

**UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO**

**Thalita Ramires da Silva**

**AVALIAÇÃO DE UM ALGOTRADING BASEADO EM DEEP  
LEARNING PARA O MERCADO DE CAPITAIS UTILIZANDO  
GERENCIAMENTO DE RISCO**

**Itajubá  
Fevereiro de 2021**

**UNIVERSIDADE FEDERAL DE ITAJUBÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO**

**Thalita Ramires da Silva**

**AVALIAÇÃO DE UM ALGOTRADING BASEADO EM DEEP  
LEARNING PARA O MERCADO DE CAPITAIS UTILIZANDO  
GERENCIAMENTO DE RISCO**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Mestre em Engenharia de Produção.

**Área de Concentração: Engenharia de Produção**

**Orientador: Prof. Dr. Edson de Oliveira Pamplona**

**Itajubá  
Fevereiro de 2021**

*Ao Audeliano Wolian Li,  
aos familiares e amigos queridos.*

# Agradecimentos

Ao meu orientador, Prof. Dr. Edson de Oliveira Pamplona, por ter aceitado a orientação no tema proposto, o que propiciou a aplicação prática do conhecimento acadêmico na vivência profissional. Pela apoio, amizade e oportunidades de aprendizado.

Aos meus pais, irmãos e demais familiares, especialmente ao meu pai, Paulo Roberto da Silva, por ser uma pessoa inspiradora, inquieta e destemida, que me ensinou a não aceitar o conformismo. Ao meu amor, Audeliano Wolian Li, por ter me inspirado a expandir meus horizontes com o Mestrado, pelo apoio nessa jornada, pelo incentivo na escolha do programa e tema, sobretudo por acreditar na minha capacidade de realizar um trabalho desta importância. A minha amiga, Adelaide Romano, pessoa querida que acompanhou e vibrou comigo em cada conquista alcançada. Ao companheiro de laboratório que se tornou um amigo, Caio Rodrigues Moraes, pelos *insights* e discussões pertinentes geradas.

Agradeço também aos envolvidos diretamente no desenvolvimento deste trabalho. Ao pesquisador doutorando Audeliano Wolian Li, pela contribuição técnica, que foi fundamental para o desenvolvimento e realização deste estudo e parceria no artigo publicado. Ao Prof. Dr. Carlos Eduardo Sanches da Silva, pelas diversas contribuições e levantamentos pertinentes à robustez do estudo, ao Prof. Dr. Carlos Henrique Pereira Mello, pela contribuição na qualidade da fundamentação teórica. Ao Prof. Dr. Victor Eduardo de Mello Valerio, pelos ensinamentos na análise bibliométrica. Ao colega MSc. Fernando Luiz Riêra Salomon, que introduziu e auxiliou na ponte entre o universo acadêmico e profissional.

Agradeço ao IEPG, ao Programa de Pós Graduação em Engenharia da Produção da Universidade Federal de Itajubá, pela oportunidade e privilégio de realizar este trabalho, e sobretudo pelo aprendizado. Estendo esse agradecimento ao corpo docente e discente, com quem tanto aprendi durante esse período.

Ao apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de financiamento 001.

*“Sonhar grande e sonhar pequeno dá o mesmo trabalho.”  
(Jorge Paulo Lemann)*

# Resumo

Previsões de séries temporais financeiras são um desafio devido a sua não linearidade e natureza caótica. Nas últimas décadas, muitos pesquisadores e investidores estudaram métodos para melhorar as análises quantitativas. No campo da inteligência artificial, técnicas sofisticadas de aprendizado de máquina, como a aprendizagem profunda, apresentaram melhor performance. Nesta dissertação, um sistema de negociação automatizado, um *algotrading*, para prever as tendências futuras dos preços do índice de ações Ibovespa é apresentado e avaliado. Usando um agente baseado em LSTM (*Long Short-Term Memory*) para aprender padrões temporais dos dados, o algoritmo dispara negociações automáticas de acordo com os dados históricos, indicadores de análise técnica e gerenciamento de risco. Inicialmente, foram desenvolvidas cinco estratégias distintas utilizando o algoritmo LSTM como base, em seguida, foi selecionado o modelo que reportou a melhor performance. Durante os testes experimentais, foi possível demonstrar que a utilização de *Trading Strategy* e gerenciamento de risco ajudaram a minimizar perdas e reduzir custos operacionais, que possuem influência direta na rentabilidade. Posteriormente, o modelo que obteve melhor resultado, o LSTM-RMODV, foi submetido à diversas melhorias. Entre elas, a implementação das técnicas de *Break-even* e *Trailing Stop* e uma série de otimizações do *trading strategy*. Com isto, foi possível obter um conjunto de parâmetros que trouxe melhores resultados ao ATS (*Automated Trading System*), dando origem ao novo modelo denominado Algo-LSTM. Em última etapa, a avaliação do *slippage* permitiu inferir que a longo prazo o impacto do *slippage* em condições razoáveis de mercado não é significativo para o resultado final. Por fim, os resultados demonstraram que o método proposto, o Algo-LSTM, apresenta melhor desempenho quando comparado a outros métodos, incluindo a técnica *buy-and-hold*. O método proposto também funciona em condições de *bear* ou *bull market*, apresentando uma taxa sobre a rentabilidade líquida com base no capital investido de 208,23% em 2019 e 112,81% em 2015. Ou seja, apesar da baixa acurácia, o algoritmo é capaz de gerar retornos consistentes quando considerados todos os custos de transação e imposto de renda devido.

**Palavras-chaves:** Avaliação Econômica. *Algotrading*. Aprendizagem profunda. *Long short-term memory*. *Trading Strategy*. Gerenciamento de Risco.

# Abstract

Financial time series predictions are a challenge due to their nonlinear and chaotic nature. In recent decades, many researchers and investors have studied methods to improve quantitative analysis. In the field of artificial intelligence, sophisticated machine learning techniques, such as deep learning showed better performance. In this work, an automated trading system, an algo trading, to predict future trends of stock index prices Ibovespa is showed and evaluated. Using an LSTM-based (Long Short-Term Memory) agent to learn temporal patterns in the data, the algorithm triggers automatic trades according to the historical data, technical analysis indicators, and risk management. Initially, five different strategies were developed using the LSTM algorithm as a basis, then the model that reported the best performance was selected. During the experimental tests, it was possible to prove that the use of trading strategy and risk management techniques helped to minimize losses and reduce operating costs, which have a direct influence on profitability. Subsequently, the model that obtained the best result, the LSTM-RMODV, underwent several improvements. Among them, the implementation of the Break-even and Trailing Stop techniques, and a series of optimizations for the trading strategy. Then, it was possible to obtain a set of parameters that brought better results to the ATS (Automated Trading System), giving rise to the new model called Algo-LSTM. In the last step, the evaluation of slippage allowed to infer that in the long-term the impact of slippage under reasonable market conditions is not significant for the final result. Finally, the results demonstrated that the proposed method, Algo-LSTM, shows better performance when compared with other methods, including the buy-and-hold technique. The proposed method also works in bear or bull market conditions, showing a rate over net income based on invested capital of 208.23% in 2019 and 112,81% in 2015. That is, despite the low accuracy, the algorithm is capable of generating consistent profits when all the transaction costs and the income tax over net revenue are considered.

**Key-words:** Economic Evaluation. Algo trading. Deep learning. Long short-term memory. Trading Strategy. Risk management.

# Lista de figuras

Figura 1 – Linha do tempo histórica da bolsa de valores brasileira . . . . .	23
Figura 2 – Produção científica anual <i>Scopus</i> e <i>Web of Science</i> . . . . .	32
Figura 3 – Dez fontes mais citadas do <i>Scopus</i> . . . . .	33
Figura 4 – Dez fontes mais citadas do <i>Web of Science</i> . . . . .	34
Figura 5 – Países correspondentes aos autores da base <i>Scopus</i> . . . . .	34
Figura 6 – Países correspondentes aos autores da base <i>Web of Science</i> . . . . .	35
Figura 7 – Os vinte países mais citados da base <i>Scopus</i> . . . . .	35
Figura 8 – Os vinte países mais citados da base <i>Web of Science</i> . . . . .	36
Figura 9 – Inteligência Artificial e suas ramificações . . . . .	41
Figura 10 – Representação do modelo de um neurônio de McCulloch-Pitts. . . . .	42
Figura 11 – Arquitetura de uma rede neural <i>feed-forward</i> com uma camada escondida . . . . .	43
Figura 12 – Conceito de descida do gradiente . . . . .	44
Figura 13 – Representação de uma rede neural recorrente com <i>loop</i> . . . . .	45
Figura 14 – Desdobramento de uma rede neural recorrente . . . . .	45
Figura 15 – Rede <i>Long short-term memory</i> . . . . .	46
Figura 16 – Fases do modelo conceitual . . . . .	50
Figura 17 – Estrutura do modelo conceitual . . . . .	50
Figura 18 – Abordagem de divisão dos dados . . . . .	51
Figura 19 – Arquitetura do modelo LSTM . . . . .	52
Figura 20 – Etapas do ATS em ambiente simulado ( <i>backtesting</i> ) . . . . .	54
Figura 21 – Etapas do ATS em ambiente real . . . . .	55
Figura 22 – Estratégia LSTM-N . . . . .	57
Figura 23 – Estratégia LSTM-PH . . . . .	57
Figura 24 – Estratégia LSTM-RMO . . . . .	58
Figura 25 – Estratégia LSTM-RMODV . . . . .	58
Figura 26 – Pontos acumulados em 2019 . . . . .	63
Figura 27 – Rentabilidade líquida acumulada em 2019 . . . . .	65
Figura 28 – Rede <i>Long short-term memory</i> . . . . .	83
Figura 29 – Compra pendurada . . . . .	85
Figura 30 – Compra executada . . . . .	86
Figura 31 – <i>Break-even</i> acionado . . . . .	87
Figura 32 – <i>Trailing Stop</i> acionado . . . . .	88
Figura 33 – TP e <i>slippage</i> apresentados . . . . .	89
Figura 34 – Compra executada . . . . .	91
Figura 35 – SL acionado . . . . .	92
Figura 36 – Compra pendurada . . . . .	93

Figura 37 – <i>Break-even</i> acionado . . . . .	94
Figura 38 – <i>Trailing Stop</i> acionado . . . . .	95
Figura 39 – Segundo <i>Trailing Stop</i> acionado . . . . .	96
Figura 40 – TP e <i>slippage</i> apresentados . . . . .	97
Figura 41 – Compra pendurada . . . . .	99
Figura 42 – <i>Break-even</i> acionado . . . . .	100
Figura 43 – <i>Trailing Stop</i> acionado . . . . .	101
Figura 44 – <i>Stop</i> acionado . . . . .	102
Figura 45 – Venda pendurada . . . . .	103
Figura 46 – SL e <i>slippage</i> apresentados . . . . .	104
Figura 47 – Compra pendurada . . . . .	106
Figura 48 – Movimentando ordem de compra . . . . .	107
Figura 49 – Compra executada . . . . .	108
Figura 50 – SL acionado . . . . .	109
Figura 51 – Segunda compra executada . . . . .	110
Figura 52 – Segundo SL acionado . . . . .	111
Figura 53 – Compra executada com TP . . . . .	113
Figura 54 – TP e alto <i>slippage</i> diário apresentado . . . . .	114

# Lista de quadros

Quadro 1 – Perfis de investidores . . . . .	24
Quadro 2 – Características técnicas do IND e WIN . . . . .	25
Quadro 3 – Percentual do tipo de investidor no IND . . . . .	25
Quadro 4 – Percentual do tipo de investidor no WIN . . . . .	25
Quadro 5 – Publicações filtradas pelos critérios das palavras-chave da pesquisa . . . . .	29
Quadro 6 – Combinações entre os termos . . . . .	30
Quadro 7 – Primeira interação entre previsão e análise técnica com os demais termos . . . . .	30
Quadro 8 – Interação entre previsão, análise técnica e método computacional com os demais termos . . . . .	31
Quadro 9 – Métodos de previsão . . . . .	40
Quadro 10 – Parametrização realizada . . . . .	59
Quadro 11 – Avaliação econômica comparativa entre Algo-LSTM e B&H . . . . .	67

# Lista de tabelas

Tabela 1 – Termos de busca para coleta de dados . . . . .	28
Tabela 2 – Métricas de avaliação do modelo . . . . .	62
Tabela 3 – Métricas de desempenho financeiro . . . . .	63
Tabela 4 – Avaliação financeira . . . . .	63
Tabela 5 – Simulação de alavancagem do LSTM-RMODV contra a técnica B&H . . .	66
Tabela 6 – Métricas de avaliação do modelo para classe de compra . . . . .	66
Tabela 7 – Métricas de avaliação do modelo para classe de venda . . . . .	66
Tabela 8 – Avaliação de performance do investimento . . . . .	68

# Lista de abreviaturas e siglas

ABC	<i>Artificial Bee Colony Algorithm</i>
ADR	<i>American Depositary Reciept</i>
AF	Análise Fundamentalista
AGT	<i>Algorithmic Trading</i>
AI	<i>Artificial Intelligence</i>
ANN	<i>Artificial Neural Network</i>
AR	<i>Autoregressive</i>
ARIMA	<i>Atoregressive Integrated Moving Average</i>
AT	Análise Técnica
ATS	<i>Automated Trading System</i>
B&H	<i>Buy and Hold</i>
B3	Brasil, Bolsa, Balcão
BC	Banco Central do Brasil
CI	<i>Computational Intelligence</i>
CNN	<i>Convolutional Neural Network</i>
Copom	Comitê de Política Monetária
DJIA	<i>Dow Jones Industrial Average</i>
DL	<i>Deep Learning</i>
DMA	<i>Direct Market Access</i>
ES	<i>Expert Systems</i>
FC	<i>Fully Connected</i>
GA	<i>Genetic Algorithm</i>
HB	<i>Home Broker</i>
HES	<i>Hybrid Intelligence Systems</i>

HFT	<i>High Frequency Trading</i>
IC	Intervalo de Confiança
IESTI	Instituto de Engenharia de Sistemas e Tecnologias da Informação
IND	Contrato Futuro do Índice Bovespa
LSTM	<i>Long Short-Term Memory</i>
MC	Mercado de Capitais
ML	<i>Machine Learning</i>
MSE	<i>Mean Square Error</i>
OHLCV	<i>Open, High, Low, Close, Volume</i>
OPEP	Organização dos Países Exportadores de Petróleo
PE	Pregão Eletrônico
PF	Pessoa Física
PVV	Pregão Viva Voz
RM	<i>Risk Management</i>
RNN	<i>Recurrent Neural Networks</i>
SC	<i>Soft Computing</i>
Selic	Sistema Especial de Liquidação e de Custódia
SFN	Sistema Financeiro Nacional
SL	<i>Stop Loss</i>
SVM	<i>Support Vector Machines</i>
TI	<i>Technical Indicators</i>
TP	<i>Take Profit</i>
TS	<i>Trading System</i>
VWAP	<i>Volume Weighted Average Price</i>
WIN	Mini Contrato Futuro do Índice Bovespa

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	Justificativas e Contribuições do Trabalho	19
1.2	Motivação	20
1.3	Objetivos do Trabalho	21
1.4	Organização do Trabalho	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>22</b>
2.1	Mercado de Capitais	22
2.2	Análise Bibliométrica	27
2.2.1	Seleção e coleta de dados	28
2.2.2	Análise dos dados	32
2.3	Trabalhos Relacionados	36
2.3.1	Métodos de previsão introdutórios	36
2.3.2	Métodos de previsão baseados em inteligência computacional	37
2.4	Conceitualização	41
2.4.1	Redes Neurais Recorrentes e Redes Long-Short Term Memory	44
<b>3</b>	<b>MÉTODO DE PESQUISA</b>	<b>48</b>
3.1	Metodologia de Pesquisa	48
3.2	Modelo Conceitual	48
3.3	Base de Dados e Preparação	51
3.4	Módulo Preditor	52
3.5	Métricas de Avaliação do Modelo	53
3.6	Sistema de Negociação Automatizado	53
3.6.1	Protótipo	56
3.6.2	Otimização Dinâmica	59
3.7	Avaliação Financeira	61
<b>4</b>	<b>RESULTADOS EXPERIMENTAIS</b>	<b>62</b>
4.1	Resultados Experimentais do Protótipo	62
4.2	Resultados Experimentais do Algo-LSTM	65
4.3	Resultados Experimentais da Taxa de Erro em Conta Real	68
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>70</b>
5.1	Contribuições	71
5.2	Limitações do Trabalho	72

<b>5.3</b>	<b>Sugestões para Trabalhos Futuros</b>	<b>73</b>
	<b>REFERÊNCIAS</b>	<b>74</b>
	<b>APÊNDICE A – ASPECTOS TÉCNICOS ACERCA DA REDE LSTM</b>	<b>82</b>
	<b>APÊNDICE B – OPERAÇÕES EM CONTA REAL</b>	<b>84</b>
<b>B.1</b>	<b>Operação do dia 22 de abril de 2020</b>	<b>84</b>
B.1.1	<i>Take Profit - 1 Gain</i>	84
<b>B.2</b>	<b>Operação do dia 20 de abril de 2020</b>	<b>90</b>
B.2.1	<i>1 Stop e 1 Gain</i>	90
<b>B.3</b>	<b>Operação do dia 23 de abril de 2020</b>	<b>98</b>
B.3.1	<i>1 Trailing e 1 Stop</i>	98
<b>B.4</b>	<b>Operação do dia 24 de abril de 2020</b>	<b>105</b>
B.4.1	<i>1 Loss com Spread</i>	105
<b>B.5</b>	<b>Primeira tentativa de operação na real, 09 de março de 2020</b>	<b>112</b>
B.5.1	<i>Circuit breaker</i>	112
	<b>ANEXO A – ARTIGO PUBLICADO</b>	<b>115</b>

# 1 Introdução

O mercado financeiro é considerado uma das áreas mais importantes para as economias globais e vem atraindo crescente interesse de pesquisadores e investidores (LIN; CHIU; LIN, 2012; CAVALCANTE *et al.*, 2016). Grande parte de sua base de sustentação é devido ao estabelecimento e desenvolvimento das companhias, exercendo um papel fundamental para o crescimento econômico das nações e impactando diretamente todo o sistema financeiro.

