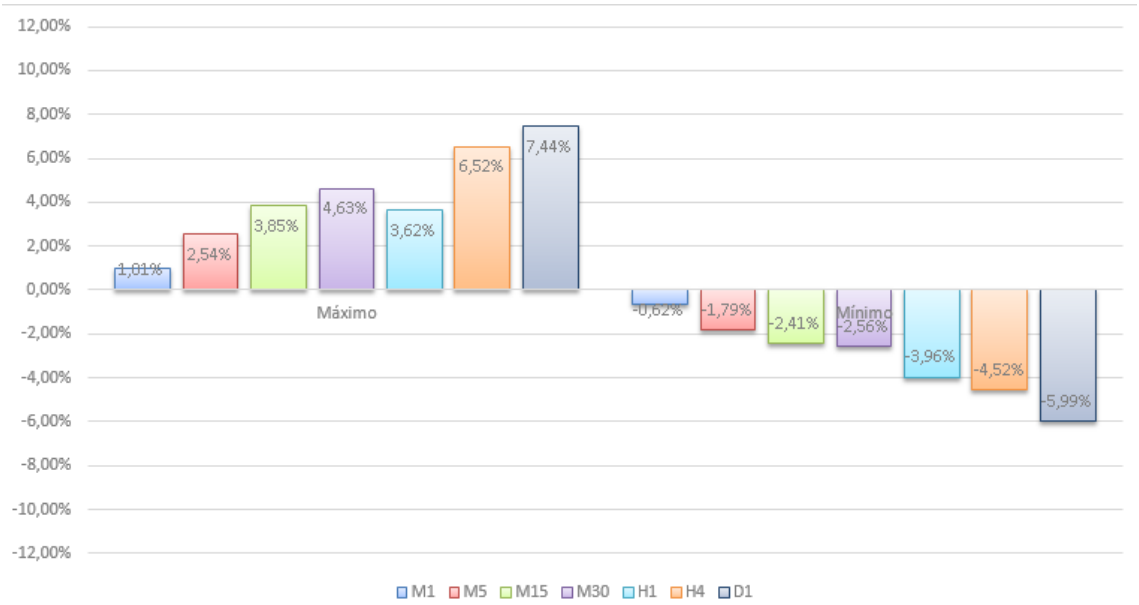

Fonte: Elaborado pelo autor com dados do ativo

A variação dos retornos percentuais de VALE3, no ano de 2017, nas periodicidades M30 (à esquerda) e H1 (à direita), são apresentadas na Figura 13. A linha vermelha continua mostrando o limite de custos operacionais estimados de 0,40%. Observa-se uma quantidade bem superior de retornos percentuais acima dos limites de custos operacionais quando comparado ao ativo BOVA11 apresentado anteriormente.

Figura 13 – Variação Retornos (%) - VALE3 2017 - À esquerda M30 e à direita H1

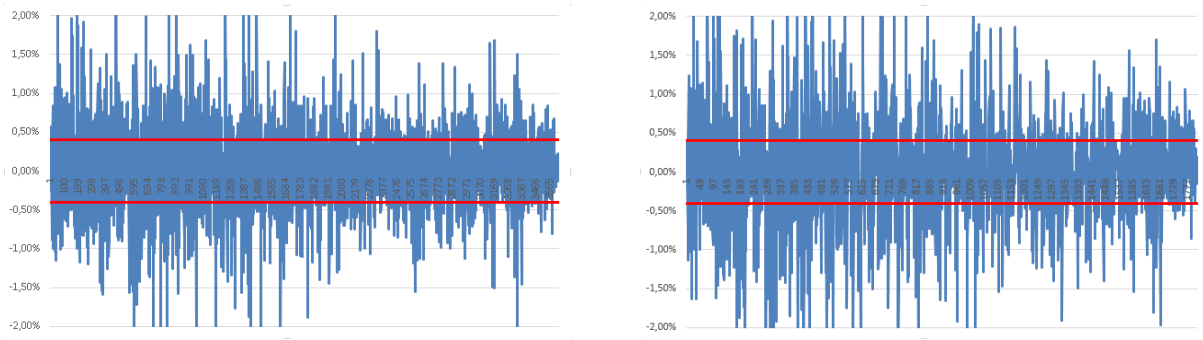

Fonte: Elaborado pelo autor com dados do Ativo

5.1.3 ITUB4

A Figura 14 apresenta as variações percentuais Máximas e Mínimas por periodicidade (M1, M5, M15, M30, H1, H4 e D1), do ativo ITUB4, no ano de 2017. O que traz

evidências dos limites máximo e mínimo de rendimentos possíveis de operações realizadas em cada periodicidade.

Figura 14 – Variação Retornos (%) Máximos e Mínimos - ITUB4 2017

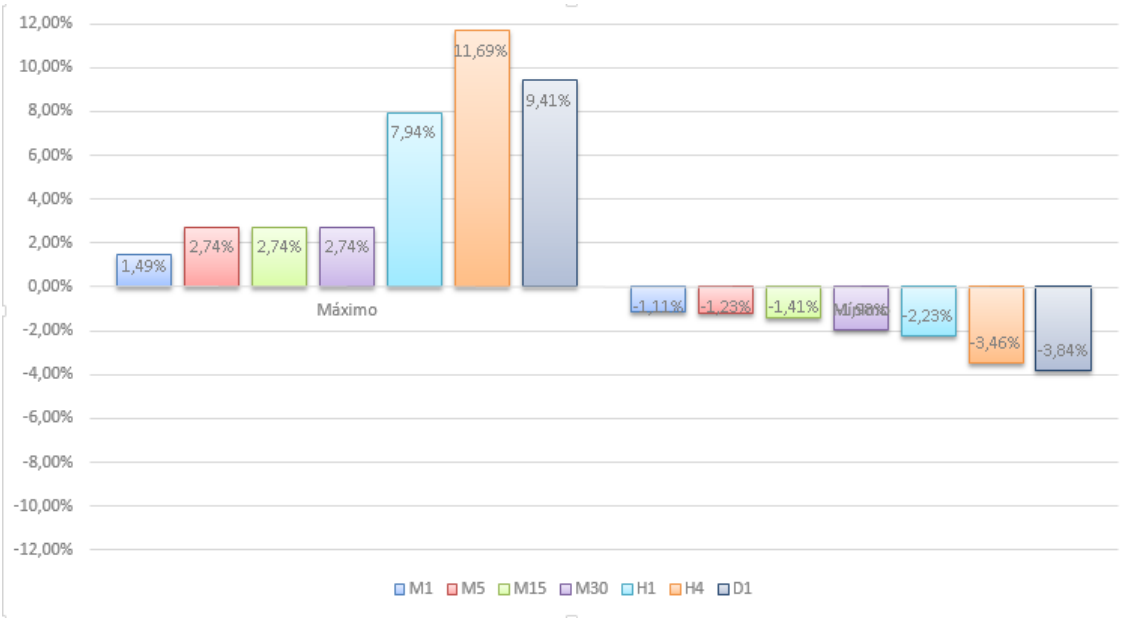

Fonte: Elaborado pelo autor com dados do ativo

A variação dos retornos percentuais de ITUB4, no ano de 2017, nas periodicidades M30 (à esquerda) e H1 (à direita), são apresentadas na Figura 15. As linhas vermelhas são os limites dos custos operacionais estimados de 0.40% e facilitam a visualização da quantidade de retornos percentuais no ativo, em cada periodicidade, no ano de 2017, que superaram estes limites.

Figura 15 – Variação Retornos (%) - ITUB4 2017 - À esquerda M30 e à direita H1

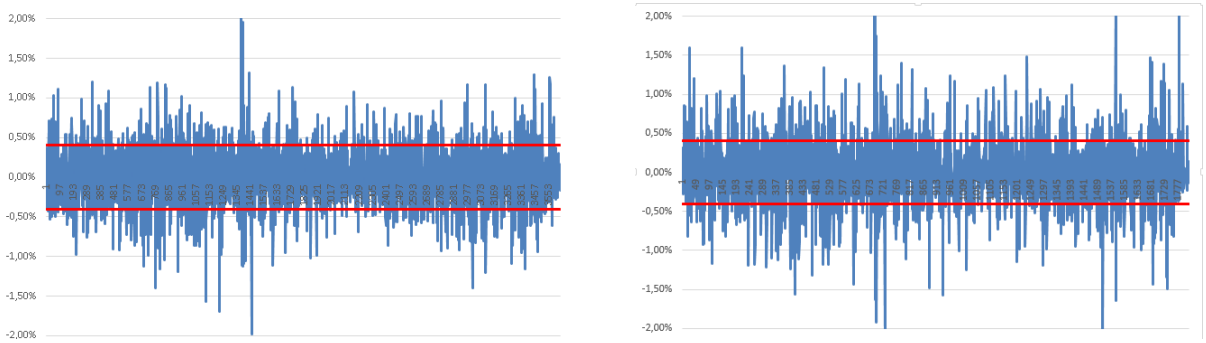

Fonte: Elaborado pelo autor com dados do Ativo

5.1.4 PETR4

A Figura 16 apresenta as variações percentuais Máximas e Mínimas por periodicidade (M1, M5, M15, M30, H1, H4 e D1), do ativo VALE3, no ano de 2017. O que traz

evidências dos limites máximo e mínimo de rendimentos possíveis de operações realizadas em cada periodicidade.

Figura 16 – Variação Retornos (%) Máximos e Mínimos - PETR4 2017

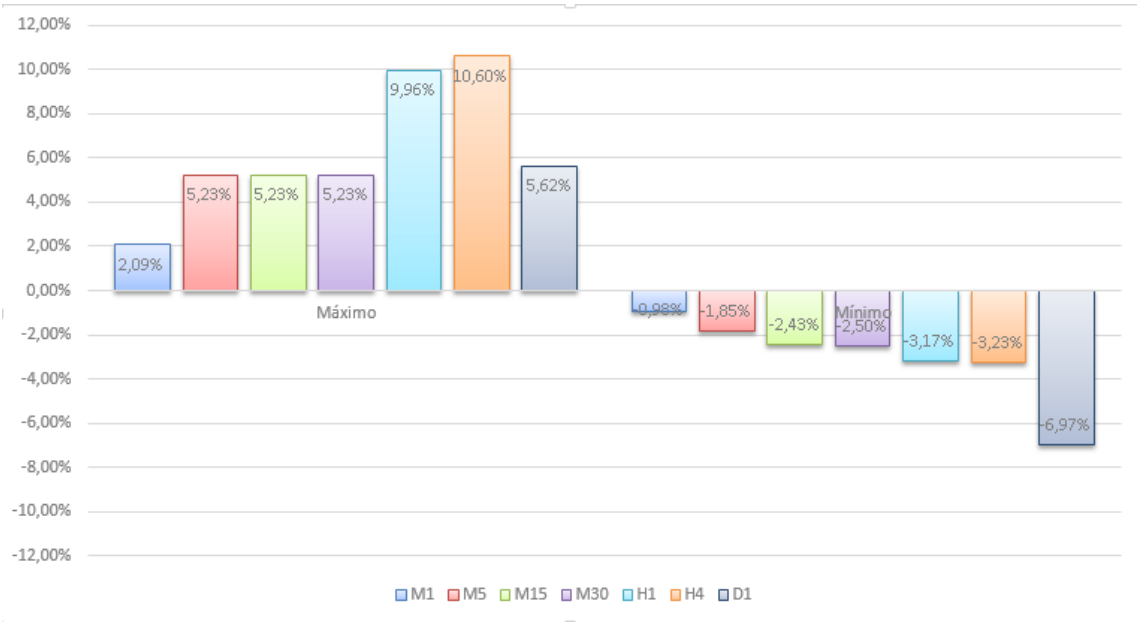

Fonte: Elaborado pelo autor com dados do ativo

A variação dos retornos percentuais de PETR4, no ano de 2017, nas periodicidades M30 (à esquerda) e H1 (à direita), são apresentadas na Figura 17. As linhas vermelhas são os limites estimados dos custos operacionais de 0,40%. Estas linhas facilitam a visualização da quantidade de retornos percentuais que atingiram valores superiores aos custos operacionais durante o ano.

Figura 17 – Variação Retornos (%) - PETR4 2017 - À esquerda M30 e à direita H1

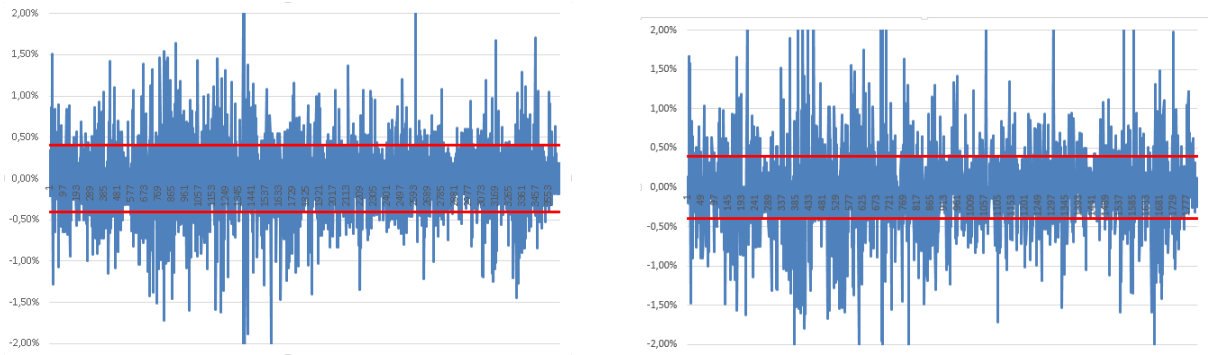

Fonte: Elaborado pelo autor com dados do Ativo

5.2 Desempenho da predição das RNAs

Os indicadores de acurácia, precisão, *recall* e *F1-Score* foram calculados para avaliar o nível de predição das redes. O experimento desliza a janela temporal *candle* por

candle (Janela deslizante), em cada ativo, para cada periodicidade. Os dados da janela de treinamento passada são apresentados às RNA Price e RNA Volume em cada *candle*. Então as RNAs realizam as predições para o *candle* seguinte. Ao final do período, temos n previsões de tamanho igual ao número de *candles* da periodicidade. Neste ponto é feito o cálculo dos indicadores. O experimento então é executado 30 (trinta) vezes e os indicadores apresentados são uma média aritmética das trinta execuções.