Neste sentido, a principal forma utilizada pelas empresas para captar recursos destinados à expansão de suas redes, novos investimentos e financiamento de suas atividades são por meio do mercado financeiro (HAWAWINI; VIALLET, 2010). Conforme os autores elucidam, essas captações podem ocorrer sob a forma de capital de terceiros no mercado monetário, como contração de empréstimos e financiamentos e também com a emissão de títulos de dívidas ou venda de parte do capital próprio da empresa emitindo ações, por meio do mercado de capitais.

Observando a ótica de investimentos segundo Rotela, Pamplona e Salomon (2014), diante de cenários de estabilidade econômica e consequentes quedas nos juros básicos da economia, alternativas de investimentos que contenham melhor rentabilidade tendem a atrair investidores com o passar do tempo. O estudo indica que fundos de renda fixa e poupança vêm perdendo atratividade, apontando o mercado de capitais como possível alternativa, tendência nos mercados financeiros mais desenvolvidos. Somando a isto, a atual conjuntura econômica brasileira vivencia um momento desafiador.

Nos últimos anos, a economia brasileira começou a sinalizar uma recuperação gradual, desprendendo do cenário de crise decorrido (BC, 2017). Isto possibilitou ao Banco Central do Brasil (BC) realizar contantes reduções da taxa básica de juros brasileira (Selic), por meio de seu Comitê de Política Monetária (Copom). Estes cortes proporcionaram a redução da taxa Selic para um dígito, importante fator uma vez que permanecia superior desde 2014 (BC, 2020c).

Em contrapartida, o ano de 2019 foi marcado por estagnação, também influenciado pelos riscos da desaceleração da economia global (BC, 2020a; WORLD BANK, 2020). Embora o final do período de 2019 tenha sugerido projeções otimistas, o surgimento em dezembro do novo Coronavírus, Covid-19, mudou completamente a temática. Em paralelo a isto, a crise do petróleo desencadeada pelo desacordo entre a Organização dos Países Exportadores de Petróleo (OPEP) e seus principais membros, Rússia e Arábia Saudita, intensificaram a crise econômica (D'SOUZA, 2020).

Por sua vez, o quadro de Covid-19, proveniente do vírus mutação da SARS-Cov que surgiu em novembro de 2002 no sul da China (CHENG *et al.*, 2007), revelou ser altamente transmissível, se espalhando pelo mundo todo o que se tornou uma pandemia (WHO, 2020). Dentre medidas tomadas pelo governo do Brasil, como pacotes de estímulos econômicos e sociais, foram adotados novos cortes à taxa Selic que atingiu o patamar de 2% na reunião do Copom realizada em agosto de 2020 (BC, 2020c).

Devido a estes acontecimentos, é possível constatar que o patamar apontado da taxa Selic apresenta-se inversamente proporcional à estabilidade econômica, pois diz respeito à medidas direcionadas aos impactos da crise local e da grande recessão mundial (BC, 2020b). Por outro lado, houve um crescimento de 68% de investidores individuais na bolsa brasileira (B3) no acumulado de julho de 2020 em relação ao fechamento de 2019 (B3, 2020c).

Como um dos prováveis fatores, o cenário de juros baixos pode ter desencadeado um maior interesse pelo mercado de capitais como opção mais rentável aos investimentos financeiros, maturidade vista em mercados mais evoluídos. Adicionalmente, uma possível causa também pode estar relacionada à oportunidade de renda extra, devido ao aumento do desemprego gerado pela crise frente à popularidade que operações de *daytrade* têm ganhado.

Segundo Huang *et al.* (2014) “*trading*”, termo que se refere a negociações no mercado de capitais, tem se tornado popular devido ao seu alto potencial de lucro. Desde a criação do sistema *home broker* em 1999, que democratizou o acesso direto de pessoa física (PF) ao mercado de capitais, o número de participantes individuais vêm crescendo cada vez mais.

Por sua vez, a evolução da computação e a internet tem atendido a diversas áreas deficitárias do mercado e uma delas foi a necessidade de transformar o antigo pregão viva voz (PVV) existente nas bolsas de valores em pregão eletrônico (PE). No Brasil, a consolidação total do sistema de PE que ocorreu em 2009 (B3, 2019b) proporcionou a entrada de novos mecanismos de negociação, como as operações automatizadas. Neste sentido, vem crescendo o interesse por robôs investidores em empresas financeiras de tecnologias, as *Fintechs* (CVM, 2016).

Em economias mais desenvolvidas, este sistema ocupa a maior participação do mercado. Estima-se que 85% das transações ocorridas em 2012 no mercado de ações dos EUA foram realizadas por meio de negociações automatizadas, frente à apenas 15% em 2003 (GLANTZ; KISSELL, 2013). Dito isto, a utilização de robôs investidores por PF sinaliza uma oportunidade para muitos que não possuem tempo e conhecimento necessário para análise e tomada de decisão no mercado, mas que desejam se beneficiar das distorções de preço existentes no curto prazo.

Estes sistemas automatizados são classificados em *algorithmic trading* (AGT) e *high frequency trading* (HFT) (CHEN, 2019; SETH, 2020a). De acordo com Seth (2020b), a característica do robô HFT de executar operações em milésimos de segundos ou até mesmo em nano segundos requer dentre outros, um computador potente e alocação de servidor direto na bolsa. Por isto, os HFTs são menos atrativos às *Fintechs*, uma vez que estes atributos elevam demasiadamente seu custo de desenvolvimento e manutenção. Diferentemente, os AGTs que também são capazes de executar operações automatizadas e suportar sofisticadas lógicas de programação, como *machine learning* (ML) e *deep learning* (DL), não possuem custos tão elevados.

Entretanto, para criar um modelo automatizado, é preciso dispor de uma base de dados com informações do ativo requerido. De acordo com Cavalcante *et al.* (2016) devido ao importante papel que o mercado financeiro desempenha na organização econômica e social dos tempos modernos, as informações que o envolvem passam a ser um recurso valioso para os

investidores, que dependem de sua qualidade e velocidade, para tomada de decisão.

Neste sentido, com intuito de contribuir para uma melhor tomada de decisão, as previsões de preços futuros para os ativos financeiros são frequentemente utilizadas. Embora exista diversas situações que requerem previsão, os autores [Montgomery, Jennings e Kulahci \(2008\)](#) apontam a existência de somente duas técnicas para esta abordagem, qualitativa e quantitativa.

Adicionalmente, as previsões quantitativas são as mais utilizadas no mercado financeiro e baseiam-se nas conhecidas análise fundamentalista e análise técnica ([VANSTONE; FINNIE, 2009](#)). A análise fundamentalista, iniciada por Benjamin Graham no início de 1928, é frequentemente utilizada para fazer a seleção de um portfólio de investimentos com base nas informações fundamentais que envolvem seus ativos, como indicadores internos e externos. Em contrapartida, a análise técnica, que foi fundamentada pelos estudos de Chales Dow desde 1884, depois conhecida como Teoria de Dow, baseia-se nos preços dos ativos e comumente é utilizada para indicar os pontos de *trade*, sinais de compra e venda dos ativos que serão operados.

O conceito de análise técnica (AT) apresentado por [Murphy \(1999\)](#), compreende o estudo da ação do preço. A ferramenta gráfica torna-se seu principal instrumento de investigação, somado a informações de preço e volume, onde busca-se prever tendências futuras do preço. Analistas técnicos, também chamados de analistas gráficos, acreditam que tudo que pode afetar o preço do mercado já está propriamente refletido no preço. Essa afirmação parte das premissas de AT de que: (a) o preço desconta tudo, (b) o preço move-se em tendência e (c) a história tende a se repetir.

[Murphy \(1999\)](#) defende que a análise fundamentalista estuda as causas das movimentações no mercado, enquanto a análise técnica estuda o efeito, em que saber o porquê das oscilações ganha pouca importância. Além disso, ressalta que os casos mais dramáticos de *bull* e *bear market* da história começaram com pouca ou nenhuma mudança nos fundamentos. Quando os fundamentos apareceram, a tendência já estava bastante consolidada.

Deste modo, nas últimas décadas vários estudos de análise técnica têm proposto métodos para previsão de séries temporais financeiras, com intuito de fornecer um sistema de suporte à tomada de decisão ([TEIXEIRA; OLIVEIRA, 2010](#); [CAVALCANTE et al., 2016](#); [KUMAR; JAIN; SINGH, 2020](#)). Os dois principais métodos são: estatístico ou econométrico e inteligência artificial ou inteligência computacional (em inglês, *Computational Intelligence - CI*) o qual engloba técnicas de ML, como lógica *Fuzzy*, algoritmo genético (em inglês, *Genetic Algorithm - GA*) e redes neurais artificiais (em inglês, *Artificial Neural Network - ANN*).

Neste trabalho, serão estudados os métodos de CI, uma vez que o método estatístico tradicional geralmente considera as séries temporais originadas de um processo linear e tenta fazer previsões para os valores futuros ([KUMAR; MEGHWANI; THAKUR, 2016](#)). Entretanto, as séries temporais financeiras são complexas, apresentando comportamento dinâmico e não linear por natureza ([SI; YIN, 2013](#)). Por fim, as técnicas de CI têm sido aplicadas com relativo sucesso, justamente por serem capazes de capturar essa relação de não linearidade entre os fatores relevantes ([ATSALAKIS; VALAVANIS, 2009](#)).

## 1.1 Justificativas e Contribuições do Trabalho

Primeiramente, [Vanstone e Finnie \(2009\)](#) indicam lacunas em relação às metodologias formais dos *trading systems* de sucesso devido ao interesse em manter a salvo seu capital intelectual. O problema identificado pelos autores neste comportamento é a inibição de novos pesquisadores a desenvolverem modelos robustos, levando a publicações que podem estar baseadas em uma metodologia fraca. Além disto, apontam que falhas na validação prática destes sistemas normalmente ocorrem devido a falta de compreensão de um *trade* real, o qual possui diversas restrições que alteram o resultado final, como custo de transação e gerenciamento de risco financeiro.

Corroborando, [Teixeira e Oliveira \(2010\)](#) apontam que embora os estudos propostos para modelar problemas da área financeira sejam amplos, muitas abordagens se propõem apenas a modelar problemas e métricas para avaliar as diferentes técnicas existentes. Neste sentido, a falta de testes práticos não deixa claro se as técnicas propostas são capazes de gerar rentabilidade real. Estratégias de *stop gain* e *stop loss*, como os autores exemplificam, são comumente utilizadas por *traders* na prática, mas raramente são consideradas em pesquisas acadêmicas.

A discussão continua com [Cavalcante et al. \(2016\)](#) ressaltando que ao longo dos anos têm sido propostos estudos na literatura para resolver problemas inerentes ao mercado financeiro baseados na metodologia de previsão convencional. O grande problema disto é que modelos inteligentes de sucesso necessitam de componentes adicionais, como estratégias de negociação (*trading strategies*) e avaliação financeira, para que o método possa ser validado tanto em ambiente real ou simulado para *trading*. Com isto, os autores propuseram uma metodologia formal que pode ser aplicada para resolução deste problema. Embora [Kumar, Jain e Singh \(2020\)](#) tenham apresentado uma continuidade ao trabalho do referido autor, a avaliação financeira não foi considerada em sua metodologia, mostrando que o tema ainda é relevante para exploração.

Por outro lado, o importante estudo realizado por [Tversky e Kahneman \(1974\)](#) que rendeu a Daniel Kahneman o prêmio Nobel de Economia em 2002, relata que pessoas sob situações de risco e incertezas tendem a tomar decisões equivocadas. Somado a isto, [Chague, De-Losso e Giovannetti \(2019\)](#) realizaram uma pesquisa demonstrando que quase a totalidade de investidores individuais sofrem perdas recorrentes na bolsa de valores brasileira em operações de *daytrade*.

Entretanto, conforme citado na seção anterior, a utilização de *trading systems* automatizados é tendência em mercados mais desenvolvidos. Com isto, os problemas humanos de tomada de decisões enviesadas por influência emocional, podem ser resolvidos por meio dos modelos de CI. Um dos benefícios apontados por [Seth \(2020a\)](#) referente ao *algotrading* é justamente a capacidade de reduzir a possibilidade de erros humanos baseados em fatores emocionais e psicológicos.

Diante do exposto, é possível perceber a contribuição desta dissertação para a área científica, uma vez que visa contribuir para esta lacuna existente. Além disto, há cada vez mais interesse não só de pesquisadores como também de investidores em métodos inteligentes de

tomada de decisão para o mercado financeiro. Alinhado a isto, uma das principais justificativas deste estudo está relacionada à aplicação prática do *trading system* proposto, onde fornece resultados de performance financeira e capacidade de gerar rentabilidade. Por fim, a validação real do trabalho busca encorajar que demais pesquisadores sigam a mesma linha, enriquecendo a academia.

Adicionalmente, após a validação do método proposto, sua aplicação poderá ser expandida para campos com mesma característica de não linearidade (MONTGOMERY; JENNINGS; KULAHCI, 2008) e pesquisas na área de energia, robótica, biologia, física, entre outras, poderão ser beneficiados com este estudo. Por fim, o modelo desenvolvido pode ser replicado tanto para utilização por investidores individuais, como pelos fundos de investimento quantitativos, sendo um exemplo deste tipo de fundo o Medallion <sup>1</sup>, considerado um dos fundos quantitativos mais rentáveis historicamente. Além disso, o algoritmo também pode ser aplicado em portfólios eficientes de investimentos.

## 1.2 Motivação

Os resultados obtidos neste trabalho são relevantes à universidade em questão, como as investigações realizados pelos pesquisadores do Laboratório de Mercado de Capitais, além dos demais grupos de pesquisa que relacionam-se ao tema, em especial ao IESTI - Instituto de Engenharia de Sistemas e Tecnologias da Informação, cujo o doutorando da área colaborou com a elaboração do artigo resultado desta dissertação, Anexo A.

Entretanto, a grande motivação para elaboração deste trabalho foi além da contribuição com as linhas de pesquisa da referida universidade. A inspiração surgiu a partir da lacuna existente na literatura referente à avaliação econômica dos modelos preditivos, indicada pelos pesquisadores Cavalcante *et al.* (2016). A partir deste estudo, foi evidenciado que quase a totalidade dos modelos preditivos ao longo dos anos não estavam levando em consideração características reais do mercado como estratégias de negociação, o que poderia ser um problema de confiabilidade nos modelos desenvolvidos.

Somado a isso, do ponto de vista prático, o expressivo interesse no tema, além de ser proveniente da experiência profissional do pesquisador na área, visa apresentar uma alternativa ao histórico de prejuízos recorrentes que os investidores individuais têm reportado em operações de *daytrade* conforme divulgação em Chague, De-Losso e Giovannetti (2019). Operações realizadas manualmente são muito suscetíveis à influência de fatores psicológicos na tomada de decisão, conforme o estudo de Tversky e Kahneman (1974). Com isto, a utilização de sistemas automatizados capazes de apresentar rentabilidade líquida positiva, configuram uma alternativa interessante para a tomada de decisão racional.

Dito isto, coloca-se em questão se é possível obter rentabilidade positiva após os custos de transação e impostos devidos em operações de curto prazo utilizando um *algotrading* base-

<sup>1</sup> <https://forbes.com.br/forbes-money/2020/12/medallion-um-dos-fundos-mais-rentaveis-da-historia/>

ado em inteligência computacional e análise técnica. Além disso, mensurar os impactos do uso de estratégias negociação e gerenciamento de risco no resultado final são pontos de atenção para a avaliação financeira dos algoritmos automatizados. Assim, o desenvolvimento deste trabalho busca responder a estas questões de pesquisa.

### 1.3 Objetivos do Trabalho

A presente dissertação possui como objetivo principal avaliar a rentabilidade líquida e propor novas estratégias de negociação intradiária com gerenciamento de risco para um *algotrading* baseado em uma lógica computacional inteligente no mercado de capitais. Para isso, foram utilizados os dados históricos de mini contratos futuros do índice Bovespa (WIN) e indicadores técnicos. Assim, o objetivo geral se desdobra nas seguintes etapas:

- Investigar as técnicas de CI mais implementadas para previsão de séries temporais financeiras, utilizando análise bibliométrica e revisão da literatura;
- Desenvolver diferentes estratégias de negociação intradiária com gerenciamento de risco;
- Propor um sistema de negociação automatizado baseado em CI, dados do WIN e indicadores técnicos utilizando as estratégias de negociação com gerenciamento de risco;
- Avaliar a performance do modelo final em termos de rentabilidade líquida considerando custos de transação e impostos inerentes para comparar com o *benchmark* local;
- Analisar a taxa de erro de performance do *algotrading* proposto em conta real, chamada *slippage*.

### 1.4 Organização do Trabalho

O restante da dissertação foi organizado da seguinte forma: Capítulo 2 apresenta um breve referencial teórico sobre o objeto de estudo, evidencia a contribuição da pesquisa por meio da revisão da literatura e análise bibliométrica, finalizando com uma conceitualização teórica em que o modelo se baseia. No Capítulo 3 foi detalhada a metodologia adotada para o sistema proposto, mostrando seus resultados experimentais no Capítulo 4. E por fim, no Capítulo 5 são apresentadas as conclusões e direções para trabalhos futuros.

## 2 Fundamentação Teórica

Este capítulo foi organizado em sessões, com objetivo de contextualizar e dar propósito à pesquisa. Para isto, inicialmente o Mercado de Capitais é brevemente introduzido na Seção 2.1 com intuito de abordar o cenário do objeto de estudo. Em seguida, é apresentada a revisão da literatura para evidenciar a contribuição teórica do trabalho em duas etapas. Primeiro, o dimensionamento da área é realizado por meio da Análise Bibliométrica na Seção 2.2 e, posteriormente, acompanhada dos trabalhos relacionados na Seção 2.3. Finalmente, na Seção 2.4 são apresentados os principais conceitos que envolvem a base da técnica utilizada no sistema proposto.

### 2.1 Mercado de Capitais

Esta seção retrata brevemente o mercado de capitais (MC) com o objetivo de abordar o objeto de estudo e apresentar os principais pontos de interesse ao trabalho. Deste modo, o enfoque será dado ao segmento BM&F e mini contratos de índice, uma vez que caracterizam a série temporal financeira trabalhada.

Primeiramente, o Sistema Financeiro Nacional (SFN) é composto por quatro áreas distintas, sendo elas o mercado monetário, câmbio, crédito e o MC. Embora esta segmentação ocorra, todas possuem o mesmo objetivo, viabilizar o fluxo financeiro na economia (CVM, 2019a). Uma vez que o presente estudo faz alusão direta ao MC, as demais áreas não serão abordadas pois fogem do escopo desta pesquisa.

Por sua vez, o MC é o local onde as empresas captam recursos de investidores por meio de emissão pública de debêntures ou ações da companhia. Neste caso, os investidores são quem assumem o risco das operações, o que pode estar relacionado ao crescente interesse de estudos na área. Para isto, os investidores necessitam da infraestrutura das bolsas de valores para viabilizar a execução de suas operações. No Brasil, a única e atual bolsa de valores é a B3. Sua linha histórica pode ser observada na Figura 1, mostrando desde sua criação por meio da Bolsa Livre até a constituição atual (B3, 2019a). É possível perceber que ao longo dos anos a bolsa brasileira, que está há mais de um século no mercado, realizou diversas junções estratégicas por meio de unificação das áreas.

Além dos investidores brasileiros, atualmente a B3 conta com um grande fluxo de capital estrangeiro. Esta abertura iniciou-se em 1976, porém ganhou força somente a partir do final da década de 80 (CVM, 2019a). O ponto alto desta entrada foi a emissão de *American Depositary Receipt* (ADR), que possibilita às empresas brasileiras estarem listadas nas bolsas de outros países.

Inicialmente, as ordens de compra e venda enviadas pelos investidores eram executadas verbalmente por operadores com utilização de cartões, por isso o nome pregão viva voz, PVV.

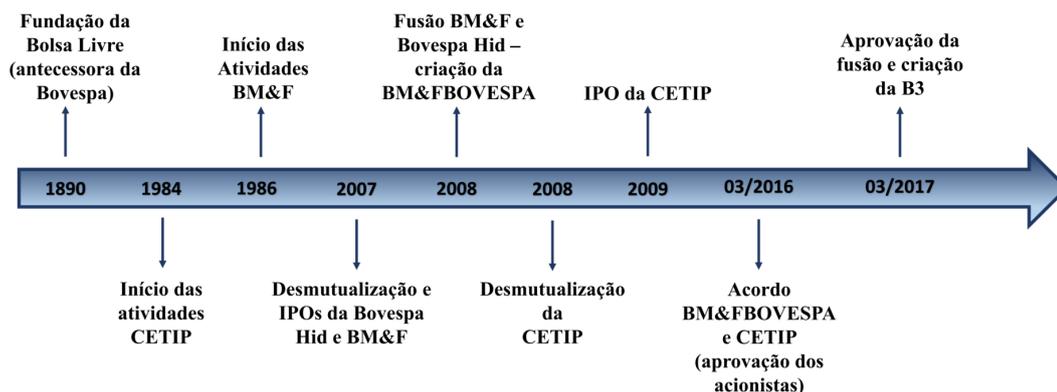


Figura 1 – Linha do tempo histórica da bolsa de valores brasileira  
 Fonte: Adaptada de B3 (2019a).

Porém, este sistema acabava sendo pouco eficiente, o que proporcionou o surgimento do pregão eletrônico, PE. É sabido que o encerramento total das atividades do PVV para o PE ocorreu em 2005 na Bovespa e em 2009 na BM&F (B3, 2019b). Ao passo que crescia a transição para o sistema eletrônico, as limitações apresentadas pelo PVV eram reduzidas.

Nesta época do PVV, o MC era praticamente dominado por pessoas jurídicas. Entretanto, sua democratização ocorreu com a criação do *home broker* (HB) em 1999, possibilitando a participação de pequenos e médios investidores na bolsa (AMORIM *et al.*, 2011; GUTMAN; JOIA; JR, 2014). Segundo Amorim *et al.* (2011), este pode ser considerado o marco inicial de entrada de PF na bolsa brasileira.

Com isto, a quantidade de corretoras no Brasil que ofereciam o HB cresceu expressivamente, pulando de 6 em 1999 para 60 em 2011 (GUTMAN; JOIA; JR, 2014). Em agosto de 2020 foram contabilizadas 90 corretoras listadas na B3, dentre elas, 39 disponibilizam o serviço de HB (B3, 2020b). Com as constantes evoluções do sistema desde 2009, atualmente é possível que os clientes insiram ordens automatizadas, os *algorithmic trade*, nos pregões por meio do modelo de DMA<sup>1</sup> (CVM, 2019a).

Por sua vez, a segmentação das áreas de negócio da B3 que possibilita ocorrer as negociações, é dividida em dois setores, Bovespa e BM&F. De acordo com o estudo fornecido em CVM (2019a), no segmento Bovespa é operado o universo das ações, valores mobiliários de renda variável e títulos de renda fixa. Por outro lado, no segmento BM&F é negociado derivativos de mercadorias e futuros, sendo estes agropecuários e financeiros.

O mercado de derivativos é caracterizado por contratos de liquidação em data futura, sendo estes: termo, futuro, opções e *swaps*. São assim chamados, pois derivam dos preços do ativo de referência em que o propósito de se criar derivativos visa atender aos objetivos de *hedge* (proteção), arbitragem e especulação. Por sua vez, os especuladores possuem papel fundamental, viabilizando a liquidez da outra ponta da operação de *hedge* (CVM, 2019a).

Segundo o documento citado, como os arbitradores não assumem riscos, o único parti-

<sup>1</sup> “O *Direct Market Access (DMA)* é um modelo de negociação que permite que o cliente final tenha acesso direto ao ambiente eletrônico de negociação em Bolsa” (CVM, 2019a).

cipante que é incumbido disto é o especulador. Por este motivo, normalmente não ficam expostos ao risco por muito tempo e dificilmente carregam as posições até a data de liquidação do contrato. Assim, a operação de especulação mais utilizada é o *daytrade*, também chamada de *intraday*, que consiste na abertura e encerramento da operação no mesmo dia de pregão.

Devido à diversidade existente no MC, não existe uma receita única de operação, havendo margem para múltiplas oportunidades, como mostrado no Quadro 1 (CVM, 2019a). As informações apresentam alguns tipos de investidores dotados de seus prováveis perfis de risco atrelados ao horizonte e objetivos de investimento. É possível inferir que o MC possui espaço tanto para aqueles que buscam rentabilidade imediata, como o caso da negociação por meio de algoritmos HFT, quanto rentabilidade futura, alinhada a reservas de aposentadoria e possíveis ganhos periódicos de dividendos. Outro ponto interessante refere-se a PF, podendo ter objetivos tanto em relação a prazos de investimento de médio quanto longo prazo, chamados de horizonte.

Quadro 1 – Perfis de investidores

Tipo	Horizonte	Perfil	Ativos	Objetivo
HFT ( <i>high frequency trading</i> )	CP	Agressivo	Diversos	Diário
Fundos diversos	CP	Fundo	Fundo	Fundo
PF	MP	Agressivo	Diversos	Rentabilidade definida
Fundos (pensão)	LP	Moderado	Empresas sustentáveis	Objetivo atuarial
PF	LP	Moderado a Conservador	Busca de dividendos e boa governança	Aposentadoria ou educação dos filhos

Fonte: Adaptado de (CVM, 2019a).

Por outro lado, no que se refere aos derivativos financeiros, o futuro de Ibovespa (IND) ganha destaque. Proveniente do índice Bovespa, representa o índice de ações de maior negociabilidade e representatividade do mercado de ações brasileiro (B3, 2019c). Sua composição é dada pela carteira teórica de ações e *units* negociadas na B3.

Deste modo, o contrato futuro de Ibovespa possibilita negociar expectativas futuras sem a necessidade de adquirir a carteira por completo, gerando custos menores e dispondo de alta liquidez (B3, 2019c). Contudo, existe outra vertente do IND que viabiliza a participação de investidores de pequeno porte, o futuro mini de Ibovespa (WIN). Os minicontratos tem objetivo de incentivar a maior participação de pessoas físicas nesta modalidade (B3, 2019d). Para visualizar este cenário, o Quadro 2 ilustra as principais diferenças entre os dois tipos de contratos futuros (B3, 2019c; B3, 2019d).

Os contratos diferem em relação ao valor atribuído a cada ponto de índice e o lote padrão mínimo negociável. Assim, cada ponto de IND possui o preço de R\$ 1,00 e seu lote mínimo são 5 contratos, enquanto o WIN é precificado em R\$ 0,20 e a partir de 1 unidade de contrato já é possível realizar operações. Deste modo, PFs e pequenas empresas podem iniciar suas atividades no mercado de derivativos com necessidade de menor capital investido (B3, 2019d).

Adicionalmente, os Quadros 3 e 4 apresentam um panorama referente ao tipo de investidor participante no IND e WIN, respectivamente, em abril de 2019. Observa-se um crescimento

Quadro 2 – Características técnicas do IND e WIN

Característica	IND	WIN
Objeto de negociação	Ibovespa	Ibovespa
Código de negociação	IND	WIN
Valor de cada ponto	1 ponto = R\$ 1,00	1 ponto = R\$ 0,20
Tamanho do contrato	Contrato × valor do ponto	Contrato × valor do ponto
Cotação	Pontos de índice	Pontos de índice
Variação mínima de apregoação	5 pontos de índice	5 pontos de índice
Lote padrão	5 contratos	1 contrato

Fonte: Elaboração própria.

duas vezes maior de participação de PF no WIN em relação ao IND. Este público ocupou posição de liderança frente aos demais tipos de investidores, corroborando para o objetivo do ativo.

Quadro 3 – Percentual do tipo de investidor no IND

Perfil do Investidor	Participação (%)
Não residente	52
Investidor institucional	30
Pessoa física	15
Instituição financeira	3

Fonte: Elaboração própria.

Quadro 4 – Percentual do tipo de investidor no WIN

Perfil do Investidor	Participação (%)
Pessoa física	46
Não residente	34
Investidor institucional	20
Instituição financeira	0

Fonte: Elaboração própria.

Usualmente, os investidores realizam diversas análises inerentes ao MC para poder tomar decisões sobre qual e quando operar determinado ativo, e uma delas é a previsão de preço futuro. Apesar da vasta quantidade de situações que requerem previsões, [Montgomery, Jennings e Kulahci \(2008\)](#) afirmam que existem somente duas abordagens de técnicas de previsão, os chamados métodos qualitativos e métodos quantitativos.

Segundo os autores citados, previsões qualitativas são subjetivas por natureza e demandam julgamento do profissional que a analisa. Além disto, os autores apontam que normalmente são utilizadas em cenários que não haja uma boa base de dados históricos, diferentemente dos métodos quantitativos, que utilizam dados históricos e modelos de previsão. Dada a natureza numérica dos dados utilizados para previsões de ativos financeiros, o método quantitativo engloba tanto a análise fundamentalista (AF), quanto a técnica (AT).

Primeiramente, a abordagem utilizada para a AF atenta aos fundamentos que envolvem uma empresa, como características financeiras, perspectivas de crescimento, fluxo de caixa e risco ([VANSTONE; FINNIE, 2009](#); [HAWAWINI; VIALLET, 2010](#)). O horizonte de investimento pretendido normalmente é de longo prazo, pois espera-se que desvios sejam corrigidos ao longo do tempo. Embora exista muitos documentos na literatura sobre AF desde 1928 com sua introdução por Benjamin Graham, propulsor da técnica *buy and hold* (B&H), o tema não é abordado com profundidade neste estudo pois foge do escopo da pesquisa.

Por sua vez, a referida AT teve origem no Japão, mais especificamente no mercado de arroz. O produtor, Munehisa Honma, criou um mecanismo de bandeiras para indicar a alta ou baixa da produção (CVM, 2019a). Deste modo, erguia-se uma bandeira branca se a produção de arroz fosse reduzida, fazendo com que o preço subisse, e de maneira oposta, uma bandeira preta era hasteada em caso de aumento da produção, que conseqüentemente reduziria o preço. Com base neste sistema criado pelo produtor e *trader* japonês, surgiram os primeiros fundamentos da técnica *candlestick*, trazida ao ocidente por Steve Nison (CVM, 2019a).

Entretanto, Charles Dow, fundador do “*Dow Jones & Company*” em 1882 (MURPHY, 1999), o “*Wall Street Journal*”<sup>2</sup> e o “*Dow Jones Industrial Average*” (DJIA)<sup>3</sup> (CVM, 2019a), foi quem elaborou os princípios para o desenvolvimento da AT no século XIX, que passou a ser chamada de Teoria Gráfica para a conhecida Teoria de Dow (BROCK; LAKONISHOK; LEBARON, 1992; MURPHY, 1999; CVM, 2019a).