O conceito proposto pela ELM, é de que a camada escondida é randômica. Portanto, não seria possível realizar um experimento de forma determinística e replicável, assim foi necessário executar o experimento trinta vezes e apresentar as médias com as seus respectivos Coeficientes de Variação (CV), informados entre parênteses logo abaixo de cada indicador.

Os resultados apresentados são referentes ao experimento feito durante o 1º semestre de 2017 para os Ativos BOVA11 e VALE3, nas periodicidades H1 e M30. Para os ativos PETR4 e ITUB4 são apresentados os resultados referentes ao experimento do 2º semestre de 2017, também nas periodicidades H1 e M30.

5.2.1 BOVA11

A Tabela 6 mostra as Matrizes de Confusão das RNAs Price e RNA Volume, nas periodicidades H1 e M30. A matriz mostra que foram realizadas, em média, para H1, 235,13 previsões de tendência Positiva (Alta), que corresponderam à situação real da variação de retorno do *candle*. Estes são os Verdadeiros Positivos (VP) da RNA Price na periodicidade H1. Enquanto, ocorreu, em média, 204,60 vezes, em que a previsão de Positivos pela RNA Price não correspondeu à tendência de Alta prevista, consistindo nos Falsos Positivos (FP).

Analogamente, houve uma previsão de tendência Negativa pela RNA Price, em H1, que correspondeu à variação Negativa Real em 208,20 dos casos, na média. Estes são os Verdadeiros Negativos (VN). Quando houve uma previsão de Negativos pela RNA, quando o retorno real foi Negativo (Baixa), a rede apresentou, na média, 217,07 casos. Estes constituindo os Falsos Negativos (FN).

Pode-se perceber que o desempenho da Rede Price na predição de Negativos(Baixa) em H1 foi ruim comparado à predição dos Positivos (Altas). RNA Price atingiu 208,20 VN e 235,13 VP, com Coeficiente de Varição (cv) de 7,02% e 5,03%, respectivamente. Observa-se ainda que, em geral, o desempenho das predições Verdadeiro Positivas foi, em média, superior ao desempenho das predições Verdadeiro Negativas. Esse desempenho melhor dos Positivos também pode ser observado nos Coeficientes de Variação, nos quais os VPs apresentaram variação menor que os VNs em todos os casos.

A Tabela 7 mostra os indicadores de desempenho das Redes Neurais treinadas para RNA Price e RNA Volume, nas periodicidade H1 e M30, no 1º Semestre de 2017.

Tabela 6 – Matriz de Confusão BOVA11 - 1º Semestre 2017

			PREVISÃO			
			H1		**M30**	
			Positivo	**Negativo**	**Positivo**	**Negativo**
REAL	**Price**	**Positivo (cv)**	235,13 (5,03%)	217,07 (4,72%)	483,93 (4,20%)	418,53 (4,12%)
		Negativo (cv)	204,60 (5,62%)	208,20 (7,02%)	402,00 (5,18%)	424,53 (3,33%)
	Volume	**Positivo (cv)**	254,93 (4,33%)	198,43 (6,10%)	476,13 (3,86%)	416,97 (3,43%)
		Negativo (cv)	205,33 (5,51%)	206,30 (5,76%)	411,97 (4,80%)	423,93 (4,13%)

Obviamente os indicadores corroboram a Matriz de Confusão apresentada anteriormente, pois são calculados com base nela.

Neste período, no ativo BOVA11, tanto para H1 quanto M30, as RNAs Price e Volume apresentaram desempenho superior em todos os indicadores de ”Alta” quando comparados aos indicadores de ”Baixa”.

Outra observação importante para a Tabela 7 é que em H1, os indicadores da **RNA Volume** foram, em geral, superiores aos da **RNA Price**. Já na periodicidade M30, a **RNA Price** apresentou indicadores, em geral, superiores à **RNA Volume**.

Tabela 7 – Indicadores RNA BOVA11 - 1º Semestre de 2017

	H1		**M30**	
	RNA Price	**RNA Volume**	**RNA Price**	**RNA Volume**
Acurácia (cv)	0,5125 (3,42%)	0,5332 (3,12%)	0,5254 (2,25%)	0,5206 (2,21%)
Precision(Alta) (cv)	0,5349 (4,80%)	0,5539 (3,87%)	0,5463 (3,47%)	0,5362 (3,51%)
Precision(Baixa) (cv)	0,4895 (4,11%)	0,5097 (5,12%)	0,5036 (2,44%)	0,5041 (3,06%)
Recall(Alta) (cv)	0,5199 (3,74%)	0,5624 (3,54%)	0,5362 (3,35%)	0,5331 (2,52%)
Recall(Baixa) (cv)	0,5046 (5,41%)	0,5011 (4,41%)	0,5138 (3,55%)	0,5072 (3,50%)
F1 Score(Alta) (cv)	0,5271 (3,69%)	0,5579 (3,13%)	0,5410 (2,89%)	0,5345 (2,62%)
F1 Score(Baixa) (cv)	0,4966 (4,19%)	0,5052 (4,24%)	0,5085 (2,35%)	0,5055 (2,84%)

5.2.2 VALE3

A Tabela 8 mostra a Matriz de Confusão dos indicadores das Redes Neurais ELM classificadora de Price e Volume, para o ativo VALE3, no 1º semestre de 2017, nas periodicidades H1 e M30.

Avaliando a Matriz de Confusão de VALE3 identifica-se que o Coeficiente de Variação em M30 foi menor que os apresentados para H1.

Tabela 8 – Matriz de Confusão VALE3 - 1º Semestre 2017

			PREVISÃO			
			H1		**M30**	
			Positivo	**Negativo**	**Positivo**	**Negativo**
REAL	**Price**	**Positivo (cv)**	223,23 (6,10%)	212,43 (6,75%)	451,30 (4,63%)	420,03 (4,31%)
		Negativo (cv)	203,77 (5,25%)	225,57 (5,06%)	419,30 (3,32%)	438,37 (4,75%)
	Volume	**Positivo (cv)**	235,3 (6,21%)	199,27 (5,85%)	475,93 (3,92%)	403,30 (4,06%)
		Negativo (cv)	205,77 (5,14%)	224,67 (5,41%)	407,97 (4,94%)	441,80 (4,49%)

A Tabela 9 apresenta os indicadores de desempenho das RNAs Price e Volume, para VALE3, no 1º Semestre de 2017. Esta Tabela mostra na periodicidade M30, todos os indicadores de desempenho da **RNA Volume** foram superiores aos da **RNA Price**, nas duas periodicidades.

Tabela 9 – Indicadores RNA VALE3 - 1º Semestre de 2017

	H1		**M30**	
	RNA Price	**RNA Volume**	**RNA Price**	**RNA Volume**
Acurácia (cv)	0,5188 (3,82%)	0,5318 (2,53%)	0,5146 (2,11%)	0,5308 (2,39%)
Precision(Alta) (cv)	0,5226 (4,30%)	0,5333 (4,59%)	0,5182 (3,16%)	0,5385 (3,26%)
Precision(Baixa) (cv)	0,5152 (4,69%)	0,5299 (4,43%)	0,5106 (3,73%)	0,5227 (3,12%)
Recall(Alta) (cv)	0,5125 (5,74%)	0,5413 (4,20%)	0,5179 (3,36%)	0,5413 (3,10%)
Recall(Baixa) (cv)	0,5254 (4,25%)	0,5219 (3,35%)	0,5110 (2,86%)	0,5199 (3,95%)
F1 Score(Alta) (cv)	0,5173 (4,61%)	0,5370 (3,82%)	0,5179 (2,88%)	0,5397 (2,70%)
F1 Score(Baixa) (cv)	0,5200 (3,95%)	0,5256 (3,24%)	0,5107 (2,95%)	0,5212 (3,10%)

5.2.3 ITUB4

A Tabela 10 apresenta a Matriz de Confusão para o ativo ITUB4, executada nas periodicidade H1 e M30, no 2º Semestre de 2017.

Tabela 10 – Matriz de Confusão ITUB4 - 2º Semestre 2017

			PREVISÃO			
			H1		**M30**	
			Positivo	**Negativo**	**Positivo**	**Negativo**
REAL	**Price**	**Positivo (cv)**	242,72 (4,97%)	211,90 (5,92%)	486,07 (3,89%)	434,79 (3,90%)
		Negativo (cv)	202,69 (6,18%)	208,69 (4,85%)	395,83 (4,24%)	414,31 (4,56%)
	Volume	**Positivo (cv)**	247,10 (4,92%)	195,21 (4,27%)	491,97 (3,61%)	389,21 (4,30%)
		Negativo (cv)	198,03 (5,19%)	225,66 (6,33%)	409,03 (4,08%)	440,79 (3,90%)

A Tabela 11 apresenta os indicadores de desempenho das RNAs Price e Volume, no ativo ITUB4, para o 2º Semestre de 2017. Para o ITUB4 neste período, observar-se uma superioridade da RNA Volume sobre a RNA Price em todos os indicadores de desempenho, tanto em H1 quanto M30.

Na Tabela 11, o desempenho dos indicadores de ”ALTA” foram superiores aos indicadores de ”BAIXA”. em M30 e H1. Os indicadores de Volume, em geral, continuam superiores aos da RNA Price. Os indicadores das duas RNAS, na periodicidade M30, atingiram menor variação (cv) que os apresentados pelas duas RNAs em H1.

Tabela 11 – Indicadores RNA ITUB4 - 2º Semestre de 2017

	H1		**M30**	
	RNA Price	**RNA Volume**	**RNA Price**	**RNA Volume**
Acurácia (cv)	0,5213 (3,10%)	0,5459 (2,77%)	0,5201 (1,60%)	0,5389 (1,98%)
Precision(Alta) (cv)	0,5450 (4,09%)	0,5551 (3,57%)	0,5511 (2,76%)	0,5460 (2,58%)
Precision(Baixa) (cv)	0,4963 (4,19%)	0,5364 (3,88%)	0,4879 (3,26%)	0,5311 (2,84%)
Recall(Alta) (cv)	0,5340 (4,36%)	0,5587 (4,32%)	0,5278 (2,82%)	0,5583 (3,01%)
Recall(Baixa) (cv)	0,5075 (4,53%)	0,5327 (3,57%)	0,5114 (3,27%)	0,5187 (3,29%)
F1 Score(Alta) (cv)	0,5391 (3,55%)	0,5566 (3,38%)	0,5391 (2,22%)	0,5520 (2,34%)
F1 Score(Baixa) (cv)	0,5015 (3,60%)	0,5343 (3,02%)	0,4992 (2,70%)	0,5247 (2,60%)

5.2.4 PETR4

A Tabela 12 apresenta a Matriz de Confusão para as previsões das RNAs no ativo PETR4, no 2º Semestre de 2017. Em M30, a média dos FN para RNA Price foram superiores aos VN. Já os FPs para a RNA Volume foram superiores aos VPs, indicando classificações ruins nestes quesitos.

Tabela 12 – Matriz de Confusão PETR4 2º Semestre de 2017

			PREVISÃO			
			H1		**M30**	
			Positivo	**Negativo**	**Positivo**	**Negativo**
REAL	**Price**	**Positivo (cv)**	244,24 (5,75%)	214,00 (6,27%)	480,45 (4,03%)	456,55 (3,97%)
		Negativo (cv)	194,14 (6,39%)	217,62 (5,32%)	407,17 (4,62%)	396,83 (4,69%)
	Volume	**Positivo (cv)**	227,86 (6,59%)	193,83 (5,85%)	432,72 (4,34%)	390,24 (3,79%)
		Negativo (cv)	214,00 (5,17%)	234,31 (6,67%)	446,45 (3,56%)	471,59 (3,42%)

A Tabela 13 apresenta os indicadores de desempenho da predição para o ativo PETR4 no 2º semestre de 2017. O desempenho dos indicadores de ”ALTA” da RNA Price foram superiores aos indicadores de ”BAIXA” em M30 e H1. Os indicadores das duas RNAS, na periodicidade M30, atingiram menor variação (cv) que os apresentados pelas RNAs em H1.

Tabela 13 – Indicadores RNA PETR4 - 2º Semestre de 2017

	H1		**M30**	
	RNA Price	**RNA Volume**	**RNA Price**	**RNA Volume**
Acurácia (cv)	0,5309 (3,25%)	0,5312 (2,72%)	0,5039 (2,58%)	0,5194 (2,02%)
Precision(Alta) (cv)	0,5571 (4,60%)	0,5155 (4,40%)	0,5413 (3,23%)	0,4921 (3,22%)
Precision(Baixa) (cv)	0,5043 (4,82%)	0,5470 (4,57%)	0,4650 (3,64%)	0,5472 (2,41%)
Recall(Alta) (cv)	0,5330 (4,71%)	0,5401 (4,57%)	0,5127 (3,32%)	0,5257 (3,29%)
Recall(Baixa) (cv)	0,5286 (4,19%)	0,5224 (4,65%)	0,4936 (4,02%)	0,5137 (2,80%)
F1 Score(Alta) (cv)	0,5445 (4,00%)	0,5273 (3,92%)	0,5265 (2,84%)	0,5083 (2,92%)
F1 Score(Baixa) (cv)	0,5159 (3,75%)	0,5342 (4,08%)	0,4787 (3,40%)	0,5298 (2,23%)

5.3 Avaliação Financeiras das Estratégias

Os resultados apresentados são da avaliação do desempenho financeiro das estratégias no 1º semestre de 2017 para os ativos BOVA11 e VALE3. Enquanto os ativos ITUB4 e PETR4 foram avaliados na execução do experimento no 2º semestre de 2017. Os mesmos períodos apresentados para os indicadores de desempenho apresentados na seção de desempenho das RNAs. Foram alternadas as periodicidades H1 e M30 para reduzir as quantidades de resultados apresentados.

A título de referência para as comparações dos resultados financeiros dos robôs com um *bechmark* de renda fixa foi calculado o CDI acumulada para o 1º Semestre de 2017, que foi de 5,61%, no período de 01/01/2017 a 30/06/2017. Já para o 2º Semestre de 2017, entre as datas 01/07/2017 e 31/12/2017, a taxa DI acumulado foi de 4,05%, cálculo realizado por meio da calculadora oferecida pela CETIP [1].

Todos os resultados apresentados nas tabelas de indicadores financeiros foram obtidos pela média aritmética da execução do experimento trinta vezes. Isso justifica as casas decimais em alguns locais como o número de ordens executada durante a operação ou o número de ordens com perda/lucro. Para fornecer a ideia do quanto os indicadores variaram em cada execução do experimento, foi colocado um valor percentual logo abaixo da média apresentada em todas os indicadores, que corresponde ao Coeficiente de Variação (CV). O CV foi obtido dividindo-se o desvio padrão pela média apresentada. Os gráficos de Evolução do Capital apresentados são o resultado líquido de uma das 30 execuções do experimento.

5.3.1 Estratégia Simple

A Estratégia Simple é aquela que realiza operações de Compras e Vendas com base no Sinal emitido apenas pela RNA ELM de tendência de Preço (RNA Price). Abre operação quando o sinal de preço indica tendência de ALTA e fecha operação quando o sinal de preço indica tendência de BAIXA. Esta estratégia ainda tem a característica de operar comprando o máximo de lotes possível dado o capital disponível para operação no momento. Além disso, opera em tendência, ou seja, caso ocorram sucessivos sinais de ALTA a estratégia mantém a operação aberta, fechando apenas quando o sinal de tendência ocorre em sentido contrário ao da operação aberta. O *Stop Loss* utilizado para esta estratégia foi de 1%.

O Fator de Lucratividade apresentado reflete a relação entre o número de ordens com Lucro e o número de ordens com perda. Assim, percentuais acima de 100% correspondem a um número maior de operações com ganhos que número de operações com perda. É desejável aumentar o percentual de lucratividade em uma estratégia. Porém, mesmo que

[1] https://www.cetip.com.br/renda-fixa/calculadora-di

ela seja menor que 100%, indicando que há mais operações com perda que com ganhos, a estratégia ainda pode se apresentar lucrativa se a média de Lucro de operações com ganho forem superiores à média de operações com perda.

O Fator de Lucro é um dos principais indicadores apresentados e estabelece a relação entre o Lucro de todas as operações com lucro e a Perda de todas as operações com perda da estratégia. Valores para o Fator de Lucro acima de 1 significa que a estratégia apresentou-se lucrativa e abaixo de 1 a estratégia obteve prejuízo.

Os indicadores financeiros serão apresentados para avaliar o desempenho apenas das COMPRAS separadamente do desempenho das VENDAS a descoberto.

5.3.1.1 BOVA11

A estratégia Simple no ativo BOVA11 em H1 embora tenha sido lucrativa nas compras, obteve um desempenho financeiro geral ruim, no 1º semestre de 2017. Apesar de ter atingido um retorno financeiro positivo e superior às estratégias *Buy and hold* e Randômico, mas perdeu para CDI.

A Figura 18 apresenta a Curva de Evolução do Capital médio para a Estratégia Simple, que considera apenas o sinal de preço. Executando apenas as ordens de Compra no ativo BOVA11, no 1º semestre de 2017.

Avaliando o resultado financeiro obtido pelas operações de Compras executadas no período, a estratégia Simple atingiu Net Profit líquido de 1,09% nos 6 meses. Perdeu também para o CDI, que apresentou 5.61% entre 01/01/2017 e 30/06/2017.

Figura 18 – Evolução do Capital COMPRAS BOVA11 H1 - 1º SEM/2017

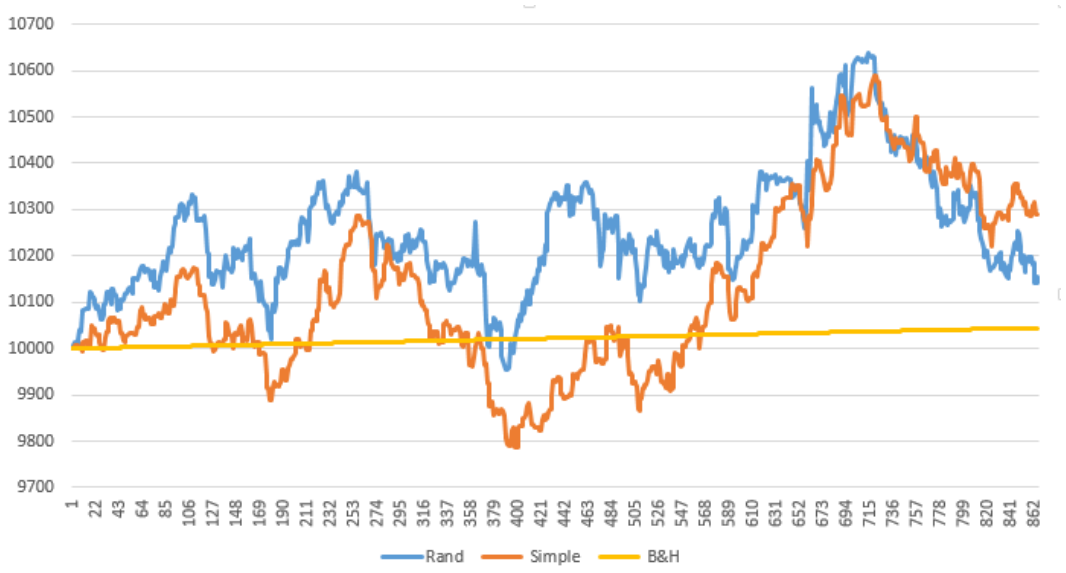

Fonte: Elaborado pelo autor com uso do Robô

Há evidências em dois pontos principais que podem explicar em parte o baixo de-

sempenho do Robô Simple. Primeiramente à taxa de predição nos indicadores *Precision* de Alta em BOVA11 H1. Em segundo lugar, de acordo com a caracterização do ativo BOVA11, o percentual *candles* acima dos custos operacionais estimados se apresentou baixa. Com a volatilidade baixa nos retornos, o ativo não apresentou características adequadas o suficiente para a execução desta estratégia de operação.

A Figura 19 apresenta a Curva de Evolução do Capital médio para a Estratégia Simple, que considera apenas o sinal da RNA de tendência de Preço. Executando apenas as ordens de venda no ativo BOVA11 em H1, no 1º semestre de 2017.

Avaliando o resultado financeiro atingido pelas operações de vendas, o desempenho foi ruim neste caso, atingindo Lucro Liquido negativo. O baixo desempenho do *Precision* de Baixa da RNA Price foi de 0,4895, no período, o que fornece evidências para explicar o comportamento em parte.

Figura 19 – Evolução do Capital VENDAS BOVA11 H1 - 1º SEM/2017

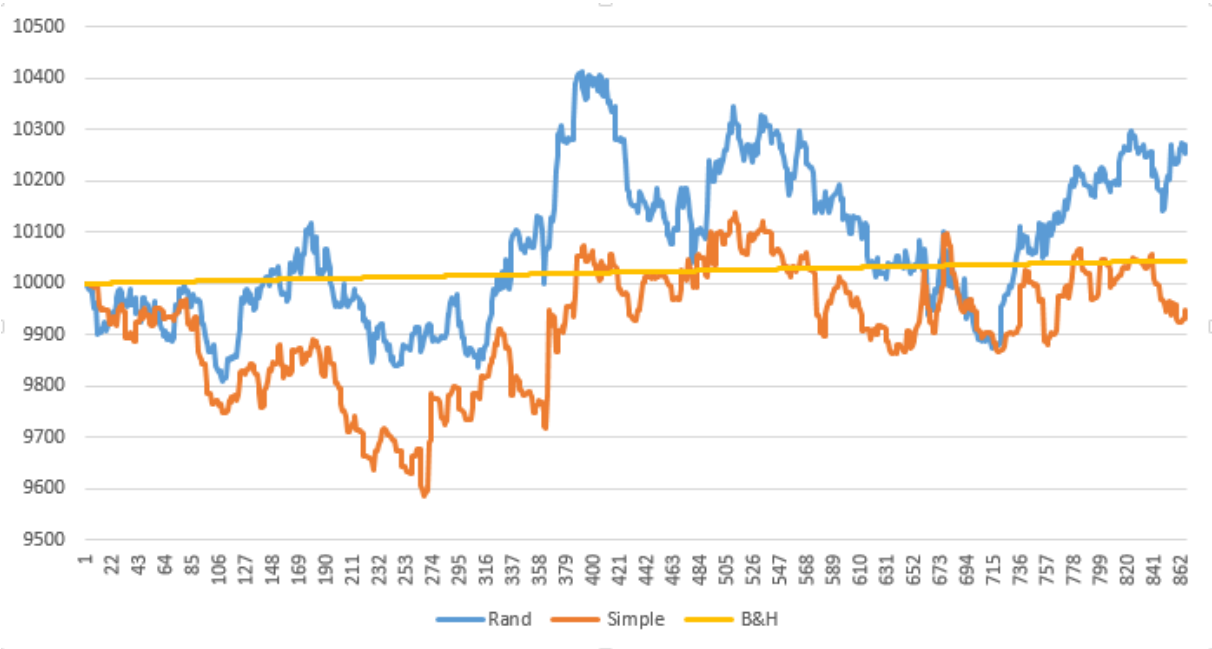

Fonte: Elaborado pelo autor com uso do Robô

A Tabela 14 apresenta os resultados financeiros médios de Compras e Vendas, brutos e líquidos, da estratégia Simple executada sobre o ativo BOVA11 H1, durante o 1º semestre 2017.

Foram, em média, 216 operações nesta estratégia. Mesmo com o lucro médio sendo superior, em todos os casos, o Fator de lucratividade de ordens impactou mais negativamente, o que levou a Estratégia Simple a um baixo desempenho financeiro espelhado no Net Profit no semestre.

A Estratégia Simple, apresentou Net Profit positivo para Compras. Porém o índice é baixo quando analisado o líquido de 1,09% frente aos 5,61% do CDI no período de 6 meses.

Para as operações de venda apresentou uma perda de 4,31% no período. Justificado em parte pelo baixo desempenho de predição da rede em previsões de baixa, além da baixa volatilidade apresentada nos *candles* do ativo neste período.

Tabela 14 – Estratégia ELM Simple Price BOVA11 H1 - 1º Semestre de 2017

	BOVA11 - H1			
	COMPRAS		**VENDAS**	
	Bruto	**Líquido**	**Bruto**	**Líquido**
Nº de Operações	215,93 (3,85%)		215,87 (3,55%)	
Nº Operações com Lucro	109,97 (6,48%)	105,00 (6,77%)	101,83 (6,10%)	096,20 (6,37%)
Nº Operações com Perda	105,97 (6,61%)	110,93 (5,95%)	114,03 (5,97%)	119,67 (5,10%)
Lucro Total	R$ 4.879,60 (14,68%)	R$ 4.524,96 (15,59%)	R$ 4.391,39 (15,68%)	R$ 4.064,49 (16,86%)
Perda Total	-R$ 4.066,41 (6,54%)	-R$ 4.416,23 (6,34%)	-R$ 4.118,31 (6,46%)	-R$ 4.495,11 (6,12%)
Fator de Lucratividade	104,35% (10,51%)	95,08% (10,13%)	89,69% (9,47%)	80,64% (8,90%)
Lucro Médio por Operação	R$ 44,35 (12,74%)	R$ 43,07 (13,63%)	R$ 43,22 (16,47%)	R$ 42,33 (17,20%)
Perda Média por Operação	-R$ 38,44 (6,03%)	-R$ 36,70 (5,80%)	-R$ 36,19 (6,84%)	-R$ 34,46 (6,34%)
Net Profit + Capital Inicial	R$ 10.813,20 (6,74%)	R$ 10.108,73 (7,21%)	R$ 10.273,08 (6,77%)	R$ 9.569,38 (7,27%)
Fator de Lucro	1,20 (15,63%)	1,03 (16,48%)	1,07 (16,14%)	0,91 (17,16%)

5.3.1.2 VALE3

Os resultados da estratégia Simple executada em VALE3 atingiram desempenho financeiro superior aos alcançados pela mesma Estratégia em BOVA11. A estratégia Simple, neste caso, superou as estratégias Randômicas, *Buy and Hold* e superior ainda ao CDI, que atingiu 5,61% no período.

A Figura 20 apresenta o gráfico de Evolução do Capital médio da Estratégia Simple executada apenas para ”Compras”, sobre o ativo VALE3-M30, no 1º semestre 2017. Verifica-se no gráfico que a Estratégia Simple superou o a Estratégia Randômica e *Buy and Hold* todo o tempo.

A Figura 21 apresenta o gráfico de Evolução do Capital da Estratégia Simple, executada apenas para operações abertas no sentido vendido, sobre o ativo VALE3-M30, no 1º semestre 2017. Verifica-se no gráfico que a Estratégia Simple superou a Estratégia Randômica quase todo o período.

Figura 20 – Evolução do Capital COMPRAS VALE3 M30 - 1º SEM/2017

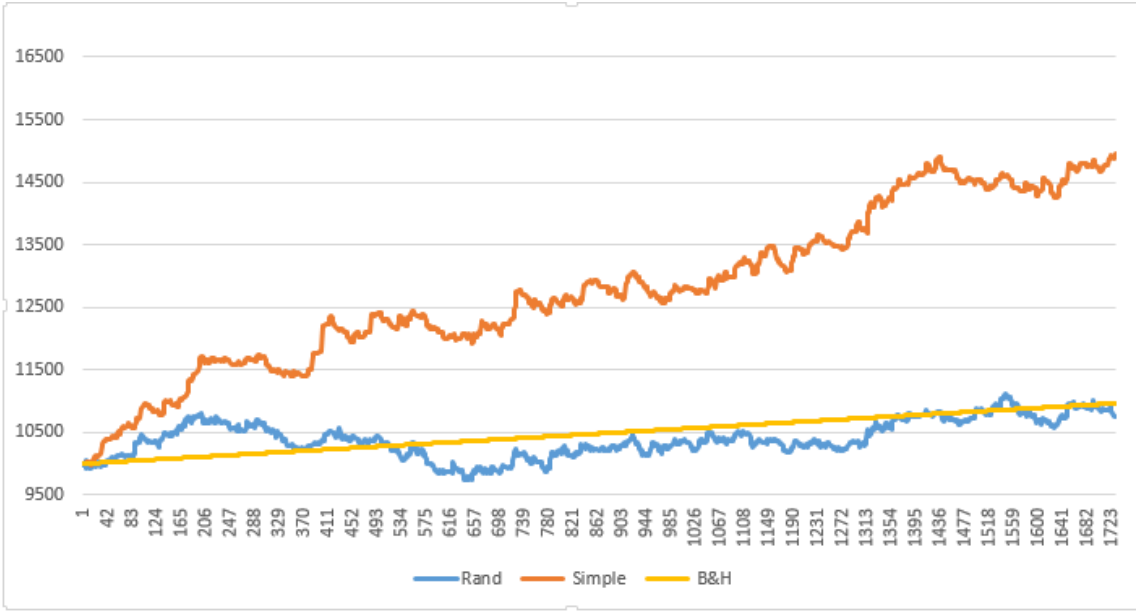

Fonte: Elaborado pelo autor com uso do Robô

O desempenho financeiro inferior das vendas em relação às compras no ativo podem ser explicados também pela análise dos indicadores de predição apresentados na Tabela 9, onde nota-se que os resultados dos indicadores de previsão da RNA Price para Altas foram superiores aos de Baixa.