Embora Charles Dow tenha falecido em 1902 sem ter escrito um livro, a coleção de artigos escritos e publicados no “*Wall Street Journal*” sobre sua observação referente aos padrões de comportamento dos preços das ações, resultou em dois principais compilados (MURPHY, 1999). Um ano após sua morte, S.A. Nelson publicou o livro “*The ABC of Stock Speculation*”, onde foi cunhado pela primeira vez o termo “Teoria de Dow” e, posteriormente, em 1922 William Peter Hamilton criou o livro “*The Stock Market Barometer*”.

Entre suas observações baseadas no DJIA, Charles Dow analisou o movimentos dos ativos, formulando os conhecidos princípios de tendência e sinais de reversão (CVM (2019a). Segundo o documento citado, haviam quatro movimentos cíclicos nos preços, sendo acumulação, elevação, distribuição e liquidação. Basicamente, investidores bem informados compravam ativos com boa perspectiva de valorização, estimulando compradores racionais e impulsionando o preço. Deste modo, o preço elevado despertava a atenção em massa, causando movimento de euforia no mercado e possibilitando aos investidores iniciais desmontar suas posições, por meio da venda para os compradores atrasados. Por fim, os investidores irracionais percebiam o equívoco, gerando saída simultânea e conseqüente cenário de pânico no mercado.

Adicionalmente, as bases da Teoria de Dow deram origem a outras conhecidas teorias, as Ondas de Elliot, desenvolvida por Ralph Elliot em “*The Wave Principles*”, abordando ondas de tendência de alta e baixa, e o famoso estudo de Fibonacci, que advém da razão áurea e foi inspirado nos conceitos de Elliot (MURPHY, 1999; CVM, 2019a). Pesquisas têm sugerido a relação da divisão do número oito por cinco como uma razão que tende a ser repetir continuamente na natureza, reforçando a ideia de que os mercados seguem padrões de comportamentos repetitivos. Estes possíveis padrões existentes, como a teoria de Dow, ondas de Elliot e padrões de Fibonacci, são os comportamentos que dão base aos estudos de AT (MURPHY, 1999).

Devido aos vastos estudos de AT, somados à possibilidade de operações automatizadas, empresas de tecnologia financeira (*FinTechs*), estão cada vez mais interessadas e presentes no

<sup>2</sup> <https://www.wsj.com/>

<sup>3</sup> O nome Jones em *Dow Jones & Company* vem de seu sócio fundador Edward Jones (CVM, 2019a).

MC. O Núcleo de Inovação em Tecnologias Financeiras (*FinTech Hub*) desenvolveu uma pesquisa com objetivo compreender o potencial impacto das *Fintechs* no MC brasileiro (CVM, 2016). Dentre as áreas ou atividades específicas de atuação, foi evidenciado que a área foco do trabalho, *algorithmic trading* é também de interesse de *Fintechs* ligadas ao MC, ocupando cerca de 5% deste mercado. Atualmente é permitido a utilização de estratégias de negociação na B3 utilizando *algotrading* (CVM, 2019b).

Adicionalmente, novas pesquisas sobre *FinTechs* apontam que a categoria de investimentos ainda é pouco explorada pelo setor. Uma pesquisa realizada com 205 *FinTechs* segmentou as principais áreas de atuação, onde a “Gestão de Investimentos” representou 8% do montante (ABFINTECHS, 2019). Além disso, outro levantamento mais detalhado realizado com 742 *startups* mapeou 14 diferentes categorias, revelando que a parcela pertencente às *FinTechs* de investimento ocuparam 5,8% do total (DISTRITO, 2020).

Estes cenários podem indicar oportunidades interessantes para aprofundamento e novos participantes, visto que o interesse crescente por inteligência artificial está cada vez mais presente no setor, apontado entre as cinco principais apostas tecnológicas, onde 68% dominam ou pretendem dominar no futuro (ABFINTECHS, 2019).

Diante de toda a explanação sobre a grande área do MC apresentadas nesta seção, foi possível situar o mercado em estudo de forma abrangente, possibilitando o entendimento, objetivo e finalidade do sistema proposto. Assim, a seção seguinte aborda os estudos bibliométricos de métodos de previsão utilizados no MC presentes na literatura.

## 2.2 Análise Bibliométrica

Com intuito de evidenciar a relevância e contribuição do método proposto ao campo de pesquisa, foi realizada uma abordagem quantitativa por meio de análise bibliométrica. A investigação referida permite o tratamento e agrupamento de uma considerável base de dados. Isto porque, dispõe de métodos matemáticos e estatísticos (LU; LIU, 2016), capazes de revelar informações que devido a características cognitivas limitadas dos seres humanos seria pouco provável inferir na mesma proporção (LIANG *et al.*, 2016).

Todavia, a confiabilidade do estudo depende da qualidade da base utilizada nas buscas. Assim, para atender ao propósito explanado a plataforma principal utilizada para extrair as publicações foi a *Scopus*, por abranger importantes periódicos e ser referência na academia (WANG; FANG; SUN, 2016). Entretanto, foi adicionada a plataforma *Web of Science*, uma das mais antigas (PARAS; PAL; EKWALL, 2018) a fim de refinar a busca e abranger possíveis trabalhos não contemplados na plataforma anterior.

Deste modo, a utilização destas plataformas fornece subsídios satisfatórios à quantidade, qualidade e análise dos dados. Além de serem identificadas como as bases de maior utilização nas revisões bibliográficas, seus dados são passíveis de análises bibliométricas por meio de *softwares*, como o *R Studio*® (CHADEGANI *et al.*, 2013; MONGEON; PAUL-HUS, 2016).

### 2.2.1 Seleção e coleta de dados

As buscas realizadas nas plataformas *Scopus* e *Web of Science* seguiram a mesma lógica, porém foram realizadas separadamente. A Tabela 1 sumariza os motores de busca utilizados contendo “palavras-chave” referentes a cada tema foco e suas possíveis variações. Também foi utilizado o seletor “*Article title, Abstract, Keywords*” e “*Topic*”. Por fim, dada a natureza acadêmica da pesquisa, os filtros “*Article*”, “*Conference Paper*” e “*Proceedings Paper*” delimitaram os tipos de documentos.

Tabela 1 – Termos de busca para coleta de dados

<b>Objeto de estudo</b>	<b>Variações</b>
“ <i>Stock Index</i> ”	“ <i>Stock Market</i> ”
	“ <i>Financial Market</i> ”
	“ <i>Market Index</i> ”
	“ <i>Future Market</i> ”
	“ <i>Future Stock Index</i> ”
<b>Objetivo</b>	<b>Variações</b>
“ <i>Forecasting</i> ”	“ <i>Forecast</i> ”
	“ <i>Predict</i> ”
<b>Parâmetros de entrada</b>	<b>Variações</b>
“ <i>Technical Analysis</i> ”	“ <i>Technical Indicators</i> ”
	“ <i>Graphical Analysis</i> ”
	“ <i>Candlestick Analysis</i> ”
<b>Ferramentas de Previsão</b>	<b>Variações</b>
“ <i>Statistical Method</i> ”	“ <i>Statistical Model</i> ”
	“ <i>Statistical Analysis</i> ”
“ <i>Computational Intelligence</i> ”	“ <i>Artificial Intelligence</i> ”
	“ <i>Machine Learning</i> ”
	“ <i>Reinforcement Learning</i> ”
	“ <i>Deep Learning</i> ”
<b>Modelo de Negociação</b>	<b>Variações</b>
“ <i>Automated Trading System</i> ”	“ <i>Automatically Trade</i> ”
	“ <i>Trading System</i> ”
	“ <i>Automated Decision Maker</i> ”
	“ <i>Automated Decision Making</i> ”
	“ <i>Stop Gain</i> ”
	“ <i>Stop Loss</i> ”
	“ <i>Take Profit</i> ”
	“ <i>Make Profit</i> ”
	“ <i>Transaction Cost</i> ”
“ <i>Intraday</i> ”	“ <i>Daytrade</i> ”
<b>Modelo final</b>	<b>Variações</b>
“ <i>Algorithm Trading</i> ”	“ <i>Algorithmic Trading</i> ”

Fonte: Elaboração própria.

Estas escolhas têm o objetivo de conduzir as buscas a resultar trabalhos diretamente re-

lacionados aos termos inseridos, sem excluir aqueles que utilizaram palavras semelhantes. Uma vez que deseja-se encontrar publicações pontuais, as aspas colocadas nos descritores focalizam o retorno dos termos completos. Demais restrições não foram aplicadas.

Em primeiro momento, os dados relativos aos termos-chave contidos no Quadro 5 foram levantados isoladamente, para em seguida iniciar os arranjos de acordo com a lógica do estudo. Deste modo, a combinação realizada visa encontrar a existência de trabalhos similares a proposta desta pesquisa. É importante destacar que o “objeto de estudo” foi aplicado em todas as buscas, a fim de não inflar os resultados com pesquisas fora do contexto.

Quadro 5 – Publicações filtradas pelos critérios das palavras-chave da pesquisa

<b>Termos Isolados</b>	<b>Número de Publicações Scopus</b>	<b>Número de Publicações Web of Science</b>
“Forecasting”	7.364	3.718
“Technical Analysis”	917	604
“Statistical Method”	1.046	210
“Computational Intelligence”	1.780	621
“Automated Trading System”	1.508	310
“Intraday”	811	499
“Algorithm trading”	3.690	1.618
<b>Integração ente os Termos</b>	<b>Número de Publicações Scopus</b>	<b>Número de Publicações Web of Science</b>
“Forecasting” AND “Technical Analysis” AND “Statistical Method” AND “Computational Intelligence Method” AND “Automated Trading System” AND “Intraday” AND “Algorithm trading”	0	0

Fonte: Elaboração própria.

Os resultados mostrados no Quadro 5 compreendem as publicações até os últimos meses de 2019 e referem-se a esta etapa de revisão bibliométrica. Novas pesquisas divulgadas nos períodos subsequentes foram monitoradas e conforme o interesse deste trabalho, foram adicionadas de forma pontual nas demais seções.

Primeiramente, a busca mostrada no Quadro 5 compreendeu o “objetivo”, a fim de evidenciar a contribuição da pesquisa. Em seguida, utilizou-se os “parâmetros de entrada” e cada tipo de “ferramentas de previsão”. Por fim, buscou-se as publicações referentes ao “modelo de negociação” e “modelo final”. Além disso, este quadro mostra a combinação total dos termos, em que não foram encontradas nenhuma publicação no período desta pesquisa bibliométrica.

Deste modo, as combinações realizadas no Quadro 6, visaram encontrar o primeiro arranjo que retornasse algum documento publicado. Utilizou-se a lógica de busca “Integração entre os Termos” contida no Quadro 5 como base inicial e a cada interação retirava-se o último termo de busca até obter alguma publicação.

Quadro 6 – Combinações entre os termos

Termos Combinados	Número de Publicações Scopus	Número de Publicações Web of Science
<i>“Forecasting” AND “Technical Analysis” AND “Statistical Method” AND “Computational Intelligence Method” AND “Automated Trading System” AND “Intraday” AND “Algorithm trading”</i>	0	0
<i>“Forecasting” AND “Technical Analysis” AND “Statistical Method” AND “Computational Intelligence Method” AND “Automated Trading System” AND “Intraday”</i>	0	0
<i>“Forecasting” AND “Technical Analysis” AND “Statistical Method” AND “Computational Intelligence Method” AND “Automated Trading System”</i>	0	0
<i>“Forecasting” AND “Technical Analysis” AND “Statistical Method” AND “Computational Intelligence Method”</i>	7	1

Fonte: Elaboração própria.

Observa-se que a primeira busca que apresentou publicação relaciona-se ao objetivo deste estudo. Assim, os demais arranjos foram realizados no Quadro 7, combinando “previsão” e “análise técnica” proveniente da Tabela 1, sendo esta a primeira junção. Deste modo, as próximas etapas contidas no Quadro 7 concentram-se no foco do trabalho.

Quadro 7 – Primeira interação entre previsão e análise técnica com os demais termos

Interações de Previsão e Análise Técnica	Número de Publicações Scopus	Número de Publicações Web of Science
<i>“Forecasting” AND “Technical Analysis”</i>	443	263
<i>“Forecasting” AND “Technical Analysis” AND “Statistical Method”</i>	18	5
<i>“Forecasting” AND “Technical Analysis” AND “Computational Intelligence”</i>	145	72
<i>“Forecasting” AND “Technical Analysis” AND “Automated Trading System”</i>	40	18
<i>“Forecasting” AND “Technical Analysis” AND “Intraday”</i>	12	10
<i>“Forecasting” AND “Technical Analysis” AND “Algorithm trading”</i>	151	78

Fonte: Elaboração própria.

Por meio dos resultados apresentados no Quadro 7 verifica-se um maior interesse da academia em pesquisas que envolvam CI ao invés de métodos estatísticos. Esta inferência é corroborada pois os métodos computacionais com inteligência artificial estão sendo considerados o estado da arte no tema e também por apresentarem maior número de publicações.

Identifica-se também, a oportunidade do objeto de estudo, pois os trabalhos que envolvem análise do mercado *intraday*, são menos de 5% do montante. De forma semelhante, os

resultados dos modelos de negociação possuem menor incidência de pesquisas em relação aos modelos finais, pois estes caracterizam naturalmente o fruto do trabalho.

Por fim, para refinar a pesquisa sem fugir do escopo do trabalho, foi realizado o arranjo final acrescentando o termo “*Computational Intelligence*”, conforme Quadro 8. Como pode ser observado, a escassez de documentos encontrados nos arranjos desta fase demonstram a contribuição científica da pesquisa. Assim, os trabalhos evidenciados no referido quadro são de suma importância ao estudo e sua investigação é apresentada na seção de trabalhos relacionados.

Quadro 8 – Interação entre previsão, análise técnica e método computacional com os demais termos

<b>Interações de Previsão, Análise Técnica e Método Computacional</b>	<b>Número de Publicações Scopus</b>	<b>Número de Publicações Web of Science</b>
“ <i>Forecasting</i> ” AND “ <i>Technical Analysis</i> ” AND “ <i>Computational Intelligence</i> ” AND “ <i>Automated Trading System</i> ”	16	7
“ <i>Forecasting</i> ” AND “ <i>Technical Analysis</i> ” AND “ <i>Computational Intelligence</i> ” AND “ <i>Automated Trading System</i> ” AND “ <i>Intraday</i> ”	1	1
“ <i>Forecasting</i> ” AND “ <i>Technical Analysis</i> ” AND “ <i>Computational Intelligence</i> ” AND “ <i>Automated Trading System</i> ” AND “ <i>Algorithm trading</i> ”	8	4
“ <i>Forecasting</i> ” AND “ <i>Technical Analysis</i> ” AND “ <i>Computational Intelligence</i> ” AND “ <i>Automated Trading System</i> ” AND “ <i>Intraday</i> ” AND “ <i>Algorithm trading</i> ”	1	0

Fonte: Elaboração própria.

Por meio das combinações e arranjos realizados, foi possível delimitar o conjunto ideal de dados utilizados no *software* de análise bibliométrica, *R Studio*<sup>®</sup> módulo bibliometria<sup>4</sup>. Para se ter uma visão geral das pesquisas sem prejudicar o cerne do trabalho, foram selecionadas todas as publicações fruto da combinação “*Forecasting*” AND “*Technical Analysis*” AND “*Computational Intelligence*”, apresentadas no Quadro 7.

É importante ressaltar que após a análise bibliométrica, foi necessária a refinação dos documentos passíveis de leitura, que compõem os trabalhos relacionados apresentados na Seção 2.3. Assim, foram incluídos somente os trabalhos que aplicaram primária ou secundariamente análises quantitativas pra previsão em séries financeiras do MC. Por conseguinte, foram excluídos os trabalhos referentes a notícias, textos e afins inclusos como parâmetros de entrada. Por fim, foram eliminados possíveis trabalhos duplicados.

Primeiramente, os dados referentes às buscas selecionadas foram compilados por plataforma de busca em uma pasta *zip* e posteriormente inseridos no *R Studio*<sup>®</sup>. O *software* faz a leitura dos dados e gera relatórios padronizados. Estes relatórios são apresentados por meio de

<sup>4</sup> library(bibliometrix)  
biblioshiny()

tabelas, gráficos e ilustrações em que alguns parâmetros de visualização da análise podem ser ajustados conforme necessidade.

Assim, a oportunidade de agrupar uma enorme quantidade de dados gerando padrões e tendências de pesquisa por meio de informações visuais possibilita uma análise criteriosa que seria humanamente insuficiente, isto é, o *software* engloba uma vasta quantidade de dados que devido a características cognitivas limitadas dos seres humanos, seria pouco provável inferir na mesma proporção (LIANG *et al.*, 2016). Com isto, segue-se para a análise dos dados.