Figura 21 – Evolução do Capital VENDAS VALE3 M30 - 1º SEM/2017

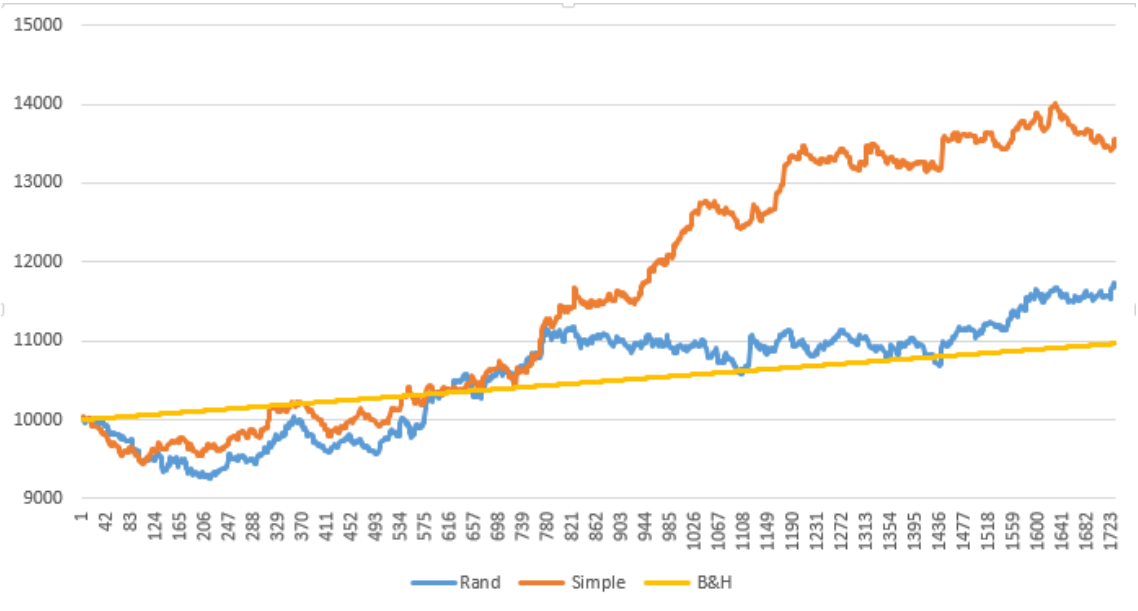

Fonte: Elaborado pelo autor com uso do Robô

A Tabela 15 apresenta o resultado financeiro das operações de compra e venda, bruto e líquido, da estratégia Simple executada sobre o ativo VALE3-M30, durante o 1º semestre 2017.

Ao final, o resultado apresentado no Net Profit Líquido das operações de Compra, foi de 25,82% no semestre, superando o CDI de 5,61% do mesmo período. Enquanto o Net Profit Líquido das operações de Compra atingiu 23,18%. Os coeficientes de variação foram de 12,57% e 11,64%, respectivamente. O *Buy and Hold* no período apresentou 10,06% de alta no 1º Semestre de 2017.

Tabela 15 – Estratégia ELM Simple Price VALE3 M30 - 1º Semestre de 2017

	VALE3 - M30			
	COMPRAS		**VENDAS**	
	Bruto	**Líquido**	**Bruto**	**Líquido**
Nº de Operações	432,57 (2,03%)		434,52 (2,97%)	
Nº Operações com Lucro	206,40 (4,41%)	202,43 (4,83%)	216,17 (4,80%)	211,97 (5,05%)
Nº Operações com Perda	226,17 (4,36%)	230,13 (4,63%)	218,34 (4,21%)	222,55 (4,39%)
Lucro Total	R$ 15.768,97 (14,08%)	R$ 15.095,11 (14,61%)	R$ 15.035,62 (12,43%)	R$ 14.331,15 (12,96%)
Perda Total	-R$ 11.774,47 (6,92%)	-R$ 12.513,03 (6,53%)	-R$ 11.298,08 (6,13%)	-R$ 12.013,24 (5,85%)
Fator de Lucratividade	91,53% (7,92%)	88,27% (8,62%)	99,20% (6,90%)	95,47% (7,52%)
Lucro Médio por Operação	R$ 76,33 (12,92%)	R$ 74,44 (12,85%)	R$ 69,60 (12,34%)	R$ 67,61 (12,31%)
Perda Média por Operação	-R$ 52,15 (7,91%)	-R$ 51,28 (8,44%)	-R$ 51,79 (6,16%)	-R$ 50,83 (6,68%)
Net Profit + Capital Inicial	R$ 13.994,50 (11,26%)	R$ 12.582,08 (12,57%)	R$ 13.737,54 (10,54%)	R$ 12.317,91 (11,64%)
Fator de Lucro	1,34 (10,22%)	1,20 (11,01%)	1,33 (8,46%)	1,19 (9,20%)

Embora a Estratégia Simple tenha apresentado um bom desempenho financeiro global, o Fator de Lucratividade, que mostra a relação entre ordens com lucro e com perda, apresentou-se baixo em todas as situações. Assim, justifica-se o uso de artifícios para reduzir o número de ordens (*Trade Filters*) com perda, como a tentativa de incluir a validação de abertura de ordens considerando outros sinais, como o sinal de previsão de tendência emitido pela RNA Volume na próxima seção.

5.3.1.3 ITUB4

Os resultados de compras, da Estratégia Simple executada para ITUB4 H1, no 2º Semestre de 2017, mostram resultados próximos ao *Buy and Hold* e se apresentou melhor que a estratégia Randômica. Conforme verificado na Figura 22 que contém o Gráfico de Evolução do Capital.

Figura 22 – Evolução do Capital COMPRAS ITUB4 H1 - 2º SEM/2017

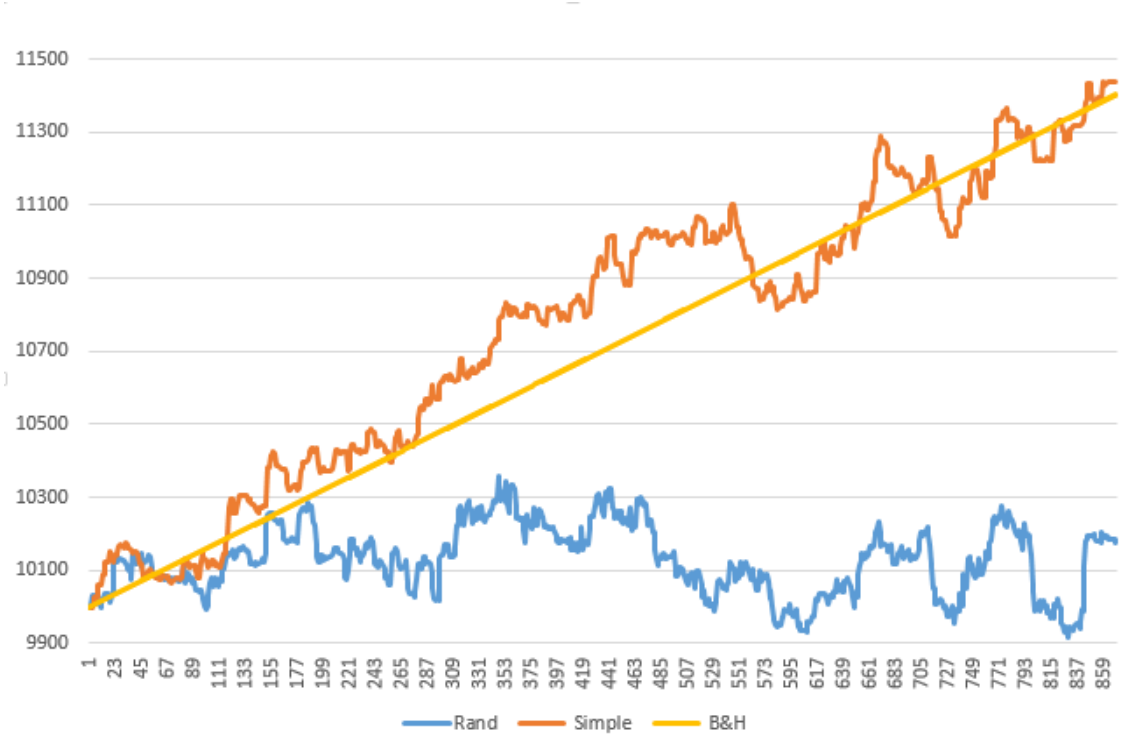

Fonte: Elaborado pelo autor com uso do Robô

Ao analisar as Vendas geradas pela Estratégia Simple executada em ITUB4 H1, no 2º Semestre de 2017, verifica-se um baixo desempenho frente ao *Buy and Hold*. O Gráfico da Figura 23 mostra a Evolução do Capital médio sobre das operações realizadas.

Considerando que estão sendo avaliadas apenas as operações de vendas, que aferem lucro nas baixas, fica mais difícil para o robô executar estratégias com alto desempenho financeiro quando opera em sentido contrário à tendência. Este caso pode ser verificado pelo rendimento da estratégia *Buy and Hold*, que evidencia há um período de altas. Assim, a Estratégia Simple atingiu um resultado de negativo de Net Profit Líquido para as operações de venda.

Um segundo fator importante que impactou negativamente no desempenho financeiro foi o baixo desempenho na predição de baixas da Rede observado na Tabela 11, na qual o *Precision* de baixa mostrou-se inferior ao *Precision* de Alta para RNA Price em H1. Na maioria dos casos, assim como nos outros ativos os indicadores de predição de Baixa foram, em geral, piores que os de alta. Este fato refletiu diretamente no desempenho financeiro na execução das estratégias executando operações de venda.

A Tabela 16 mostra os resultados atingidos pela Estratégia Simple em ITUB4 H1. Observa-se que houve um Net Profit médio de 12,17% bruto, frente a 5,12% líquido. Já na análise das operações de VENDAS realizada com a estratégia houve uma perda de -6,67% do Net Profit. Assim, a estratégia apresentou-se mais adequada para operações de compra

Figura 23 – Evolução do Capital VENDAS ITUB4 H1 - 2º SEM/2017

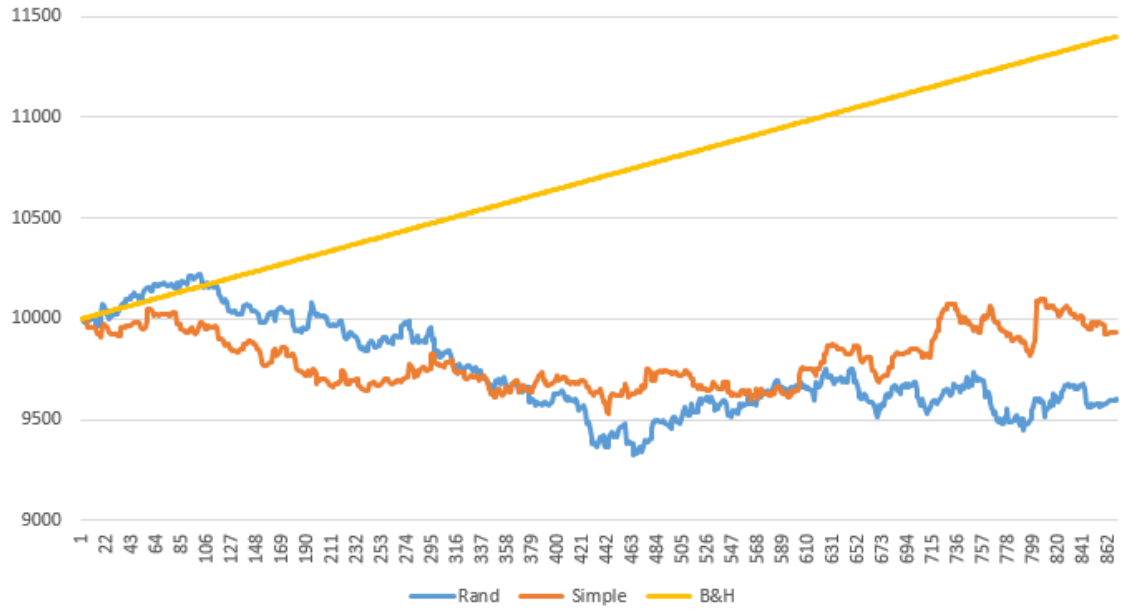

Fonte: Elaborado pelo autor com uso do Robô

neste ativo no período.

5.3.1.4 PETR4

A Estratégia Simple executada para PETR4 M30, apresentou-se lucrativa, embora não tenha superado a estratégia de *Buy and Hold*, que neste caso atípico, teve rendimentos superiores a 30% no semestre.

A Figura 24 apresenta o Gráfico de Evolução do Capital médio da Estratégia Simple executada apenas para Compras, sobre o ativo PETR4 - M30, no 2º semestre 2017. Verifica-se no Gráfico que a Estratégia Simple superou a Estratégia Randômica e *Buy and Hold* todo o período.

A Figura 25 apresenta o Gráfico de Evolução do Capital médio da Estratégia Simple executada apenas para Vendas, sobre o ativo PETR4 - M30, no 2º semestre 2017.

A Tabela 17 mostra os resultados atingidos pela Estratégia Simple em PETR4 M30.

Mas uma vez observou-se um baixo rendimento no desempenho da Estratégia Simple para as ordens de venda. O Net Profit Líquido, para Compras foi de 7,20%, com coeficiente de variação de 9,53%. O CDI do período foi de 4,05%, enquanto o *Buy and Hold* atingiu 14,02%.

5.3.2 Estratégia ELM Simple x ELM Price & Volume

A Estratégia Simple é aquela que realiza operações de Compras e Vendas com base no Sinal emitido apenas pela RNA ELM de tendência de Preço. Já a Estratégia ”*Price*

Tabela 16 – Estratégia ELM Simple Price ITUB4 H1 - 2º Semestre de 2017

	ITUB4 - H1			
	COMPRAS		**VENDAS**	
	Bruto	**Líquido**	**Bruto**	**Líquido**
Nº de Operações	216,10 (2,97%)		215,52 (3,85%)	
Nº Operações com Lucro	107,03 (6,72%)	102,03 (6,79%)	102,34 (8,60%)	097,07 (8,47%)
Nº Operações com Perda	109,07 (6,84%)	114,07 (6,44%)	113,17 (6,01%)	118,45 (5,28%)
Lucro Total	R$ 4.795,17 (10,23%)	R$ 4.451,52 (10,68%)	R$ 4.026,76 (10,68%)	R$ 3.698,79 (11,04%)
Perda Total	-R$ 3.578,38 (8,01%)	-R$ 3.939,80 (7,70%)	-R$ 3.991,30 (7,69%)	-R$ 4.366,16 (7,37%)
Fator de Lucratividade	98,85% (12,16%)	90,03% (11,75%)	90,94% (12,26%)	82,29% (11,21%)
Lucro Médio por Operação	R$ 44,82 (7,96%)	R$ 43,62 (7,69%)	R$ 39,35 (6,75%)	R$ 38,09 (6,71%)
Perda Média por Operação	-R$ 32,84 (5,97%)	-R$ 31,40 (6,17%)	-R$ 35,28 (5,70%)	-R$ 33,69 (5,58%)
Net Profit + Capital Inicial	R$ 11.216,80 (5,54%)	R$ 10.511,72 (5,88%)	R$ 10.035,46 (5,53%)	R$ 9.332,63 (5,87%)
Fator de Lucro	1,35 (14,47%)	1,14 (14,65%)	1,02 (14,01%)	0,85 (14,08%)

and Volume" (PriceVol) considera sinais da RNA de Preço e sinais da RNA de Volume para tomar a decisão nas operações de compra e venda, sendo esta a única diferença entre as duas Estratégias.

As estratégias tem a característica de operar com todo o poder de compra dado o valor da ação no momento. Além disso, operam em tendência, ou seja, caso ocorram sucessivos sinais indicando compra, a operação é mantida aberta. O fechando da operação ocorre apenas quando o sinal é emitido em sentido contrário ao da operação aberta. O *Stop Loss* utilizado para as estratégias foi de 1%.

Como a Estratégia Simple não apresentou bons resultados para BOVA11, em decorrência em parte da volatilidade do ativo não estar adequada para as periodicidades e características de sinais em que o robô executa as operações. Assim, este ativo será retirado das comparações nesta seção. Como a Estratégia Simple também apresentou resultados financeiros ruins quando operando vendas, nas próximas comparações serão apresentadas apenas as compras. Assim, serão feitas comparações dos melhores resultados da Estratégia Simple com a Estratégia PriceVol, a fim de verificar a sua qualidade e desempenho.

Figura 24 – Evolução do Capital COMPRAS PETR4 M30 - 2º SEM/2017

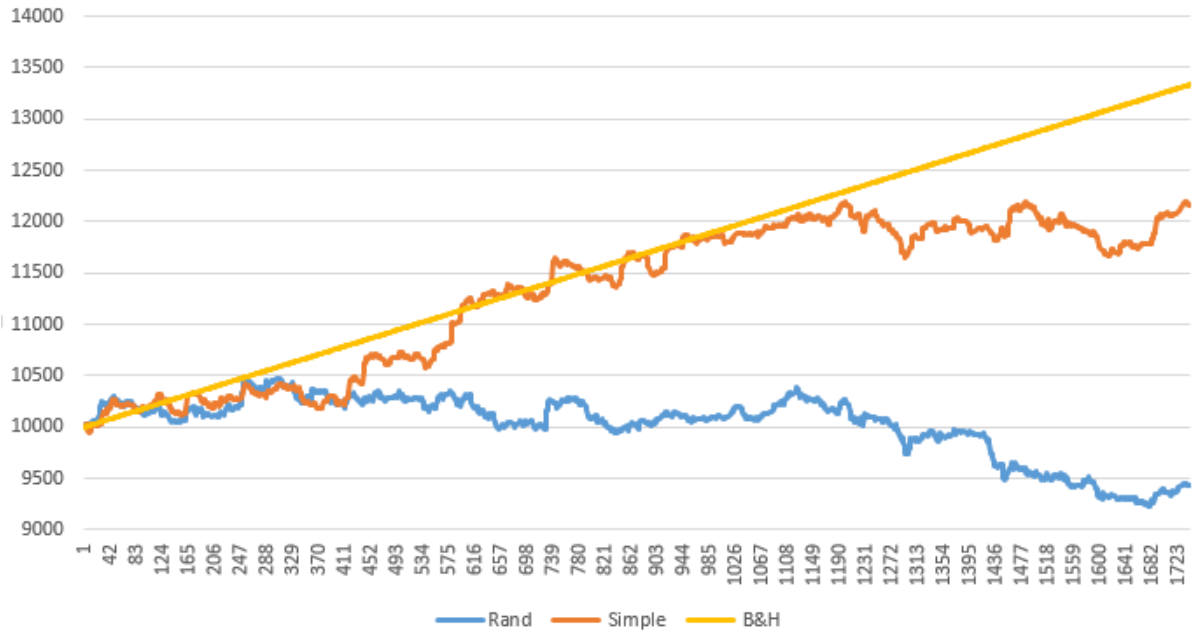

Fonte: Elaborado pelo autor com uso do Robô

Figura 25 – Evolução do Capital VENDAS PETR4 M30 - 2º SEM/2017

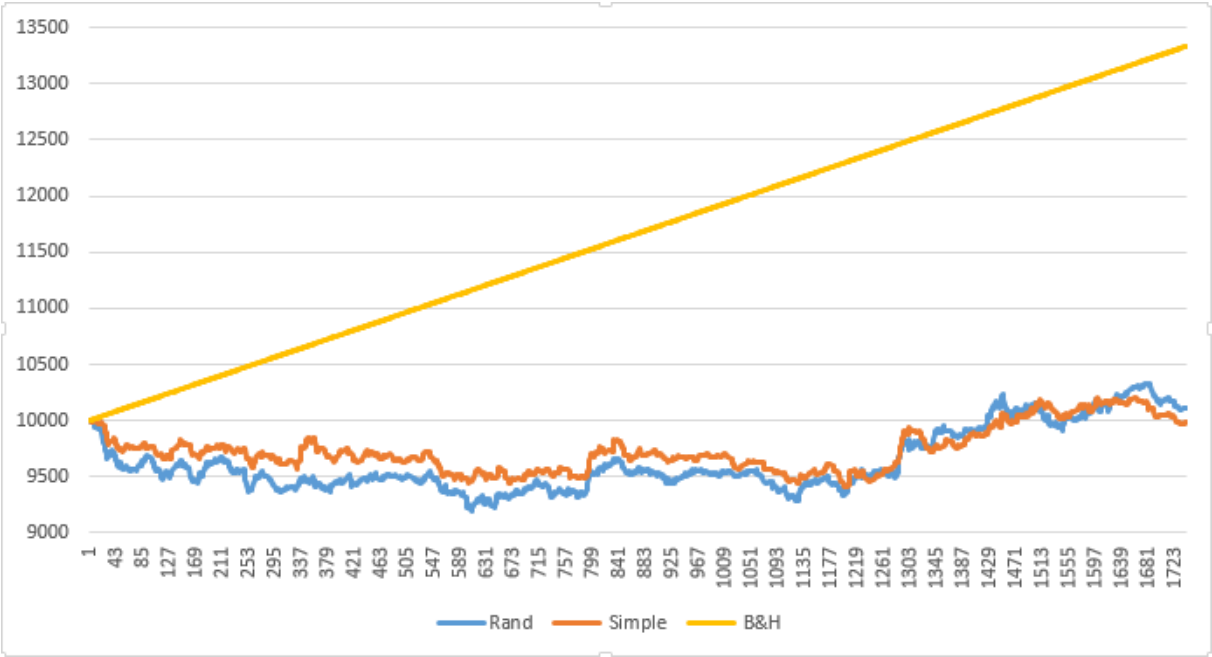

Fonte: Elaborado pelo autor com uso do Robô

5.3.2.1 VALE3

As duas estratégias tiveram um bom desempenho para Compras em VALE3, tanto em M30 quanto em H1. O Net Profit da Estratégia PriceVol foi superior em M30 mas inferior na periodicidade H1. Entretanto, a Estratégia PriceVol atingiu um maior Fator de Lucro e menor Maxdrawdown (MDD) nos dois casos, VALE3 M30 e H1. O MDD foi, em média, 1%

Tabela 17 – Estratégia ELM Simple Price PETR4 M30 - 2º Semestre de 2017

	PETR4 - M30			
	COMPRAS		**VENDAS**	
	Bruto	**Líquido**	**Bruto**	**Líquido**
Nº de Operações	434,03 (2,38%)		427,28 (2,71%)	
Nº Operações com Lucro	204,52 (5,21%)	204,52 (5,21%)	191,00 (5,08%)	191,00 (5,08%)
Nº Operações com Perda	229,52 (3,97%)	229,52 (3,97%)	236,28 (4,56%)	236,28 (4,56%)
Lucro Total	R$ 9.541,03 (12,50%)	R$ 8.872,26 (13,30%)	R$ 6.301,69 (8,97%)	R$ 5.677,12 (9,62%)
Perda Total	-R$ 7.402,56 (5,38%)	-R$ 8.151,50 (4,94%)	-R$ 6.863,51 (3,98%)	-R$ 7.634,66 (3,76%)
Fator de Lucratividade	89,32% (7,82%)	89,32% (7,82%)	81,07% (8,14%)	81,07% (8,14%)
Lucro Médio por Operação	R$ 46,67 (11,75%)	R$ 43,40 (12,63%)	R$ 32,99 (7,15%)	R$ 29,72 (7,93%)
Perda Média por Operação	-R$ 32,29 (6,32%)	-R$ 32,29 (6,32%)	-R$ 29,09 (4,91%)	-R$ 29,09 (4,91%)
Net Profit + Capital Inicial	R$ 12.138,47 (8,39%)	R$ 10.720,76 (9,53%)	R$ 9.438,18 (5,97%)	R$ 8.042,46 (7,00%)
Fator de Lucro	1,29 (10,74%)	1,09 (11,72%)	- 0,92 (9,12%)	- 0,74 (9,85%)

menor que a Estratégia Simple.

O Gráfico da Figura 26 apresenta a Evolução do Capital médio, para as estratégias de operação em VALE3 M30, durante o 1º Semestre de 2017. Neste caso, a Evolução do Capital da Estratégia PriceVol obteve resultados financeiro superiores aos da Estratégia Simple. Além disso, existem outros fatores nos quais a PriceVol se destacou, como menor MDD médio, maior Fator de Lucro, e menor quantidade de operações.

O Gráfico da Figura 27 apresenta a Evolução do Capital médio, para as estratégias de operação em VALE3 H1, durante o 1º Semestre de 2017. Neste caso, a Evolução do Capital da Estratégia Simple obteve resultados Net Profit Líquido superior aos da Estratégia PriceVol. No entanto, existem outros fatores nos quais a PriceVol se destacou, como MDD, o Fator de Lucro, e menor quantidade de operações.

A Tabela 18 mostra os resultados alcançados pela execução das duas Estratégias, Simple e PriceVol, executadas em VALE3 H1 e M30, no 1º semestre de 2017. Nota-se primeiramente que o número de ordens abertas pela Estratégia Simple foi quase o dobro de ordens executadas da Estratégia PriceVol.

O Fator de Lucro é um indicador muito utilizado na comparação do desempenho financeiro de robôs de investimento. Quanto maior o Fator de Lucro, maior será o Lucro em

Figura 26 – Evolução do Capital COMPRAS VALE3 M30 - 1º SEM/2017

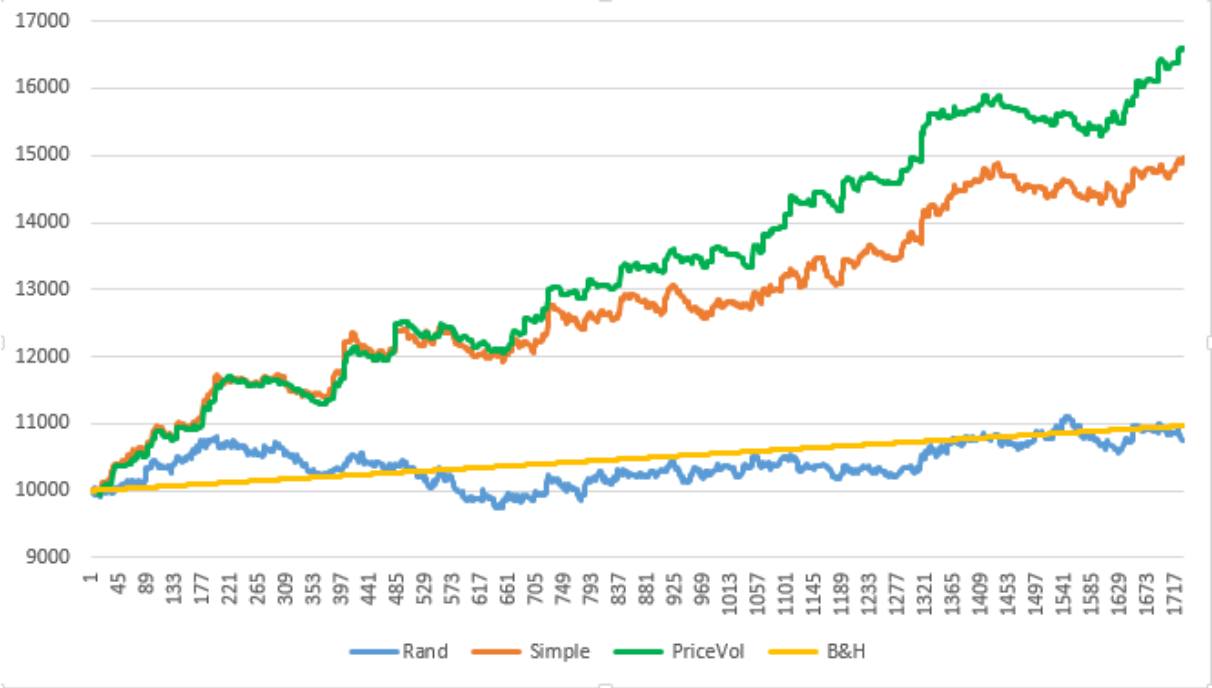

Fonte: Elaborado pelo autor com uso do Robô

relação as Perdas. Se a estratégia PriceVol atingisse o Lucro Total de R$ 11.981,82 (da Estratégia Simple em H1), como PriceVol H1 apresentou Fator de Lucro igual a 1,91, teria perdido apenas R$ 6.273,20, frente aos R$ 7.733,79 de Perdas da Estratégia Simple. Isso daria à Estratégia PriceVol um Lucro Líquido de R$ 5.708,62, lucro superior ao apresentado pela Estratégia Simple de R$ 4.248,03. Isso significa que o risco da estratégia PriceVol é menor que o risco da estratégia Simple, ou seja, é mais seguro investir na estratégia PriceVol.