### 2.2.2 Análise dos dados

Primeiramente, foi possível identificar por meio das análises contidas no *software*, que para esta base de publicações utilizada, aponta-se para uma formação de pesquisas em 2002. Vale destacar que embora seja sabido que os estudos quantitativos datam de meados do século XIX, o ponto de partida em questão refere-se somente aos documentos inseridos nesta análise, conforme citado na seção anterior. A devida evolução histórica referente ao interesse acadêmico da área será abordada nas seções seguintes.

Alguns anos após esse marco inicial em 2002, houve um avanço expressivo de publicações, de 2009 a 2010, em termos proporcionais aos anos anteriores, mas que logo se contraiu até 2013, ano sinalizado como uma tomada de impulso ao início de um novo ciclo de alta. Desde então, a produção científica seguiu um nível de crescimento exponencial, como pode ser observado na Figura 2.

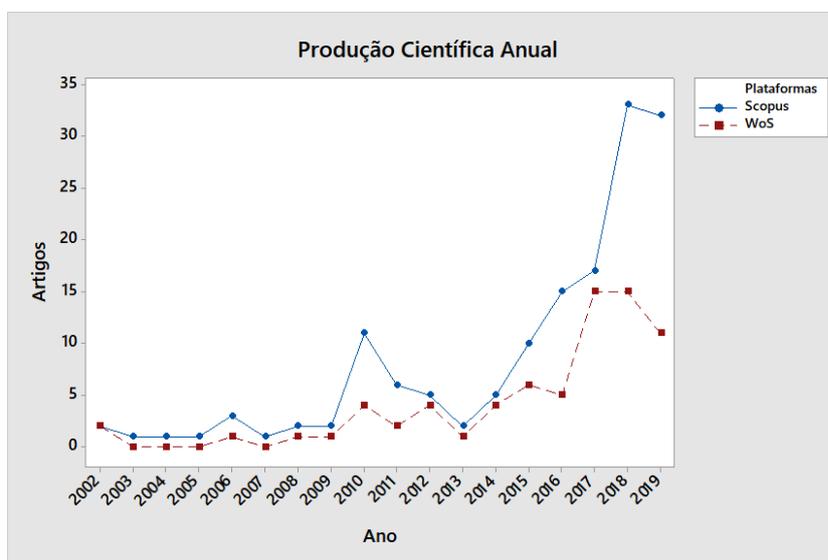


Figura 2 – Produção científica anual *Scopus* e *Web of Science*

Fonte: Elaboração própria.

Estes ciclos de alta surgiram logo após a crise financeira norte-americana em 2008. A conhecida crise do *subprime*, despertou questionamentos sobre a estrutura do sistema financeiro americano e internacional, bem como seus riscos sistêmicos e mecanismos de supervisão e

regulação (CINTRA; FARHI, 2008). Eclodida em 2007, a crise agravou-se em 2008, causando o desaparecimento e falência de grandes bancos de investimento.

A bolha especulativa gerada no setor imobiliário americano desencadeou uma crise mundial. Seus reflexos atingiram tanto as economias desenvolvidas como países de baixa renda por um período considerável. Segundo o IMF (2013) as economias globais apresentavam progresso gradual, mas as perspectivas ainda permaneciam moderadas, uma vez que economias avançadas enfrentavam um longo, difícil e incerto caminho para a sustentabilidade fiscal.

Como é sabido, momentos de crise geram oportunidades. Deste modo, o enfraquecimento dos Estados Unidos, que refletiu numa recessão econômica internacional, paralelo ao crescimento das pesquisas sobre AT, podem estar correlacionados e não se tratar apenas de coincidência. Se as análises macroeconômicas, insumos das análises fundamentalistas estavam em risco, naturalmente intensificou-se o interesse pelos métodos quantitativos AT. Entretanto, estudos mais aprofundados são necessários para poder corroborar com a hipótese levantada.

Outro importante relatório proporcionado pelo *software* diz respeito às fontes. A relevância foi mensurada pelo volume de publicações, as citações pela quantidade e o fator de impacto pelo índice H. Com isto, a revista *Expert Systems With Applications* foi o periódico com maior impacto observado nas duas plataformas. Logo depois, o *Journal Applied Soft Computing* mostrou uma curvatura acentuada de crescimento pelo *Scopus*, podendo ganhar maior representatividade e se tornar uma fonte mais atrativa aos pesquisadores.

Referente às citações, nas Figuras 3 e 4 são reveladas as dez fontes mais citadas em cada plataforma. Com essas informações fica evidente que a revista *Expert Systems With Applications* representa alto valor ao estudo, sinalizando um local robusto para publicações. Além disto, o relevante periódico *The Journal of Finance* também está entre os destaques.

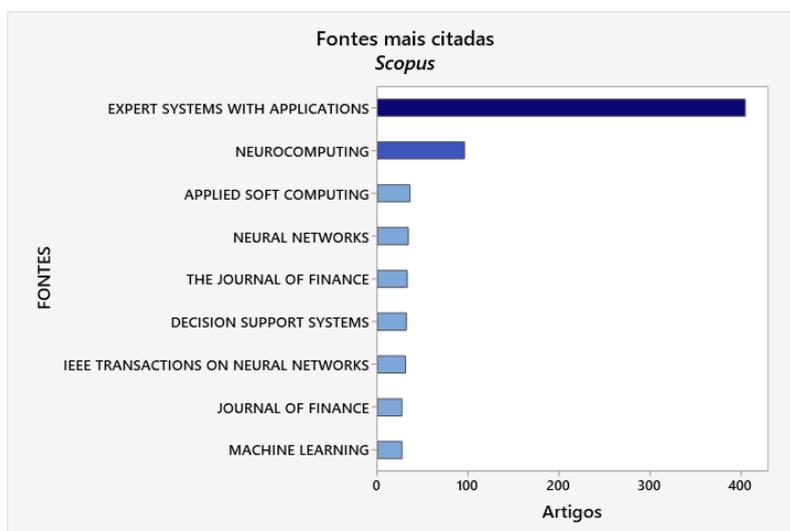


Figura 3 – Dez fontes mais citadas do *Scopus*

Fonte: Elaboração própria.

Por outro lado, a classificação dos países em volume de publicação e quantidade de citações mostradas nas Figuras 5 - 8, evidencia posição de destaque para o Brasil, ocupando

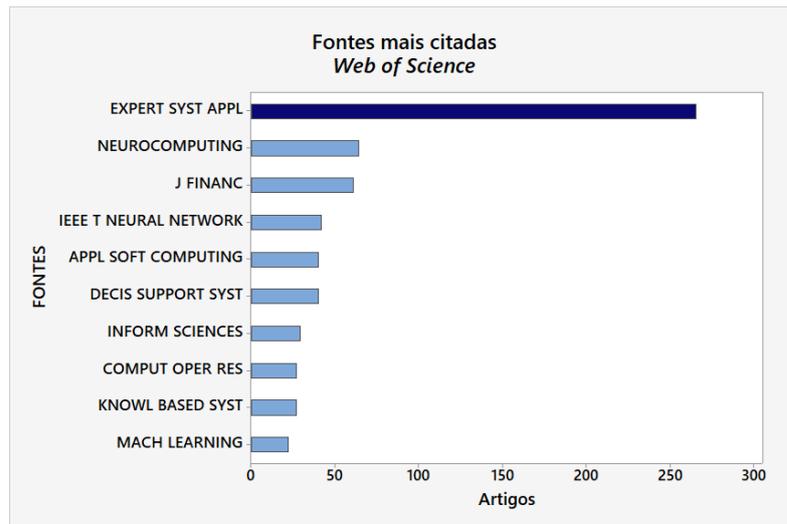


Figura 4 – Dez fontes mais citadas do *Web of Science*  
 Fonte: Elaboração própria.

o terceiro lugar nas categorias. Além disso, a quantidade de publicações brasileiras ficaram quase empatadas com as chinesas, Figura 5 e 6. Dentre os vinte países listados, 70% não têm publicado em conjunto com algum outro país, como é o caso do Brasil.

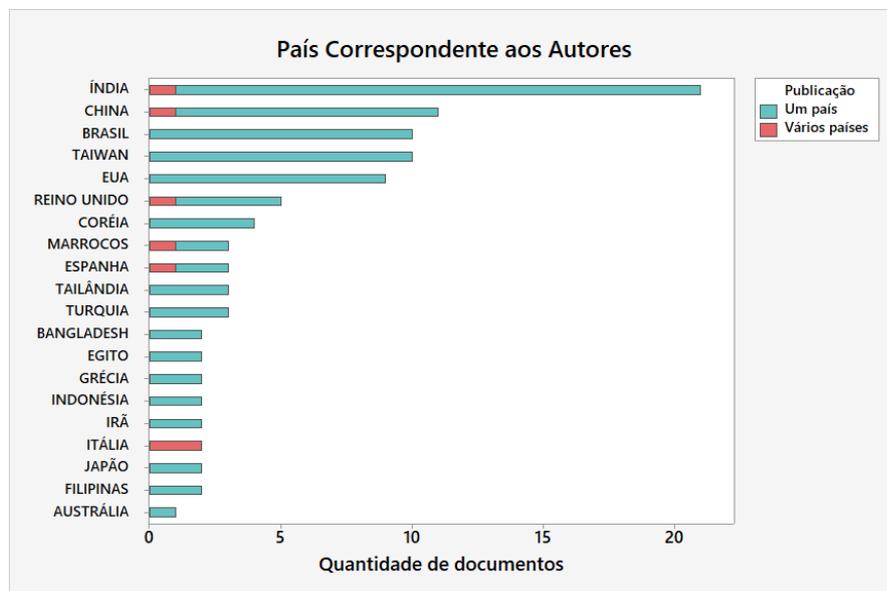


Figura 5 – Países correspondentes aos autores da base *Scopus*  
 Fonte: Elaboração própria.

Considerando as citações recebidas, Figuras 7 e 8, o Brasil ficou somente atrás de Taiwan e EUA, respectivamente. Por outro lado, em relação aos demais países classificados, a partir da oitava posição observa-se que o número de citações reduz significativamente nas duas plataformas analisadas. Ou seja, o Brasil está contido nos grupos de maior concentração.

Por fim, entre as palavras-chave mais incidentes, a posição de DL mostrou uma proporção relativamente menor em relação ao montante das demais palavras, indicando ser uma

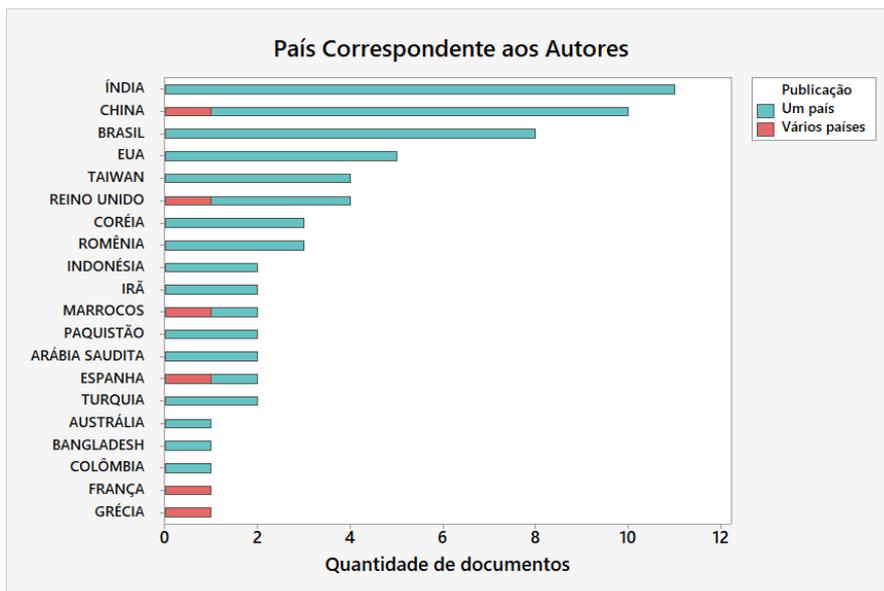


Figura 6 – Países correspondentes aos autores da base *Web of Science*  
 Fonte: Elaboração própria.

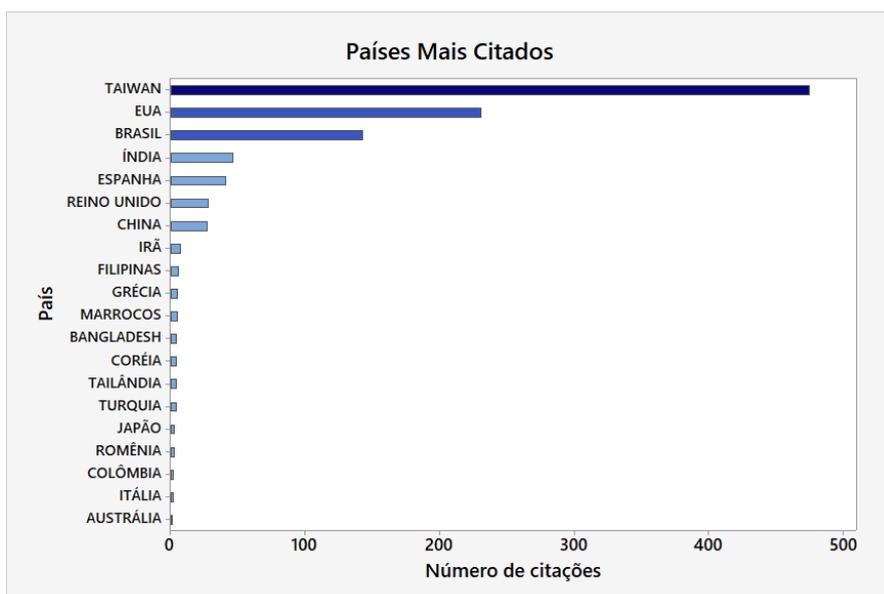


Figura 7 – Os vinte países mais citados da base *Scopus*  
 Fonte: Elaboração própria.

área ainda pouco explorada pelos pesquisadores. Devido ao fato de sua aplicação para o MC ter se intensificado há praticamente três anos e atualmente ser considerada o estado-da-arte, esta menor incidência sinaliza oportunidades de pesquisa e geração de novos conhecimentos para a academia. Dito isto, encerra-se a análise bibliométrica, evidenciando os principais pontos de interesse ao estudo. Seus documentos passíveis de leitura são abordados na próxima seção.

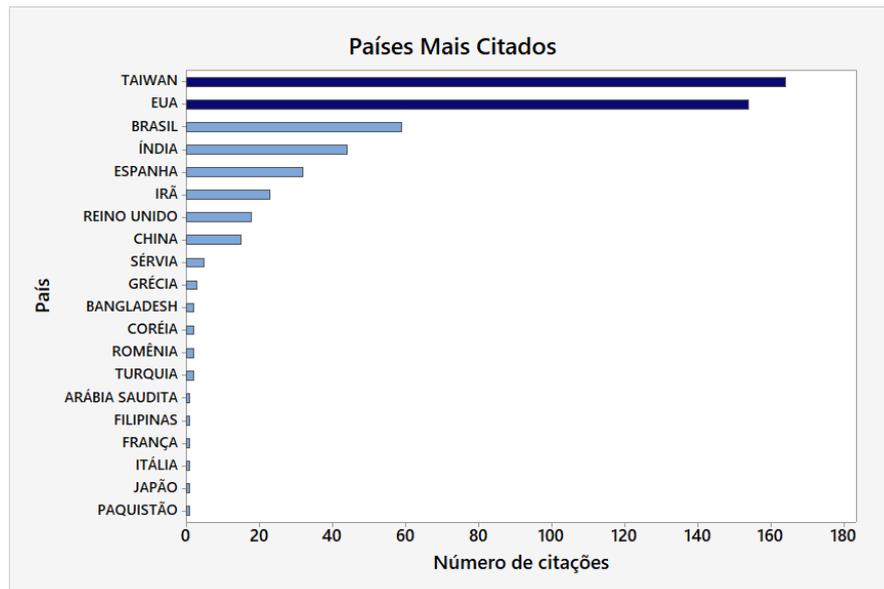


Figura 8 – Os vinte países mais citados da base *Web of Science*

Fonte: Elaboração própria.

## 2.3 Trabalhos Relacionados

Os métodos de previsão possuem grande destaque por abranger o interesse tanto de investidores quanto de pesquisadores. Deste modo, esta seção apresenta as preponderantes publicações evidenciadas a partir da pesquisa bibliométrica e demais trabalhos relevantes ao estudo. O objetivo deste item foi buscar uma revisão robusta do que têm sido pesquisado ao longo dos tempos, servindo de base teórica a construção do algoritmo proposto.