O Fator de Lucro de PriceVol foi maior, passando de 1,20 na Simple M30 para 1,53 na PriceVol M30 e de 1,54 na Simple H1 para 1,91 na PriceVol H1. Assim, a estratégia apresentou-se com menor risco, avaliando por este indicador.

Os resultados apresentado na Tabela 18 são valores líquidos, descontados dos custos operacionais de corretagem estimados para as transações. É possível observar que a estratégia PriceVol atingiu melhores resultados na maior parte dos indicadores financeiros. Apresentou melhores indicadores no número de Operações, que foi reduzido. O Fator de Lucratividade atingiu índices maiores. O Lucro Médio das operações foi superior. O Fator de Lucro médio foi superior e o Maxdrawdown médio foi reduzido.

5.3.2.2 ITUB4

Analisando o Net Profit Total das estratégias em ITUB4, a Estratégia PriceVol mostrou-se superior à Estratégia Simple em M30, mas inferior em H1. O Fator de Lucro e o MDD foi superior em todos os casos. A quantidade de operações abertas em PriceVol

Figura 27 – Evolução do Capital COMPRAS VALE3 H1 - 1º SEM/2017

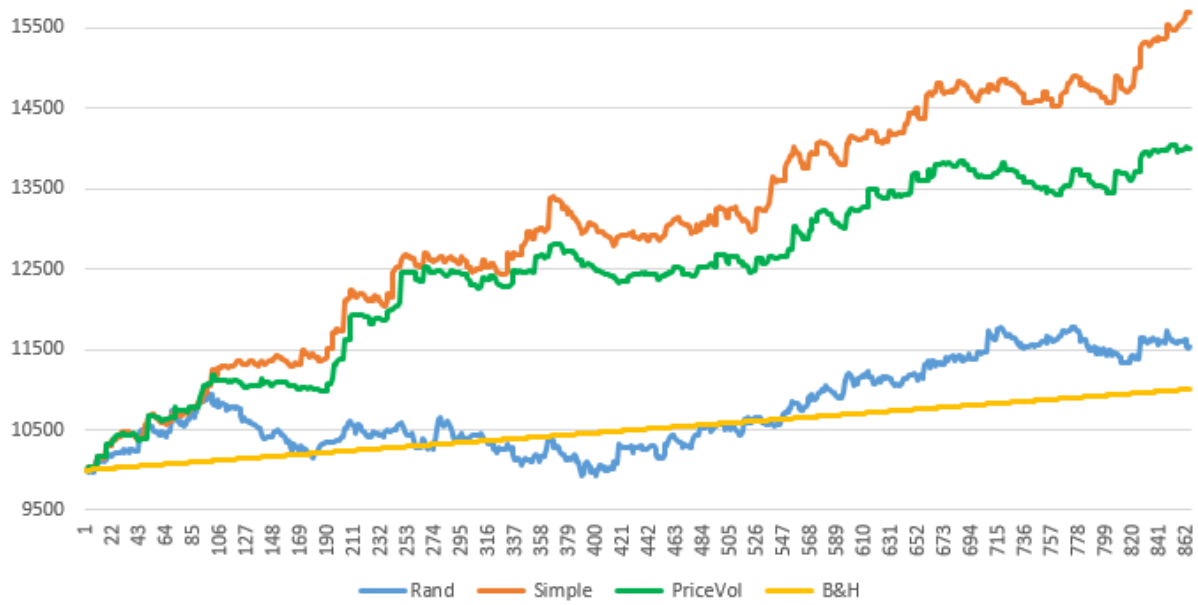

Fonte: Elaborado pelo autor com uso do Robô

continuam próximas da metade abertas pela Estratégia Simple.

O Gráfico da Figura 28 expõe a Evolução do Capital médio das Estratégias operando em COMPRAS no ativo ITUB4 M30 no 2º Semestre de 2017. Observa-se que a estratégia PriceVol teve um comportamento superior às outras na maior parte do semestre, embora não tenha atingindo o Net Profit de Buy and Hold ao final do período.

Figura 28 – Evolução do Capital COMPRAS ITUB4 M30 - 2º SEM/2017

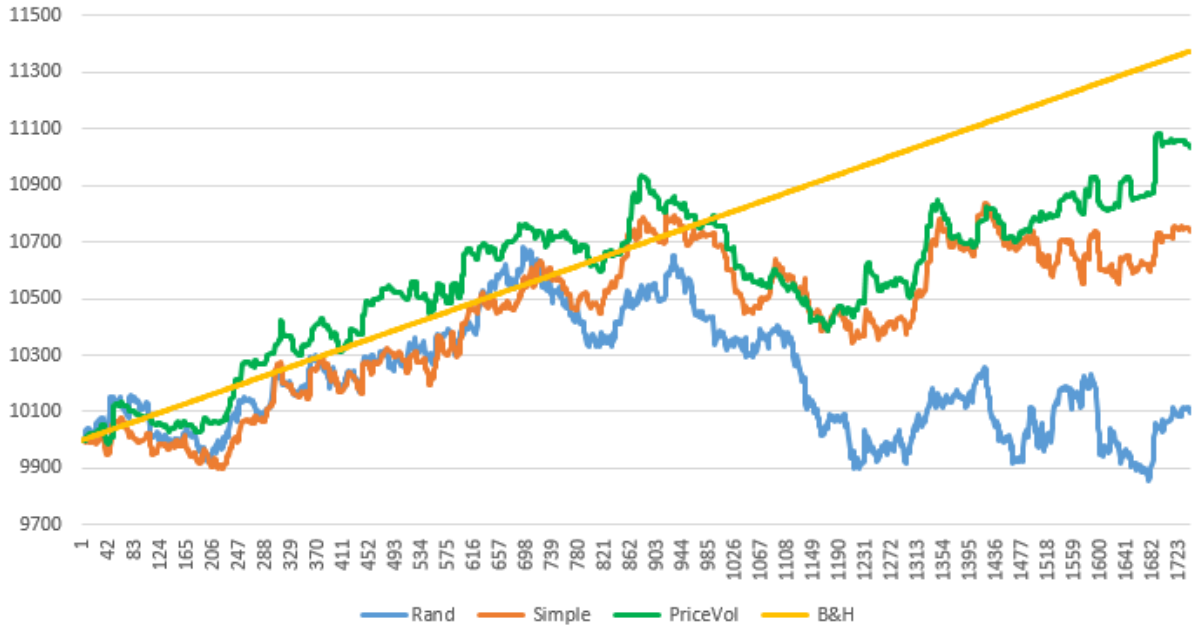

Fonte: Elaborado pelo autor com uso do Robô

Tabela 18 – Comparativo Estratégia Simple X PriceVol VALE3 1º Sem/2017

	VALE3			
	M30		**H1**	
	Simple	**PriceVol**	**Simple**	**PriceVol**
Nº de Operações	432,57 (2,03%)	219,87 (3,56%)	214,93 (3,78%)	111,53 (7,57%)
Nº Op. c/ Lucro	202,43 (4,83%)	106,40 (6,70%)	105,23 (6,20%)	053,83 (10,70%)
Nº Op. c/ Perda	230,13 (4,63%)	113,47 (7,90%)	109,70 (6,28%)	057,70 (10,36%)
Lucro Total	R$ 15.095,11 (14,61%)	R$ 11.466,24 (17,58%)	R$ 11.981,82 (18,12%)	R$ 8.545,37 (18,37%)
Perda Total	-R$ 12.513,03 (6,53%)	-R$ 7.510,05 (8,78%)	-R$ 7.733,79 (9,49%)	-R$ 4.484,84 (11,31%)
% Lucrat.	88,27% (8,62%)	94,62% (13,07%)	96,36% (9,41%)	94,18% (14,24%)
Lucro Médio	R$ 74,44 (12,85%)	R$ 107,56 (15,17%)	R$ 113,65 (16,09%)	R$ 158,51 (14,05%)
Net Profit + Capital Inicial	R$ 12.582,08 (13,26%)	R$ 13.956,19 (12,70%)	R$ 14.248,03 (11,67%)	R$ 14.060,53 (9,89%)
Fator de Lucro	1,20 (11,01%)	1,53 (15,93%)	1,54 (12,66%)	1,91 (16,96%)
Maxdrawdown	-7,87% (29,12%)	-6,47% (31,08%)	-6,64% (30,52%)	-5,99% (25,94%)

O Gráfico da Figura 29 mostra a Evolução do Capital das Estratégias operando em COMPRAS no ativo ITUB4 H1 no 2º Semestre de 2017. Neste caso, a estratégia PriceVol teve um comportamento superior às outras praticamente todo do semestre, atingindo ainda um Net Profit superior ao final do período.

A Tabela 19 expõe os dados médios da execução das estratégias em ITUB4 no 2º semestre de 2017. É importante observar que, mais uma vez, a Estratégia PriceVol apresentou Fator de Lucro superior e MDD inferior aos alcançados pela estratégia Simple, tanto em M30 quanto em H1.

5.3.2.3 PETR4

Em PETR4, avaliando o indicador Net Profit, as estratégias apresentaram um bom desempenho, embora tenham sido inferiores ao *Buy and Hold*, que teve uma lucratividade de quase 35% no semestre. O Net Profit de PriceVol foi superior ao alcançado pela estratégia Simple e continuou executando quase a metade das ordens que foram executadas pela Simple. A estratégia PriceVol atingiu maior Fator de Lucro e menor MDD em todos os casos.

O Gráfico da Figura 30 mostra a Evolução do Capital para as estratégias executando ordens de compra em PETR4 M30 no 2º Semestre de 2017.

Figura 29 – Evolução do Capital COMPRAS ITUB4 H1 - 2º SEM/2017

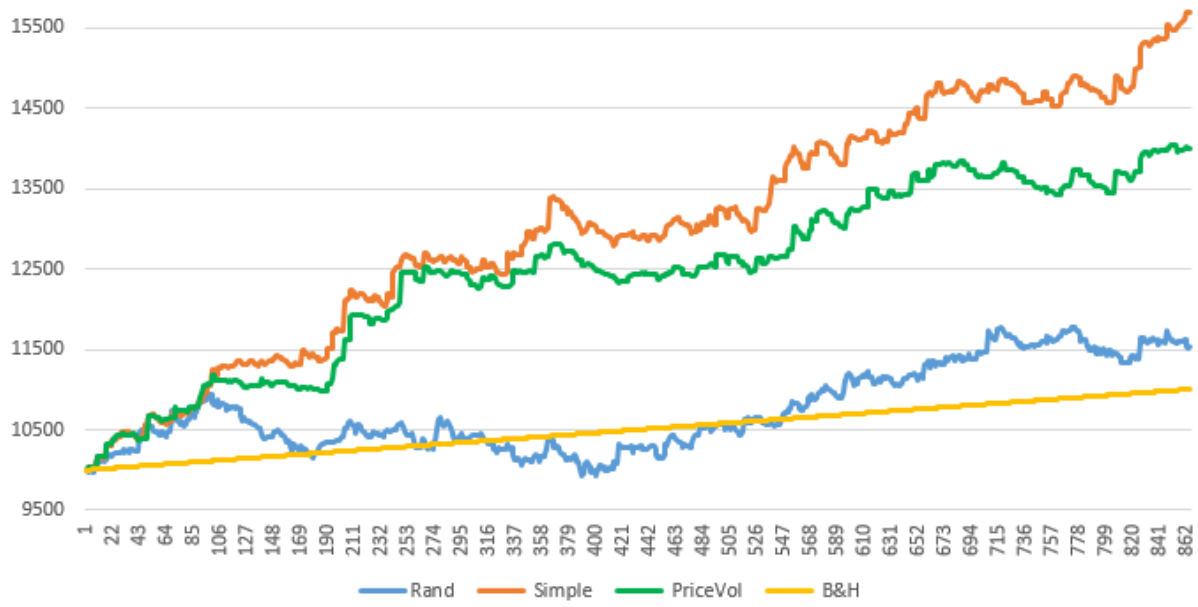

Fonte: Elaborado pelo autor com uso do Robô

Figura 30 – Evolução do Capital COMPRAS PETR4 M30 - 2º SEM/2017

Fonte: Elaborado pelo autor com uso do Robô

O Gráfico da Figura 31 mostra a Evolução do Capital para as estratégias executando ordens de compra em PETR4 H1 no 2º Semestre de 2017.

A Tabela 20 expõem os dados das Estratégias Simple e PriceVol, executadas em PETR4 no 2º Semestre de 2017.

Analisando o Fator de Lucro para PETR4, no segundo semestre de 2017, verifica-se

Tabela 19 – Comparativo Estratégia Simple X PriceVol ITUB4 2º Sem/2017

	ITUB4			
	M30		**H1**	
	Simple	**PriceVol**	**Simple**	**PriceVol**
Nº de Operações	436,45 (2,69%)	222,55 (3,85%)	216,10 (2,97%)	111,83 (4,85%)
Nº Op. c/ Lucro	204,28 (4,59%)	106,00 (6,82%)	102,03 (6,79%)	053,14 (9,30%)
Nº Op. c/ Perda	232,17 (4,54%)	116,55 (5,93%)	114,07 (6,44%)	058,69 (9,24%)
Lucro Total	R$ 5.718,29 (5,40%)	R$ 4.417,00 (9,62%)	R$ 4.451,52 (10,68%)	R$ 3.284,17 (13,28%)
Perda Total	-R$ 6.142,70 (5,61%)	-R$ 3.855,87 (7,42%)	-R$ 3.939,80 (7,70%)	-R$ 2.343,47 (11,01%)
% Lucrat.	88,21% (7,35%)	91,33% (9,78%)	90,03% (11,75%)	91,62% (15,71%)
Lucro Médio	R$ 28,02 (5,48%)	R$ 41,73 (8,93%)	R$ 43,62 (7,69%)	R$ 61,83 (9,78%)
Perda Média	-R$ 23,34 (5,61%)	-R$ 29,93 (5,45%)	-R$ 31,40 (6,17%)	-R$ 36,79 (8,05%)
Net Profit + Capital Inicial	R$ 9.575,60 (5,57%)	R$ 10.803,16 (7,31%)	R$ 10.511,72 (5,88%)	R$ 10.561,13 (5,04%)
Fator de Lucro	0,93 (9,21%)	1,15 (12,94%)	1,14 (14,65%)	1,43 (21,12%)
Maxdrawdown	-5,75% (29,85%)	-4,86% (36,84%)	-4,83% (35,12%)	-3,79% (37,87%)

que a Estratégia PriceVol em M30 alcançou **1,36** quando a Simple atingiu apenas **1,09**. Já em H1, o PriceVol atingiu **1,82**. Quando Simple atingiu **1,40**. O Net Profit também foi superior em todos os casos.

O MDD é um importante indicador de Risco que demonstra a maior perda de capital desde um máximo até um mínimo da curva de Evolução do capital. A Estratégia PriceVol também teve MDD menor em todos os caso, atingindo em média 1,15% a menos que os MDDs alcançados pela estratégia Simple. Neste indicador, pode-se dizer que a Estratégia PriceVol apresentou menor risco que a Estratégia Simple.

Figura 31 – Evolução do Capital COMPRAS PETR4 H1 - 2º SEM/2017

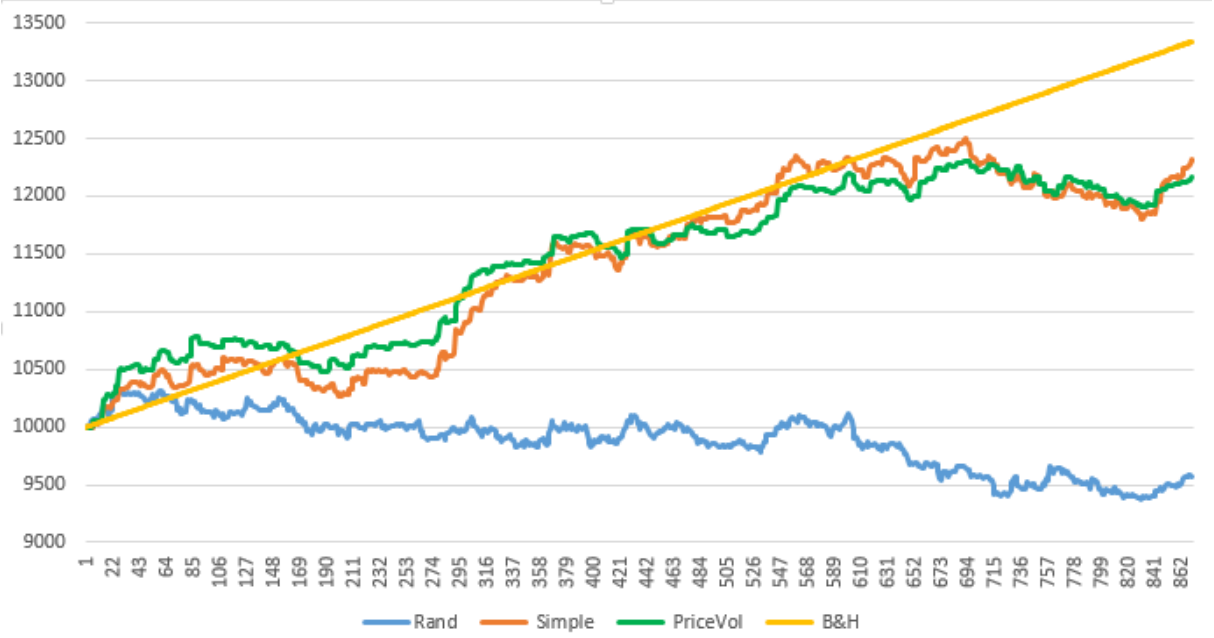

Fonte: Elaborado pelo autor com uso do Robô

Tabela 20 – Comparativo Estratégia Simple X PriceVol PETR4 2º Sem/2017

	PETR4			
	M30		**H1**	
	Simple	**PriceVol**	**Simple**	**PriceVol**
Nº de Operações	434,03 (2,38%)	219,55 (5,24%)	216,00 (3,23%)	110,07 (5,79%)
Nº Op. c/ Lucro	204,52 (5,21%)	107,17 (7,82%)	110,21 (5,68%)	057,21 (7,36%)
Nº Op. c/ Perda	229,52 (3,97%)	112,38 (7,64%)	105,79 (6,86%)	052,86 (10,36%)
Lucro Total	R$ 8.872,26 (13,30%)	R$ 6.605,51 (13,20%)	R$ 7.048,90 (16,48%)	R$ 5.451,49 (19,23%)
Perda Total	-R$ 8.151,50 (4,94%)	-R$ 4.891,10 (7,33%)	-R$ 5.058,69 (6,88%)	-R$ 3.023,65 (11,92%)
% Lucrat.	89,32% (7,82%)	95,99% (11,84%)	104,88% (11,31%)	109,47% (13,49%)
Lucro Médio	R$ 43,40 (12,63%)	R$ 61,78 (13,19%)	R$ 63,88 (14,36%)	R$ 95,48 (19,02%)
Perda Média	-R$ 32,29 (6,32%)	-R$ 40,41 (8,47%)	-R$ 44,74 (9,52%)	-R$ 54,06 (9,25%)
Net Profit + Capital Inicial	R$ 10.720,76 (9,53%)	R$ 11.714,41 (8,13%)	R$ 11.990,21 (9,98%)	R$ 12.427,84 (8,25%)
Fator de Lucro	1,09 (11,72%)	1,36 (16,06%)	1,40 (18,57%)	1,82 (20,55%)
Maxdrawdown	-6,70% (30,27%)	-5,31% (40,55%)	-5,48% (43,57%)	-4,58% (36,02%)

6 Conclusão e Trabalhos Futuros

Neste trabalho foram desenvolvidos e avaliados robôs de operação que implementam estratégias de investimento automatizadas no Mercado Financeiro. Uma avaliação do desempenho na predição de Redes neurais artificiais do tipo ELM como classificadoras de tendência de retorno de preço e crescimento de volume foi realizada com intuito de verificar a sua aplicabilidade em estratégias de investimento de curto prazo (*Day Trade*). Posteriormente, foi realizada uma comparação entre robôs que implementam as estratégias *Buy & Hold*, Randômica com a estratégia que considera os sinais emitidos pelas previsões da ELM Simple e Price & Volume (PriceVol) afim de verificar o seu desempenho financeiro.

As Estratégias apresentadas mostraram-se com capacidade de gerar lucro e reduzir o risco em robôs em várias situações, frente aos *benchmarks* e *baselines* selecionados, apresentando bons indicadores financeiros de risco e retorno em investimentos.

6.1 Considerações Finais

As considerações finais foram organizadas em duas subseções para expor questões referentes à predição das RNAS e para considerações a respeito das Estratégias e métricas financeiras.

6.1.1 Rede ELM

Com os experimentos realizados concluir que as redes ELM são aplicáveis e adequadas para uso em estratégias automatizadas de operação no curto prazo. O desempenho é muitas vezes superior a outras redes neurais, como, por exemplo, MLP, no que tange ao tempo de treinamento. Isso faz com que ela atinja a convergência em períodos de tempo inferiores ao necessários para a tomada de decisão nestes casos. O treinamento da rede ocorre em poucos segundos ou milisegundos, mesmo com entradas de dados e janelas de tempo grandes. Assim, dão sinais dentro do tempo de resposta muito pequeno e podem operar mesmo em granularidades menores que as apresentadas neste estudo (5 minutos).

A taxa de acerto da rede ELM Price atingiu *Precision* de Alta suficientes para que as estratégias obtivessem Lucro na maioria dos casos, mas o indicador *Precision* de Baixa não apresentou resultados suficientes para gerarem bons retornos financeiros quando as estratégias operaram com sinais de vendas.

Ao considerar o tratamento das *features* nos dados de entrada das redes neurais, como a aplicação de logaritmo em algumas entradas, (ex.: $\log_{10}$(retorno)), trouxe diferenças significativas nos indicadores de desempenho de predição das redes ELM.

Os indicadores de previsão alcançados pela RNA Volume foram bons e quando utilizados juntamente as previsões da RNA de Preço para auxiliar nas decisões de abertura de operações conseguiram melhorar o desempenho financeiro tanto em redução do risco quanto em retornos da estratégia PriceVol.

6.1.2 Estratégias

A Estratégia Simple, que considera apenas as previsões da ELM Price, não atingiu bons resultados neste ativo. Avalia-se que a volatilidade encontrada no ativo juntamente com a baixa qualidade de predição da RNA Preço não foram adequadas para a Estratégia.

Os resultados atingidos pela estratégia Simple apresentaram, na maioria dos casos, bons resultados quando operando em compras, os resultados financeiros foram superiores aos dos *benchmarks* de estratégia avaliados, média Randômica e CDI e em algumas situações *Buy and Hold*, mas não foram satisfatórios quando operando em Vendas devido aos sinais de predição ruins.

O indicador financeiro Fator de Lucro, é um dos indicadores financeiros mais importantes para avaliação de Robôs de investimento. Quanto maior o Fator de Lucro, maior será o Lucro em relação as Perdas. Portanto, fornece uma relação de risco e retorno da estratégia. A Estratégia PriceVol atingiu Fator de Lucro superior à Estratégia Simple em todos os casos. Assim, pode-se afirmar que o conjunto de predições das RNA Volume corroborou para a melhoria do desempenho financeiro da estratégia.

O Total Net Profit (Lucro Líquido Total) da estratégia PriceVol foi superior aos da Estratégia Simple para a maioria dos casos, mas perdeu para *Buy and Hold* em alguns casos.

O Ensemble ainda funcionou como *trade filter*, ao incluir as previsões da RNA Volume, o Número de operações da Estratégia PriceVol reduziu para quase a metade da Estratégia Simple. Assim, pode-se considerar o *ensemble* quando o objetivo do investidor é reduzir os custos operacionais da estratégia.

O *Maxdrawdown* (MDD) é outro importante indicador ao se avaliar Robôs de investimento, oferecendo um excelente indicador do risco da perda de capital ao utilizar uma estratégia. Neste quesito a estratégia PriceVol apresentou MDD inferior à estratégia Simple em todos os casos. Assim, pode-se afirmar mais uma vez que o conjunto de predições das RNAs foi mais efetivo e contribuiu para a redução do risco inerente à queda de capital na execução da estratégia de investimento.

Por fim, pode-se dizer que a predição do comportamento de ativos no mercados de capitais não é tarefa simples. O estudo nesta área do conhecimento exige um esforço grande para conhecimento interdisciplinar como estatística, finanças, econometria e computação. O trabalho fornece evidências de que com conjuntos de redes neurais podem trazer melhorias

em alguns indicadores pontuais de estratégias automatizadas, mas não existem, até o momento, quaisquer fórmulas estabelecidas para gerar ganhos fora do padrão quando essas são submetidas a situações reais. Espera-se que o desenvolvimento deste trabalho tenha sido uma pequena contribuição no sentido de tornar as ferramentas adaptativas o suficientes para se adaptarem às mudanças observadas no mercado financeiro em tempo real.

6.2 Trabalhos Futuros

A quantidade e a qualidade dos dados de entrada (*features*) é um fator que afeta a qualidade da previsão das redes neurais. A inclusão e o pivotamento de novos indicadores da análise técnica podem melhorar ainda mais a os indicadores de previsão dos classificadores ELM aqui apresentados.

Os resultados apresentados dão indícios de que uma pequena alteração na qualidade da previsão afeta os indicadores financeiros, porém isso ainda não foi quantificado neste trabalho. Dessa forma, sugere-se para trabalhos futuros saber quantificar essa afetação dos indicadores de previsão nos indicadores financeiros.

Realizar o experimento em outros *time frames*, inclusive operação em alta frequência (HFT), já que há indícios da possibilidade do uso de ELM para este período de tempo. Isso pode ser feito, mesmo que a rede seja treinada e reutilizada por algum período de tempo sem ter que ser retreinada.

A questão dos Custos operacionais pode ser melhor trabalhada com desenho de análise de sensibilidade, trocando o dinheiro por pontos base. Assim, o estudo se apresentará mais atemporal por conta do capital e por conta da corretagem. Um *boxplot* também poderia ser incluído nos estudos, substituindo os gráficos de máximo e mínimo e os gráficos de volatilidade dos ativos. A matriz de confusão BOVA11 vale a pena fazer um teste de significância estatística e comparar a precisão do desempenho com o retorno financeiro. Pode-se ainda incluir um Teste de Hansen para análise estatística.

Melhora os indicadores de comparação *buy and hold*. Se o *Buy and Hold* operar em todos os *candles* sempre comprado em seu gráfico de evolução do capital será mostrado a curva de evolução do capital durante a execução do experimento e não uma linha, como apresentado neste trabalho. Outra sugestão interessante é de incluir um *benchmark* do tipo *Sell and Hold* para comparação com as estratégias que apenas vendem.

Sugere-se ainda quantificar o efeito financeiro da variação do *Stop Loss* e do *Target* nos indicadores financeiros.