Os principais desafios para a construção dos modelos de previsão para o mercado financeiro encontram-se no tratamento de suas séries temporais. Séries temporais financeiras são dinâmicas e caracterizadas por não linearidade (SI; YIN, 2013; CAVALCANTE *et al.*, 2016). Aspectos como a grande propensão a ruídos e o comportamento caótico por natureza, ocorrem devido ao fato dos preços de ações e índices serem afetados por razões diversas, causando uma dinâmica não parametrizada (WANG *et al.*, 2011). Os autores afirmam que a tarefa de previsão não é somente um grande desafio, trata-se de amplo interesse de investidores.

Assim, esta seção foi dividida em duas partes, com o objetivo de apresentar os principais trabalhos relacionados aos métodos quantitativos preditivos, temática da pesquisa em questão. Deste modo, primeiramente foi realizada uma breve explanação a respeito dos métodos introdutórios na Seção 2.3.1, para em seguida apresentar os métodos quantitativos baseados em CI na Seção 2.3.2.

### 2.3.1 Métodos de previsão introdutórios

As previsões de séries temporais financeiras iniciaram com os métodos estáticos, também conhecidos como modelos econométricos. Esta análise era baseada na premissa de que as

séries eram geradas de um processo linear e com isto eram realizadas as previsões (MONTGOMERY; JENNINGS; KULAHCI, 2008; BROOKS, 2019). Porém, este argumento não era correto, devido às características já citadas anteriormente das séries temporais financeiras. Com o avanço da computação, a utilização de CI nas previsões ganharam maior destaque devido ao sucesso alcançado. Desta forma, vários autores realizaram estudos comparativos, a fim de corroborar para a questão, como por exemplo Bahrammirzaee (2010), Adebisi, Adewumi e Ayo (2014), Hsu *et al.* (2016).

Bahrammirzaee (2010) buscou avaliar e comparar a precisão de técnicas de redes neurais artificiais (em inglês, *Artificial Neural Network - ANN*), *Expert Systems (ES)* e *Hybrid Intelligence Systems (HES)* com métodos tradicionais estatísticos ao longo dos últimos 20 anos. Os resultados mostraram que os modelos de CI apresentaram em sua grande maioria precisão superior aos métodos estatísticos. Dentre estes, o autor relata que modelos híbridos possuem melhor desempenho, pois se propõe a resolver deficiências dos sistemas isolados.

Adebisi, Adewumi e Ayo (2014) realizaram um estudo comparativo entre o método estatístico *Autoregressive Integrated Moving Average (ARIMA)* e o modelo computacional ANN a partir de 5.680 observações referentes às ações da empresa “Dell” no período de 1988 a 2011. Os resultados apresentados pelos autores mostraram que os dois modelos obtiveram boas previsões, entretanto, o modelo ANN mostrou desempenho superior com a precisão bastante próxima aos dados reais.

Por sua vez, Hsu *et al.* (2016) realizaram um estudo considerável de comparação dos modelos estatísticos frente aos métodos de ML. A base de dados utilizada compreendeu 34 mercados diferentes, de 2008 a 2014. Os autores confrontaram o modelo estatístico *Autoregressive (AR)* frente ao modelo de ML *Support Vector Machines (SVM)*, uma vez que testes realizados identificaram estes dois como os melhores de cada divisão. Após 272 previsões distintas, os autores puderam concluir que o método SVM é substancialmente superior ao método econométrico.

Assim, é possível dizer que os modelos estatísticos desempenham um papel secundário nos estudos de previsões para mercados financeiros. Em especial o artigo predecessor (HSU *et al.*, 2016) relativamente recente, forneceu evidências robustas quanto a aplicabilidade de ML nos métodos preditivos. À vista disso, não traz grandes contribuições ao estudo estender a revisão literária dos modelos estatísticos. Deste modo, o capítulo evoluiu para próxima seção tratando especificamente dos métodos de CI, em linha com objetivo de revelar a curva de conhecimento científica.

### 2.3.2 Métodos de previsão baseados em inteligência computacional

A complexidade apresentada pelas séries temporais financeiras fez com que os estudos de CI buscassem uma investigação com maior profundidade, a fim de modelar a realidade dinâmica dos ativos e apresentar métodos que pudessem retratar estratégias de *trade* para aplicação prática.

Embora o estudo minucioso de Bahrammirzaee (2010) tenha apresentado resultados significativos ao uso de CI, o autor concluiu que a maior dificuldade ainda compreendia lidar com os problemas inerentes a não linearidade dos modelos. Mas com a intensificação das pesquisas, as técnicas se tornaram mais sofisticadas, podendo ser capazes de lidar melhor com a complexidade indicada por Podsiadło e Rybiński (2014). Estes autores propuseram uma revisão de 1992 a 2012 da clássica técnica *rough sets*. A pesquisa revelou que a técnica foi eficiente na solução de problemas tanto na área de finanças como economia.

Segundo a *survey* – tipo de metodologia de pesquisa – realizada por Atsalakis e Valavanis (2009), a aplicação de *soft computing* (SC) mostrou como outra área de CI têm sido aplicada com relativo sucesso para previsão, revelando bons resultados. Os autores apontaram que os dois principais fatores são referentes à capacidade de capturar uma relação de não linearidade entre fatos relevantes do mercado sem seu conhecimento prévio, e exigência de menor custo computacional. Além disto, trabalhos utilizando GA também têm gerado resultados relevantes ao tema segundo Brito e Oliveira (2012) e Radeerom (2014).

Adicionalmente, Brito e Oliveira (2016) deram continuidade ao seu *trading system* (TS) elaborado em 2012. O novo estudo utilizou uma junção de técnicas de SC. Assim, os resultados experimentais aferidos por Brito e Oliveira (2016) indicaram melhora da rentabilidade do modelo proposto, 2016, em comparação com o próprio modelo de 2012.

É importante ressaltar que uma das técnicas mais difundidas de CI para previsão é a utilização de ANN. O primeiro estudo a respeito da aplicabilidade desta abordagem para o mercado de ações foi elaborado por White (1988). A partir disto, diversas pesquisas surgiram e ampliaram os horizontes das previsões para preços e movimentos dos ativos do MC (TEIXEIRA; OLIVEIRA, 2010; WANG *et al.*, 2011; RODRÍGUEZ-GONZÁLEZ *et al.*, 2011; HUANG *et al.*, 2014; ADEBIYI; ADEWUMI; AYO, 2014; ORIANI; COELHO, 2016; PINTO; SCHNITMAN; REIS, 2018).

Todavia, segundo Rodríguez-González *et al.* (2011), os modelos tradicionais de ANN apresentavam limitações. Isto abriu espaço para o desenvolvimento e aplicação de novas técnicas de ML, a fim de tentar resolver estes problemas. A principal deficiência encontrada era devido ao fato dos modelos comumente sofrerem com *overfitting*, a maior desvantagem do princípio de minimização de risco (KUMAR; MEGHWANI; THAKUR, 2016).

Dentre os modelos que vêm aplicando ML, destacam-se as pesquisas (BRASILEIRO *et al.*, 2013; GONZALEZ; PADILHA; BARONE, 2015; GERLEIN *et al.*, 2016; HSU *et al.*, 2016; WU; MAO; LI, 2018; ZHOU *et al.*, 2019). Brasileiro *et al.* (2013) utilizaram estratégias de *stop gain* e *stop loss*. Os autores compararam o modelo desenvolvido com a proposta de Teixeira e Oliveira (2010), cujos resultados mostraram que o modelo proposto alcançou melhor desempenho global e rentabilidade, mesmo considerando os custos de transação.

Por outro lado, Gonzalez, Padilha e Barone (2015) desenvolveram um algoritmo de previsão semanal para o Ibovespa. Com base nos resultados obtidos, os autores consideraram o modelo uma ferramenta útil para *traders*. Gerlein *et al.* (2016) utilizaram seis modelos binários

de classificação para FOREX. De acordo com os autores, apesar dos modelos não serem dotados de alta acurácia, foram capazes de apresentar rentabilidade em sua maioria.

Existem diferentes tipos de aprendizagem de máquina e a técnica de aprendizagem supervisionada é um método de otimização do modelo, trabalhada com maior atenção na literatura. Devido à escassez de pesquisas publicadas na área, o tema tem sido caracterizado como algo inovador e a relevância do método é significativa, uma vez que representa uma boa alternativa aos problemas de *overfitting* (ZHOU *et al.*, 2019), falhas normalmente encontradas na utilização de ANN. O modelo desenvolvido pelo autor citado considera na fase de teste do algoritmo, os custos de transação, levando ao entendimento de aplicabilidade real do modelo, uma vez a rentabilidade atingiu performance superior a maioria dos demais comparados.

Assim, esta temática ganha ainda mais importância com o extenso estudo empregado por Hsu *et al.* (2016), que testou e comprovou a superioridade em utilizar o método SVM, classificado como ferramenta de aprendizagem supervisionada, em detrimento dos modelos amplamente empregados de ANN, como já mencionado anteriormente. Em adição, o estudo publicado por Wu, Mao e Li (2018) comprova que a aplicação de otimização é eficaz a melhora das previsões de mercado.

Aprofundando, modelos avançados de inteligência artificial, como a aprendizagem profunda (em inglês, *Deep Learning - DP*) ganham atenção. Nelson, Pereira e Oliveira (2017) construíram um modelo de previsão *intraday* baseado em ML com uso da técnica *Long Short-Term Memory* (LSTM). A avaliação do modelo foi comparada com outros algoritmos mais tradicionais de ML e estratégias de investimento. Por sua vez, o modelo proposto alcançou boa precisão e retorno financeiro superior a técnica B&H.

No quesito processamento de imagem, Sezer e Ozbayoglu (2018) desenvolveram um *algotrading* a partir de uma rede *Convolutional Neural Network* (CNN). O objetivo foi transformar séries temporais em imagens 2-D. A análise dos resultados foi satisfatória ao estudo. Assim, em comparação as demais estratégias comuns, dentre elas a clássica B&H, o modelo apresentou melhores resultados.

Posto isso, os principais trabalhos relacionados a proposta desta dissertação foram sumarizados no Quadro 9 em ordem cronológica decrescente de publicação. Foram extraídas das publicações somente informações úteis à construção do TS proposto. Nesta linha, se faz importante saber o tempo gráfico utilizado e o período que compreende as bases de dados, segunda e terceira coluna, respectivamente. Em seguida, é mostrado o objeto de estudo e seus respectivos mercados. Por sua vez, o item “Tec. CI” refere-se à técnica de CI empregada e na coluna posterior são apresentados os indicadores técnicos (em inglês, *Technical Indicators - TI*) utilizados de forma quantificada.

Por sua vez, as três últimas colunas caracterizam as informações principais à contribuição deste trabalho. Por meio de uma classificação binária nominal simples buscou-se identificar se os trabalhos estavam avaliando os custos de transação das operações, se as estratégias de gerenciamento de risco “*stop gain* e *stop loss*” foram inseridas e por fim, se os teste realizados

Quadro 9 – Métodos de previsão

Estudo	Dados candle	Tempo	Objeto de estudo	Mercado	Tec. CI	TI	Custos	Stop Gain e Stop Loss	Teste conta real
Zhou <i>et al.</i> (2019)	diário	2012 - 2014	índice de ação	China e EUA	ML	12	Sim	Não	Não
Sezer e Ozbayoglu (2018)	diário	2002 - 2017	ação e ETF	EUA	DL	15	Não	Não	Não
Pinto, Schnitman e Reis (2018)	60 min	2012-2016	ação	Brasil	ANN	3	Não	Não	Não
Wu, Mao e Li (2018)	diário	2010-2018	comodite	-	ML	7	Não	Não	Não
Nelson, Pereira e Oliveira (2017)	15 min	2008 - 2015	ação	Brasil	DL	175	Não	Não	Não
Brito e Oliveira (2016)	diário	2005 - 2012	Forex	EUA	SC	4	Não	Não	Não
Hsu <i>et al.</i> (2016)	60 min	2008-2014	índice de ação	Américas, África, Ásia, Europa e Oriente Médio	ML	8	Não	Não	Não
Gerlein <i>et al.</i> (2016)	60 min	2002-2009	Forex	EUA, Europa e Japão	ML	2	Não	Não	Não
Oriani e Coelho (2016)	diário	2013-2014	ação	Brasil	ANN	12	Não	Não	Não
Gonzalez, Padilha e Barone (2015)	semanal	1989-1998	índice de ação	Brasil	ML	7	Não	Não	Não
Adebiyi, Adewumi e Ayo (2014)	diário	1988-2011	ação	EUA	ANN	-	Não	Não	Não
Radeerom (2014)	diário	2010-2013	índice de ação	Tailândia	GA	5	Não	Não	Não
Huang <i>et al.</i> (2014)	diário	1980-2012	ação e índice de ação	Ásia, Canadá e EUA	ANN	7	Não	Não	Não
Brasileiro <i>et al.</i> (2013)	diário	1998-2009	ação	Brasil	ML	-	Sim	Sim	Não
Brito e Oliveira (2012)	diário	2005-2012	Forex	EUA	GA	4	Não	Não	Não
Rodríguez-González <i>et al.</i> (2011)	diário	2005-2009	ação e índice de ação	Espanha	ANN	1	Não	Não	Não
Wang <i>et al.</i> (2011)	mensal	1993-2009	índice de ação	China	ANN	-	Não	Não	Não
Teixeira e Oliveira (2010)	diário	1998-2009	ação	Brasil	ANN	5	Sim	Sim	Não

Fonte: Elaboração própria.

foram aplicados em contas reais.

Os dados contidos no Quadro 9 fornecem informações que sustentam a pesquisa proposta. A grande maioria dos trabalhos analisados não têm realizado estudos para o mercado

*intraday* e avaliação dos custos de transação. Observa-se que as estratégias de *stop gain* e *stop loss* foram aplicadas somente em Teixeira e Oliveira (2010) e Brasileiro *et al.* (2013). Além disto, nos documentos analisados neste estudo bibliográfico, não foram encontradas publicações com testes realizados em conta real.

Por fim, foi possível observar uma tendência de pesquisas voltadas ao uso de técnicas mais sofisticadas, como DL. Vale lembrar que a importância de DL também foi sinalizada na análise bibliométrica na seção 2.2. Diante disto, a próxima seção finaliza este capítulo de fundamentação teórica abordando a conceitualização necessária à base do modelo proposto neste trabalho.

## 2.4 Conceitualização

O termo inteligência artificial (em inglês, *Artificial Intelligence* - AI), foi cunhado por John McCarthy em 1956 (MOOR, 2006) no Projeto de Pesquisa de Verão de Dartmouth (MC-CARTHY *et al.*, 2006) e configura a grande área de conhecimento que abrange os conceitos de ML. Esta época se tornou o marco da evolução dos estudos no campo da AI, impulsionando também as pesquisas de ANN, que décadas adiante ganhariam popularidade com a aplicação de DL.

Tendo em vista que estes conceitos vêm sendo extensivamente abordados na literatura e se tornaram de amplo conhecimento, o presente estudo descreve um breve relato de sua evolução temática sem fugir do escopo do trabalho. Primeiramente, a relação entre as áreas de AI citadas podem ser observadas por meio da figura 9.

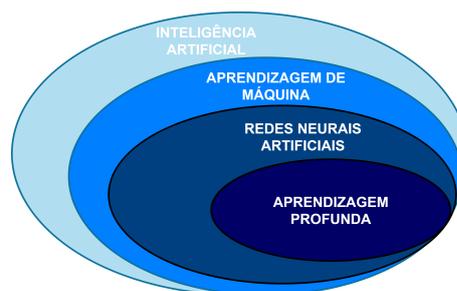


Figura 9 – Inteligência Artificial e suas ramificações

Fonte: Elaboração própria.

Os estudos de uma ANN datam desde 1940, onde McCulloch e Pitts (1943) introduziram o primeiro modelo computacional de ANNs. Após amplamente estudada, esta aplicação caiu em desuso devido a fatores tecnológicos limitantes que dificultaram seu progresso. Somado a isto, o surgimento de novos algoritmos, como o SVM, foi capaz de superar sua performance em vários aspectos.