Executar o experimento em uma plataforma de robôs de investimento em bolsa proporciona a realização de *backtesting* com resultados mais próximos do real. A SmarttBot

e o Meta Trader são plataformas adequadas para este tipo de tarefa e oferecem facilidades para construção de robôs como bibliotecas para cálculo de indicadores. Além disso, ao definir a estratégia, facilitam na execução do *backtesting*, gerenciando a configuração de vários tipos de *stops*, como *stop* fixo percentual e *trailing stop*, que normalmente são difíceis de se controlar em ambientes simulados. Tudo isso faz com que os resultados dos *backtestings* sejam mais próximos do real e completos, oferecendo relatórios de desempenho financeiro com dezenas de indicadores.

Como o trabalho mostrou evidências de que o conjunto de redes neurais foi mais eficiente para as operações em vários pontos, sugere-se que novas pequisas sejam realizadas no sentido de criar outras redes neurais com responsabilidades específicas, compondo a tomada de decisão das operações. Assim, podem ser criadas redes com responsabilidade para prever a volatilidade, o tempo de duração das tendência, prever o nível de *stop loss* adequado, dentre outras.

O processo de otimização dos parâmetros da estratégia é determinante para a melhoria dos resultados financeiros. Pode-se utilizar de ferramentas como algoritmo completo (força bruta), para quantidade de parâmetros menores, ou mesmo Algoritmos Genéticos (AG), quando as parametrizações apresentarem um espaço para busca de solução muito grande. A otimização ainda pode ter variações na sua função objetivo variando entre o máximo do fator de lucro, mínimo de *Drawdown*, máximo fator de recuperação, dentre outros. Algumas plataformas de desenvolvimento de robôs, como o Meta Trader 5, apresentam facilidades para realizar este tipo de otimização.

Referências

AKUSOK, A. et al. High-performance extreme learning machines: a complete toolbox for big data applications. **IEEE Access**, IEEE, v. 3, p. 1011–1025, 2015. Citado na página 22.

ALDRIDGE, I. **High-frequency trading: a practical guide to algorithmic strategies and trading systems**. [S.l.]: John Wiley and Sons, 2009. v. 459. Citado na página 4.

ATMAN, A.; GONÇALVES, B. A. Influence of the investor's behavior on the complexity of the stock market. **Brazilian Journal of Physics**, Springer, v. 42, n. 1-2, p. 137–145, 2012. Citado na página 5.

AZOFF, E. M. **Neural network time series forecasting of financial markets**. [S.l.]: John Wiley & Sons, Inc., 1994. Citado na página 13.

BARROW, D. K.; CRONE, S. F. Crogging (cross-validation aggregation) for forecasting—a novel algorithm of neural network ensembles on time series subsamples. In: IEEE. **Neural Networks (IJCNN), The 2013 International Joint Conference on**. [S.l.], 2013. p. 1–8. Citado na página 13.

BARTLETT, P. L. The sample complexity of pattern classification with neural networks: the size of the weights is more important than the size of the network. **IEEE transactions on Information Theory**, IEEE, v. 44, n. 2, p. 525–536, 1998. Citado na página 21.

BODIE, Z.; KANE, A.; MARCUS, A. Fundamentos de investimentos. **Ekonomija: teorija i praksa**, v. 5, n. 1, p. 117–119, 2012. Citado na página 18.

BOLLINGER, J. Using bollinger bands. **Stocks & Commodities**, v. 10, n. 2, p. 47–51, 1992. Citado na página 32.

BRAGA, A. de P. **Redes neurais artificiais: teoria e aplicações**. LTC Editora, 2007. ISBN 9788521615644. Disponível em: <https://books.google.com.br/books?id=R-p1GwAACAAJ>. Citado 3 vezes nas páginas 19, 20 e 23.

CALÔBA, L. O. M. Previsão de volatilidade implícita utilizando redes neurais. **Orientadores: Claudio Contador e Luiz Pereira Calôba. Rio de Janeiro: UFRJ/COPPEAD**, 2000. Citado na página 22.

CAO, L.; TAY, F. E. Financial forecasting using support vector machines. **Neural Computing & Applications**, Springer, v. 10, n. 2, p. 184–192, 2001. Citado 2 vezes nas páginas 13 e 31.

CARVALHO, A. C.; AMAZONAS, E. Análise de viabilidade da aplicação de redes neurais no mercado financeiro. **Engenharia de Computação em Revista**, v. 1, n. 1, 2010. Citado 2 vezes nas páginas 22 e 23.

CHEN, C. Citespace ii: Detecting and visualizing emerging trends and transient patterns in scientific literature. **Journal of the American Society for Information Science and Technology**, Wiley Subscription Services, Inc., A Wiley Company, v. 57, n. 3, p. 359–377, 2006. Citado na página 10.

CHONG, T. T.-L.; NG, W.-K. Technical analysis and the london stock exchange: testing the macd and rsi rules using the ft30. **Applied Economics Letters**, Taylor & Francis, v. 15, n. 14, p. 1111–1114, 2008. Citado na página 30.

CORREA, J. M. A. **Estudo e Modelagem de uma Estratégia Financeira Baseada na Combinação de Redes Neurais Artificiais para apoiar a Tomada de Decisão no Mercado Financeiro**. Dissertação (Mestrado) — MMC, CEFET-MG, Belo Horizonte, 2017. Citado 2 vezes nas páginas 8 e 15.

DONG, Y.; ZHANG, J. An improved boosting scheme based ensemble of fuzzy neural networks for nonlinear time series prediction. In: IEEE. **2014 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2014. p. 157–164. Citado 2 vezes nas páginas 6 e 14.

EDWARDS, R. D.; BASSETTI, W.; MAGEE, J. **Technical analysis of stock trends**. [S.l.]: CRC Press, 2012. Citado na página 24.

ESCOVEDO, T. et al. Using ensembles for adaptive learning: A comparative approach. In: IEEE. **Neural Networks (IJCNN), The 2013 International Joint Conference on**. [S.l.], 2013. p. 1–7. Citado 2 vezes nas páginas 13 e 14.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. SciELO Brasil, 2006. Citado 2 vezes nas páginas 19 e 20.

HAYASHI, Y. et al. Three-MLP Ensemble Re-RX algorithm and recent classifiers for credit-risk evaluation. In: . IEEE, 2015. p. 1–8. ISBN 978-1-4799-1960-4. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7280388>. Citado 2 vezes nas páginas 6 e 13.

HAYKIN, S. S. **Redes neurais**. [S.l.]: Bookman, 2001. Citado na página 22.

HINTON, G. E.; SALAKHUTDINOV, R. R. Reducing the dimensionality of data with neural networks. **science**, American Association for the Advancement of Science, v. 313, n. 5786, p. 504–507, 2006. Citado na página 21.

HOERL, A. E.; KENNARD, R. W. Ridge regression: Biased estimation for nonorthogonal problems. **Technometrics**, Taylor & Francis Group, v. 12, n. 1, p. 55–67, 1970. Citado na página 21.

HUANG, G.-B. et al. Universal approximation using incremental constructive feedforward networks with random hidden nodes. **IEEE Trans. Neural Networks**, v. 17, n. 4, p. 879–892, 2006. Citado na página 10.

HUANG, G.-B.; SIEW, C.-K. Extreme learning machine: Rbf network case. In: IEEE. **Control, Automation, Robotics and Vision Conference, 2004. ICARCV 2004 8th**. [S.l.], 2004. v. 2, p. 1029–1036. Citado na página 10.

HUANG, G.-B.; WANG, D. H.; LAN, Y. Extreme learning machines: a survey. **International Journal of Machine Learning and Cybernetics**, Springer, v. 2, n. 2, p. 107–122, 2011. Citado 2 vezes nas páginas 6 e 33.

HUANG, G.-B. et al. Extreme learning machine for regression and multiclass classification. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, IEEE, v. 42, n. 2, p. 513–529, 2012. Citado na página 10.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: IEEE. **Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on**. [S.l.], 2004. v. 2, p. 985–990. Citado na página 10.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. **Neurocomputing**, Elsevier, v. 70, n. 1, p. 489–501, 2006. Citado 5 vezes nas páginas 10, 12, 13, 21 e 22.

HULL, J. C.; BASU, S. **Options, futures, and other derivatives**. [S.l.]: Pearson Education India, 2016. Citado na página 7.

JAMES, C. Kanban Cell Neuron network Stock Trading System (KCNSTS). In: . IEEE, 2015. p. 1–8. ISBN 978-1-4799-1960-4. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7280366>. Citado na página 14.

JUNIOR, R.; SARAIVA, T.; IKEDA, R. H. Mercados eficientes e arbitragem: um estudo sob o enfoque das finanças comportamentais. **Revista Contabilidade & Finanças**, SciELO Brasil, v. 15, n. 34, p. 97–107, 2004. Citado na página 7.

KANNAN, K. S. et al. Financial stock market forecast using data mining techniques. In: **Proceedings of the International Multiconference of Engineers and computer scientists**. [S.l.: s.n.], 2010. v. 1, p. 4. Citado 2 vezes nas páginas 31 e 32.

KRIESEL, D. A brief introduction on neural networks. Citeseer, 2007. Citado 2 vezes nas páginas 19 e 20.

LEMOS, F. **Análise Técnica dos Mercados Financeiros**. SARAIVA EDITORA, 2015. ISBN 9788502637825. Disponível em: <https://books.google.com.br/books?id=xQUfvgAACAAJ>. Citado 2 vezes nas páginas 23 e 24.

LIMA, R. R. D. de. Análise comparativa de previsão por meio de modelos econométricos e redes neurais. 2014. Citado 2 vezes nas páginas 20 e 23.

MARANGONI, P. H. et al. Redes neurais artificiais para previsão de séries temporais no mercado acionário. Florianópolis, 2010. Citado na página 19.

MELLO, M. T. **Aplicação de redes neurais artificiais no processo de precificação de ações**. [S.l.]: Pelotas, 2005. Citado na página 20.

NAKAMURA, H. **Humans Lose Out as Robots Take Tokyo Stock Exchange**. 2015. Acessado: 2016-11-20. Disponível em: <https://www.bloomberg.com/news/articles/2015-03-05/robots-take-tokyo-as-high-frequency-equity-infiltration-hits-70->. Citado na página 5.

NAMETALA, C. A. L. **Construção de um Robô Investidor baseado em Redes Neurais Artificiais e Preditores Econométricos**. Dissertação (Mestrado) — UFMG, Belo Horizonte, 2017. Citado na página 14.

NETO, M. C. A. et al. Improving financial time series prediction using exogenous series and neural networks committees. In: . IEEE, 2010. p. 1–8. ISBN 978-1-4244-6916-1. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5596911>. Citado 2 vezes nas páginas 6 e 19.

NORVIG, P.; RUSSELL, S. **Inteligência Artificial, 3ª Edição**. [S.l.]: Elsevier Brasil, 2014. v. 1. Citado na página 6.

OLIVEIRA, A. C. S. de et al. Aplicação de redes neurais artificiais na previsão da produção de álcool. 2010. Citado na página 20.

OLIVEIRA, F. A. de; NOBRE, C. N.; ZARATE, 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**, v. 40, n. 18, p. 7596–7606, 2013. Citado 3 vezes nas páginas 6, 14 e 29.

PAIVA, F. D. **Redes neurais para decisões no mercado de ações brasileiro**. Tese (Doutorado), 2014. Citado na página 14.

POMMERANZENBAUM, I. R. **Redes Neurais Artificiais na Predição das Principais Séries do Índice IBOVESPA e suas Aplicações em Sistemas Automatizados de Negociação**. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2014. Citado 2 vezes nas páginas 22 e 23.

PULIDO, M.; MELIN, P.; CASTILLO, O. Genetic optimization of ensemble neural networks for complex time series prediction. In: **The 2011 International Joint Conference on Neural Networks**. [S.l.: s.n.], 2011. Citado 2 vezes nas páginas 6 e 13.

RUSSELL, S. J. et al. **Artificial intelligence: a modern approach**. [S.l.]: Prentice hall Upper Saddle River, 2003. v. 2. Citado na página 19.

SACHETIM, H. M. **Análise técnica: estudo da confiabilidade dos principais indicadores de análise técnica, aplicados as ações mais negociadas na Bovespa no período de 1995 a 2005**. Dissertação (Mestrado), 2006. Citado 3 vezes nas páginas 24, 25 e 30.

SILVA, A. L. C. d. **Introdução à análise de dados**. [S.l.: s.n.], 2009. Citado na página 25.

SILVA, E. et al. A binary ensemble classifier for high-frequency trading. In: IEEE. **2015 International Joint Conference on Neural Networks (IJCNN)**. [S.l.], 2015. p. 1–8. Citado 2 vezes nas páginas 6 e 29.

SORNETTE, D. **Why Stock Markets Crash: Critical Events in Complex Financial Systems**. Princeton University Press, 2004. Disponível em: <https://books.google.com.br/books?id=1Rr8cQAACAAJ>. Citado na página 24.

TOSTES, F. P. **Gestão de risco de mercado: metodologias financeira e contábil**. [S.l.]: FGV Editora, 2007. Citado na página 18.

WILDER, J. **New Concepts in Technical Trading Systems**. Trend Research, 1978. ISBN 9780894590276. Disponível em: <https://books.google.com.br/books?id=WesJAQAAMAAJ>. Citado na página 31.

XAVIER, A. **Estratégias estatísticas em investimentos: heurísticas seguras para investimentos e regras de gerenciamento de risco**. [S.l.]: Novatec Editora, 2017. Citado 3 vezes nas páginas 16, 17 e 18.

YAO, J.; TAN, C. L.; POH, H.-L. Neural networks for technical analysis: a study on klci. **International journal of theoretical and applied finance**, World Scientific, v. 2, n. 02, p. 221–241, 1999. Citado na página 5.

ŻBIKOWSKI, 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, v. 42, n. 4, p. 1797–1805, 2015. Citado na página 31.

ZHANG, G. P. Time series forecasting using a hybrid arima and neural network model. **Neurocomputing**, Elsevier, v. 50, p. 159–175, 2003. Citado na página 13.

ZHU, Q.-Y.; HUANG, G.-B.; SIEW, C.-K. A fast constructive learning algorithm for single-hidden-layer neural networks. In: IEEE. **Control, Automation, Robotics and Vision Conference, 2004. ICARCV 2004 8th**. [S.l.], 2004. v. 3, p. 1907–1911. Citado na página 10.