Posteriormente, no ano de 2000, houve o retorno das ANNs associadas às técnicas de DL, mas somente por volta de uma década depois foi quando aconteceu o significativo impulso da área, revolucionando as pesquisas. Acompanhada da transformação digital e computacional

que o mundo passava neste período, sofisticadas pesquisas trouxeram algoritmos surpreendentes com a utilização de DL, possibilitando agora resolver problemas complexos não solucionados anteriormente. Assim, em 2017 ocorreu o verdadeiro marco de DL com o famoso caso do algoritmo AlphaGo, que foi capaz de vencer o campeonato mundial do complexo jogo de tabuleiro Go (SILVER *et al.*, 2016).

Em síntese, o funcionamento de uma rede profunda encontra-se na adição de maiores quantidades de camadas ocultas para um conjunto de dados suficientemente grande, possibilitando o tratamento de problemas complexos antes não suportados pelas tradicionais ANNs. Embora pareça simples, trata-se de uma sofisticada abordagem que só foi possível devido a transformação tecnológica ocorrida, como a evolução do setor computacional, internet e o conhecido movimento *big data*<sup>5</sup>.

Primeiramente, as redes neurais artificiais foram criadas com objetivo de representar matematicamente o funcionamento do sistema nervoso de um cérebro (MCCULLOCH; PITTS, 1943). Sua estrutura é formada por unidades chamadas de neurônios e as interações existentes entre eles são responsáveis pela transmissão de informações. Este processo assemelha-se ao sistema biológico, uma vez que é inspirado em redes neurais biológicas. Sua estrutura e representação matemática são mostradas na Figura 10 e Equação 2.1, respectivamente (JAIN; MAO; MOHIUDDIN, 1996).

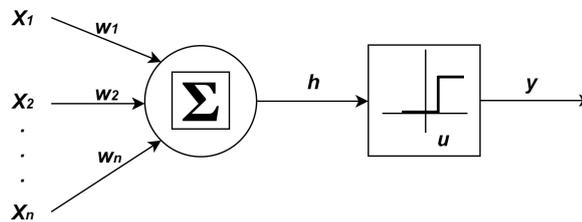


Figura 10 – Representação do modelo de um neurônio de McCulloch-Pitts.

Fonte: Adaptada de (JAIN; MAO; MOHIUDDIN, 1996).

$$y = \theta \left( \sum_{j=1}^n w_j x_j - u \right), j = 1, 2, \dots, n \quad (2.1)$$

Neste cálculo,  $\theta(\cdot)$  é a unidade *step function* representada por  $u$ , dada a soma recebida  $h$ , resultado da multiplicação do peso da sinapse  $w_j$  associado ao *input*  $x_j$ . O valor do *output*  $y$  será 1 caso o resultado da unidade seja positivo, em contrapartida, para resultados negativos o valor de  $y$  será 0.

Entretanto, para que uma ANN possa realizar um aprendizado de máquina e reconhecer padrões, é necessário executar o treinamento da rede. Neste processo, a divisão da base de dados a ser estudada é de suma importância e deve ser dividida em treino e teste, de modo que os dados de teste não sejam conhecidos pelo algoritmo durante o treinamento, evitando resultados tendenciosos. Para isto, o cálculo aplicado inicialmente ocorre de forma análoga à

<sup>5</sup> Em suma, o que configura o movimento *big data* é a capacidade de armazenamento e processamento de dados em alto volume, variedade, velocidade e veracidade, os conhecidos 4Vs (IBM, 2020).

Equação 2.1. Deste modo, a Figura 11 exemplifica a estrutura de uma ANN *feed-forward*<sup>6</sup> de uma camada.

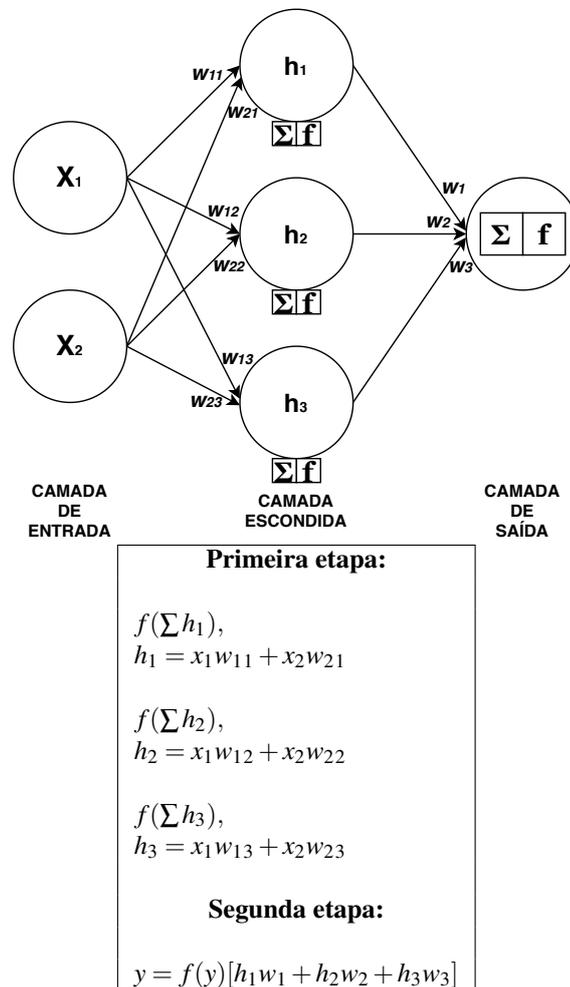


Figura 11 – Arquitetura de uma rede neural *feed-forward* com uma camada escondida  
 Fonte: Elaboração própria.

A primeira etapa representa o cálculo da camada de entrada para a camada escondida. O  $x$  é a unidade *input* da camada de entrada, o  $w$  é o peso da ligação entre camadas, o  $h$  é o valor de cada camada escondida e  $f$  representa as devidas funções de ativação. Vale destacar que diferentes funções de ativação podem ser escolhidas conforme as características de cada rede. Feito isto, a segunda etapa apresenta o resultado final  $y$  da camada de saída, que representa a resposta da rede.

Com a resposta da rede, é possível prosseguir com o treinamento. Primeiramente, é comparado o valor real presente na base de dados de treinamento com o previsto após os cálculos realizados, calculando a taxa de erro. Uma das formas mais comuns e amplamente utilizadas para cálculo do erro é o erro quadrático médio (em inglês, *Mean Square Error* - MSE) (MONTGOMERY; JENNINGS; KULAHCI, 2008).

<sup>6</sup> As redes *feed-forward* não possuem *loops*, ou seja, retornos de retroalimentação em suas conexões, diferentemente das redes recorrentes (JAIN; MAO; MOHIUDDIN, 1996)

A partir do cálculo do erro de previsão, é utilizado o algoritmo *backpropagation* (JAIN; MAO; MOHIUDDIN, 1996) para atualizar os pesos da rede. Aplicando-se este conceito, a atualização dos pesos é baseada em novo processo de cálculo, considerando o “delta” ( $\Delta$ ) para cálculo da variação a ser empregada em cada peso  $w_{ij}$  com base na derivada do erro até encontrar os novos pesos para assim repetir todo o cálculo citado anteriormente. Cada processo completo deste cálculo representa um treinamento da rede, chamado *epoch* (época).

Um dos mais importantes conceitos de treinamento do algoritmo é a descida do gradiente. O objetivo deste processo é encontrar o conjunto ideal de pesos que represente o mínimo global, Figura 12. Esta é uma das formas de finalizar o treinamento da rede, evitando que mínimos locais prejudiquem o desempenho do algoritmo.

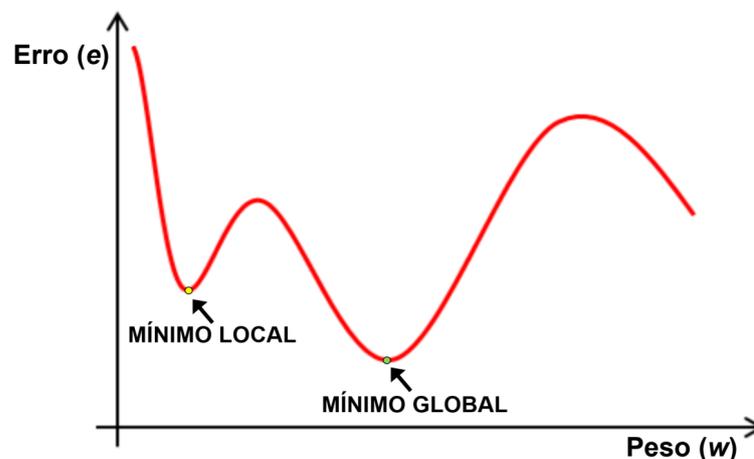


Figura 12 – Conceito de descida do gradiente  
Fonte: Elaboração própria.

Tradicionalmente, ANN possuem conexões unidirecionais, as chamadas *feed-forward*, como exemplificadas nesta seção chamadas. Mas também, existem redes neurais com capacidade de passar informações em vários sentidos se retroalimentando por meio de *loops*, como será visto a seguir.

#### 2.4.1 Redes Neurais Recorrentes e Redes Long-Short Term Memory

Ao inferir sobre determinada situação, o cérebro humano recorre à memória retida pré existente sobre aquele determinado contexto. Não diferente disto, uma rede neural também necessita destas habilidades de memória. Como as ANN não possuem esta habilidade, foram criadas as redes neurais recorrentes (em inglês, *Recurrent Neural Networks* - RNN) para resolver este problema (OLAH, 2015).

A Figura 13 ilustra o funcionamento básico de uma RNN. Nesta representação, a informação proveniente de um *output*  $x_t$  é recebida pela camada A, onde é processada e transportada para próxima camada,  $h_t$ . Entretanto, como pode ser observado, existe também uma realimentação na própria camada A. Ou seja, a informação processada também é mantida na própria

camada por meio de um ciclo chamado *loop*, permitindo que a informação persista em memória de curto prazo (OLAH, 2015). Conforme a quantidade de *loops* são definidos, réplicas dos neurônios da camada oculta são criadas formando múltiplas camadas de uma ANN padrão. Este desdobramento da RNN é mostrado na Figura 14.

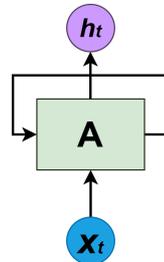


Figura 13 – Representação de uma rede neural recorrente com *loop*

Fonte: Adaptada de (OLAH, 2015).

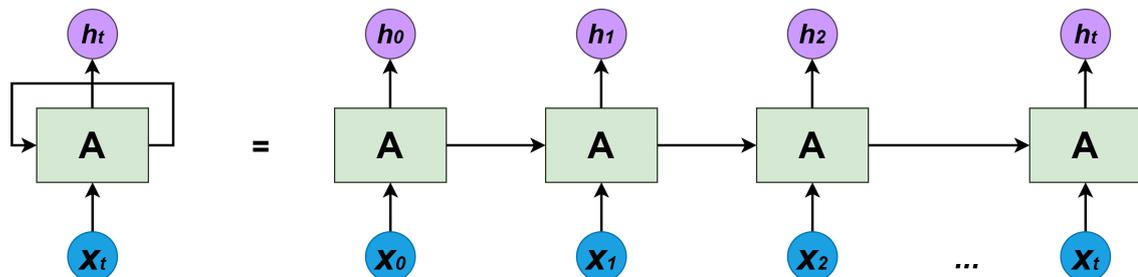


Figura 14 – Desdobramento de uma rede neural recorrente

Fonte: Adaptada de (OLAH, 2015).

Entretanto, devido ao fato das RNNs possuírem certa limitação referente à retenção de informação, problemas mais complexos que apresentavam *gaps* significativos entre a resposta a ser dada e o momento em que a informação relevante foi mantida, tornaram-se um desafio. Conforme o *gap* crescia, a RNN se tornava incapaz de aprender e reportar a resposta requerida (HOCHREITER; SCHMIDHUBER, 1997; OLAH, 2015).

Como as RNNs sofriam com o processamento de uma grande quantidade de dados, os erros tendiam a explodir ou desaparecer com uma memória de curto prazo, causando o efeito *gradient vanishing problem* (HOCHREITER; SCHMIDHUBER, 1997). Assim, os autores Hochreiter e Schmidhuber (1997) desenvolveram uma nova arquitetura recorrente, a rede Long Short-Term Memory, com gradiente apropriado que foi capaz de lidar com o retorno do erro, possuindo memória de longo prazo e capacidade de lidar com intervalos de tempo acima de 1000 etapas, mesmo em casos de ruído e sequências incompreensíveis. Além disso, a nova arquitetura utilizada impôs um fluxo constante de erro, tratando o problema do *gradient vanishing* entre as etapas (HOCHREITER; SCHMIDHUBER, 1997). Estes fatores tornaram a LSTM uma das redes de DL mais utilizadas atualmente.

Tradicionalmente, a RNN padrão possui uma estrutura simplificada, dotada normalmente de uma função de ativação *tanh*. Por outro lado, a rede LSTM possui uma complexa

arquitetura formada pelas chamadas células de memória. Desde a primeira LSTM proposta, sua estrutura inicial sofreu diversas modificações e atualmente, uma das estruturas mais difundidas é composta por 3 unidades chamadas de portões, os *gates*, sendo o *input gate*, *output gate* e *forget gate* (GREFF *et al.*, 2016).

Os *gates* são as estruturas capazes de regular a informação, isto é, remover, adicionar, e reter os dados. A representação da célula de memória LSTM é mostrada na Figura 15, indicando todo o processamento da informação. Como poder ser observado, Cada *gate* é composto por uma função de ativação *sigmoid*<sup>7</sup> representada na figura pela letra *S*. Os aspectos técnicos do funcionamento desta LSTM pode ser visto no Apêndice A.

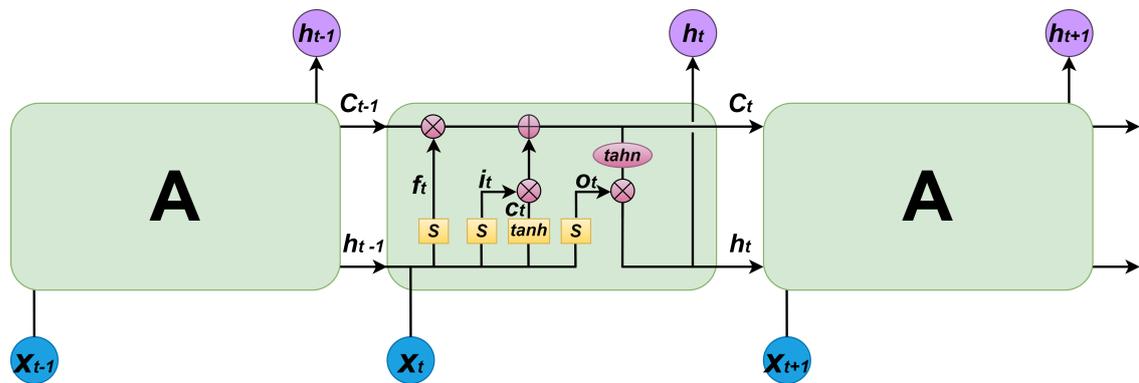


Figura 15 – Rede *Long short-term memory*  
 Fonte: Adaptada de (GREFF *et al.*, 2016; OLAH, 2015).

Um importante trabalho utilizando LSTM para a construção de um TS *intraday* foi proposto por Nelson, Pereira e Oliveira (2017). O modelo desenvolvido pelos autores utilizou como base de dados ações do índice Bovespa granulada em *candles* de 15 minutos. Por sua vez, os TI utilizados foram gerados a partir da biblioteca TA-Lib<sup>8</sup>. Na fase de treinamento foi utilizada a técnica *dropout*, importante ferramenta que ajuda a evitar *overfitting* da rede. Para avaliação do modelo, diversas métricas foram utilizadas e comparadas com modelos tradicionais de ML, inclusive a técnica B&H. Assim, os resultados demonstraram que o modelo proposto alcançou melhor performance e maior rentabilidade frente aos demais considerados. Embora o modelo compreenda um sistema simples de avaliação financeira, com ausência de elementos de gerenciamento de risco das operações, é apontado como futuras melhorias abordar *trading strategies* mais realistas.

Outros estudos têm apresentado resultados relevantes à área, como Si *et al.* (2017) que utilizaram com sucesso LSTM para auxiliar na tomada de decisão de um algoritmo autônomo de previsão. Os autores propuseram o modelo MODRL para tomada de decisão autônoma. O TS desenvolvido foi aplicado em um conjunto de dados de janeiro de 2016 a junho de 2017 em três índices de alta liquidez da China, otimizando o risco-retorno das operações. Também foi

<sup>7</sup> A função de ativação *sigmoid* é uma das mais utilizadas para ANNs, também conhecida como *logistic function* (JAIN; MAO; MOHIUDDIN, 1996).

<sup>8</sup> <http://ta-lib.org>

utilizado camadas *dropout* para evitar *overfitting* na fase de treinamento. Os resultados experimentais demonstraram que o modelo de proposto pelos autores reportou melhores resultados quando comparados a técnica B&H (SI *et al.*, 2017). Em adição, (JIA *et al.*, 2019; TROIANO; VILLA; LOIA, 2018) têm concentrado o uso de indicadores técnicos ao LSTM com objetivo de aperfeiçoar os resultados. Ainda no mercado da China, Jia *et al.* (2019) estudaram seis diferentes séries de ações pelo período de 2005 a 2017 compiladas em candles diários e diferentes TIs para minimizar ruídos do mercado. Com a construção do TS aplicando LSTM para previsão, os autores alcançaram resultados que puderam revelar a importância do método proposto.

Finalizando, o ilustre trabalho realizado por Tversky e Kahneman (1974), que rendeu a Daniel Kahneman o prêmio Nobel de Economia em 2002, comprova que pessoas sob situações de risco e incertezas tendem a tomar decisões equivocadas. Além disto, este comportamento é apontado como um dos principais motivos da alta taxa de mortalidade de pessoas físicas em operações de *daytrade* na bolsa de valores brasileira (CHAGUE; DE-LOSSO; GIOVANNETTI, 2019).

Por isto, o presente trabalho busca fornecer um modelo de negociação automatizado acessível a pessoas físicas como alternativa ao problema encontrado na literatura e no mercado real, eliminando o fator psicológico para a tomada de decisão. Além disso, o sistema proposto também pode ser considerado como elemento integrante de portfólio de investimentos e fundos de investimentos quantitativos. Assim, diante da relevância dos resultados alcançados e metodologia empregada em Nelson, Pereira e Oliveira (2017), seu trabalho foi utilizado como base para a construção do TS proposto apresentado nas seções seguintes.

## 3 Método de Pesquisa

Com base no objetivo geral desta dissertação visto na Seção 1.3, o presente capítulo tem a proposta de apresentar a metodologia utilizada na pesquisa e o modelo proposto. Para isto, este item foi dividido primeiramente em metodologia de pesquisa e as demais seções abordam o modelo desenvolvido.

### 3.1 Metodologia de Pesquisa

Com base no propósito prático deste trabalho, a natureza da pesquisa é aplicada com objetivo explicativo e abordagem quantitativa por meio do método de modelagem e simulação. Esta classificação de pesquisa teve embasamento científico nos tipos de pesquisas utilizadas em engenharia de produção.

Assim, a natureza é aplicada por se tratar de um problema real que busca soluções práticas (MARCONI; LAKATOS, 2003). No que se refere aos objetivos explicativos e a abordagem quantitativa, essa categorização justifica-se pelo fato de investigar uma relação causal quantitativa entre as variáveis estudadas (BERTRAND; FRANSOO, 2002; MARTINS; MELLO; TURRIONI, 2014). Por sua vez, a escolha do método de pesquisa modelagem e simulação, foi devido ao modelo proposto, que utiliza técnicas matemáticas para modelagem do ambiente em estudo e ferramentas computacionais para simular este ambiente (BERTRAND; FRANSOO, 2002).

Um dos primeiros modelos que se tem registro na literatura sobre métodos de modelagem e simulação é a proposta apresentada por Mitroff *et al.* (1974). A estrutura elaborada pelos autores abrange uma fase inicial de compreensão do problema, por meio de um modelo conceitual. Em seguida é feita a modelagem em um sistema computacional com o objetivo de encontrar a solução do problema. Nesta fase é feita a validação do modelo e se necessário devidos ajustes são aplicados. Por fim, com as soluções encontradas, o modelo é implementado em ambiente simulado e real.

### 3.2 Modelo Conceitual

Seguindo a mesma linha de Mitroff *et al.* (1974), utilizou-se neste trabalho o modelo de Cavalcante *et al.* (2016), por retratar o ambiente de estudo em questão. Os autores citados propuseram um guia prático para construção de um TS inteligente em seis etapas, já a versão deste trabalho propõe oito fases para desenvolvimento do modelo. O diferencial do modelo proposto diz respeito a avaliação financeira comparando dois cenários, o *backtest*, onde as operações

são executadas exatamente nos pontos definidos e a conta real, onde há presença de *slippage*<sup>1</sup>, possibilitando responder as questões de pesquisa levantadas na Seção 1.1.

Os estágios seguidos para a construção do modelo são ilustradas na Figura 16. Conforme observado, o primeiro passo apresenta a realização de todo o tratamento inicial dos dados e definição dos *inputs* e *outputs* do modelo. Feito isto, na segunda fase foi preciso definir os algoritmos utilizados para a previsão e treinamento do modelo. Com isto, na terceira fase é possível parametrizar o algoritmo para iniciar o treino e sua validação. Nesta fase 3, ocorre o aprendizado das características do mercado a partir dos dados históricos e os *inputs* inseridos.

Com o treino finalizado, são definidas as métricas para o teste e com isto a avaliação da acurácia do modelo, ambas na fase 4. É importante destacar que grande parte da literatura existente tem apresentado métodos preditivos até o ponto apresentado nesta fase 4. Poucos estudos tem ido além, propondo sistemas de negociação ou aplicação de técnicas de negociação que permitem a real avaliação financeira dos modelos propostos (VANSTONE; FINNIE, 2010; TEIXEIRA; OLIVEIRA, 2010; CAVALCANTE *et al.*, 2016). Por este motivo, as próximas fases, 5-8, caracterizam a maior contribuição deste trabalho.

Uma vez que o sucesso de um sistema inteligente depende da definição das regras de negociação, chamadas de *trading strategy*, na fase 5 foram definidas posições de entradas com base no valor da previsão recebida do modelo pelo *output*. Além disto, esta estratégia também caracteriza o gerenciamento de risco das operações executadas – explicado detalhadamente na seção de estratégia do modelo.

Depois de definido o *trading strategy*, a fase 6 apresenta o teste simulado do algoritmo por meio do *backtesting*, permitindo verificar se a estratégia aliada a previsão do modelo exibe boa performance. Por outro lado, na fase 7 é realizada a avaliação do modelo em ambiente real, a fim de mensurar o *slippage* apresentado. Finalmente, na fase 8 é realizada a avaliação financeira a partir da performance do modelo (CAVALCANTE *et al.*, 2016). Esta é uma das fases mais importantes, pois fornece informações para demonstrar se o modelo pode produzir rentabilidade no mundo real.

Feito isto, a estrutura do sistema de negociação automatizado (em inglês, *Automated Trading System - ATS*) é apresentada na Figura 17. O algoritmo preditor escolhido foi o LSTM devido sua relevância e performance. Assim, busca-se apresentar uma alternativa ao estudo realizado por Nelson, Pereira e Oliveira (2017) que utilizaram ativos menos líquidos, ações, em comparação aos índices de ações, que possuem maior volume financeiro e de negociações.

Simplificadamente, o modelo preditor LSTM recebe os dados alimentados na camada de entrada e realiza o processamento gerando a previsão na camada de saída. Com esta previsão, o sistema de negociação é capaz de realizar uma classificação conforme parâmetros já configurados. Caso a classe gerada seja para “comprar” ou “vender” a operação é executada e realizada a avaliação da rentabilidade. O detalhamento das etapas é apresentado a seguir.

<sup>1</sup> Diferença entre o preço esperado, em que definiu-se a entrada e a saída para uma operação, e o preço real em que a operação foi executada (CHEN, 2020)

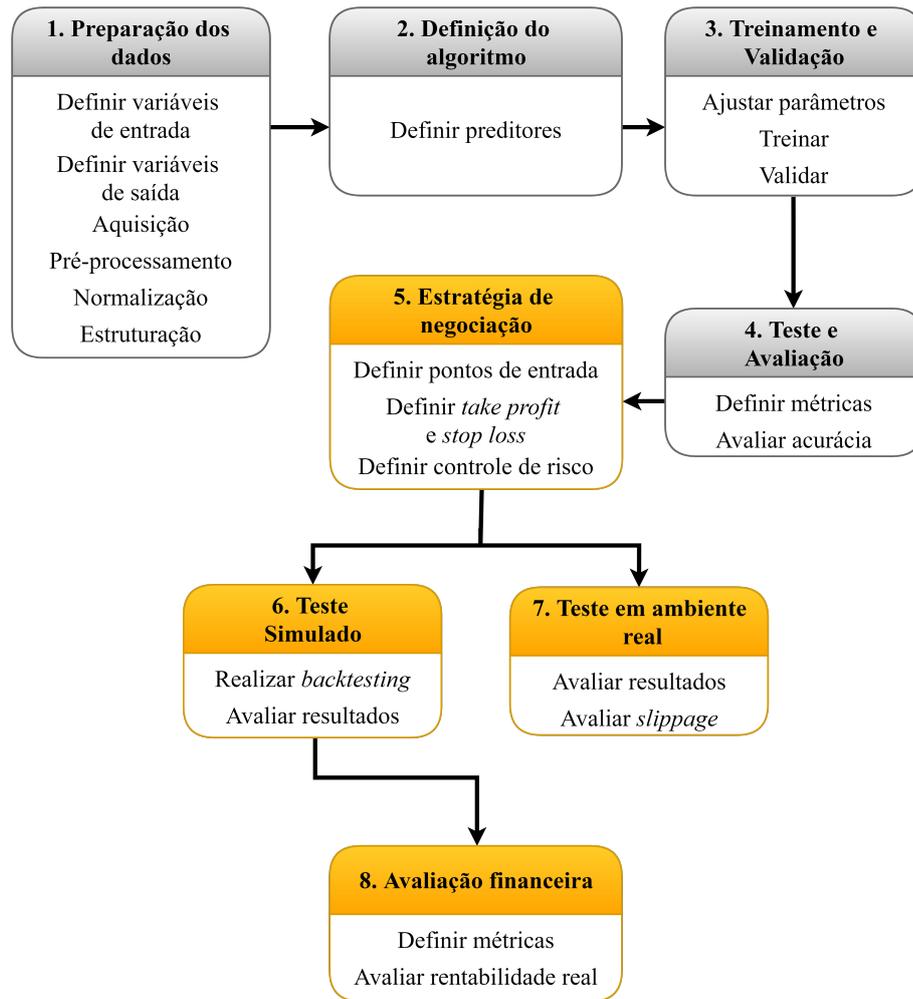


Figura 16 – Fases do modelo conceitual  
 Fonte: Adaptada de Cavalcante *et al.* (2016).

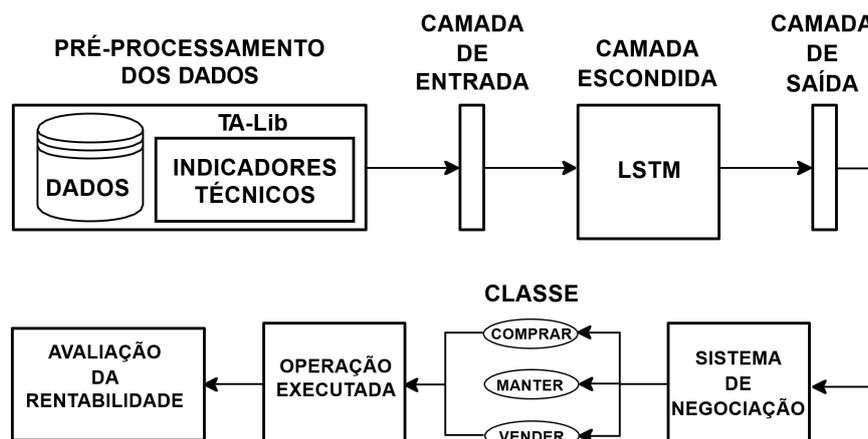


Figura 17 – Estrutura do modelo conceitual  
 Fonte: Elaboração própria.

### 3.3 Base de Dados e Preparação

Referente ao sistema do modelo proposto, primeiramente, esta fase é composta pela aquisição dos dados do mini índice Bovespa (WIN). A estrutura referente aos dados históricos utilizados correspondem ao formato de barras, chamados de *candles*. A composição de cada *candle* foi granulada em 5 minutos dotada dos preços de abertura, máxima, mínima, fechamento e volume financeiro (em inglês, *open, high, low, close, volume* - OHLCV).

A base OHLCV corresponde ao período de janeiro de 2016 a dezembro de 2018, totalizando 79.867 observações das quais foram separadas em 85% para treino e 15% para teste de performance do modelo preditor. A etapa de avaliação de rentabilidade do modelo treinado utilizando *backtesting* foi realizada em dois períodos distintos, 2015 e 2019.

O primeiro modelo em *backtesting*, o protótipo mostrado na Seção 3.6.1, foi executado em 2019, ano caracterizado como *bull market*, altista. Com os resultados obtidos, o modelo passou por um processo de melhoria dos parâmetros de negociação e também do método de abordagem do *backtesting*, considerando o movimento dinâmico desde a abertura até o fechamento de cada *candle* de cinco minutos, o que trouxe maior confiabilidade aos resultados finais.

Identificou-se também a necessidade de realizar o *backtesting* em uma situação adversa de mercado, um *bear market*. Assim, além de avaliar novamente o período de 2019 utilizando o modelo otimizado e *backtesting* melhorado, foi analisado 2015, ano de baixa do Ibovespa. Em contrapartida, foi desconsiderado o *backtesting* no período de 2015 para o protótipo devido sua menor adequação a realidade de mercado. Por fim, em 2020 foi utilizado um período para mensurar o *slippage* em conta real referente ao modelo otimizado. Esta abordagem de divisão dos dados, bem como o período de avaliação dos modelos citados é ilustrada na Figura 18.

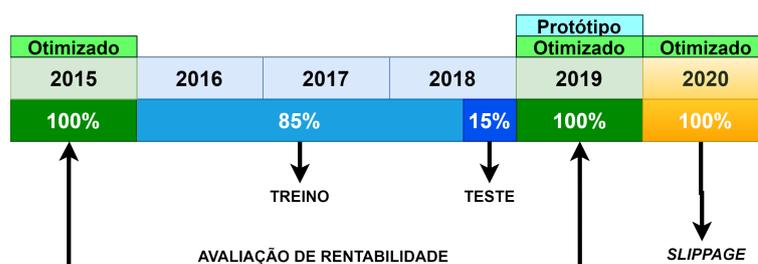


Figura 18 – Abordagem de divisão dos dados

Fonte: Elaboração própria.

Além dos dados OHLCV, foram utilizados 108 TIs como variáveis de entrada, comumente utilizados em TA. Os indicadores podem ser obtidos por meio da plataforma de negociação ou pela ferramenta chamada TA-Lib<sup>2</sup>. Neste caso, foi escolhida a segunda opção devido ao alto custo computacional envolvido na primeira. Assim, após a aquisição, foi realizada a devida normalização de todos os dados OHLCV e TIs por meio de sua padronização, Equação 3.1, para poder utilizá-los na previsão de forma mais limpa, ajudando na suavização de ruídos naturais

<sup>2</sup> <http://ta-lib.org>

de séries financeiras. O valor  $z$  de cada ponto da série é dado pela amostra  $x$  considerando a média  $\mu$  e o desvio padrão  $\sigma$  da série.

$$z = \frac{x - \mu}{\sigma} \quad (3.1)$$

### 3.4 Módulo Preditor

O algoritmo preditor foi baseado na rede neural LSTM, de codificação semelhante àquela desenvolvida no estudo preliminar apresentado em Silva, Li e Pamplona (2020), utilizando a biblioteca *TensorFlow*<sup>3</sup> e interface *Keras*<sup>4</sup> para a linguagem Python. Entretanto, este estudo foi aprimorado onde os resultados da segunda fase são apresentados nesta dissertação. Por sua vez, a utilização de um código aberto, *open source*, permite realizar toda a customização do modelo conforme os parâmetros requeridos, tornando possível este aprimoramento com a nova programação.

Deste modo, a arquitetura do modelo desenvolvido, resultado de testes experimentais, é composta de 4 camadas LSTM intercaladas com 4 camadas *dropout* e finalizado com 1 camada *fully connected* (FC). A Figura 19 exemplifica o fluxo dos dados da camada de entrada para camada oculta, onde  $n$  representa a quantidade de neurônios utilizados e  $r$  a taxa *dropout*. Assim, os dados históricos são recebidos por blocos formados pelos 20 *candles* anteriores. Resultando em uma matriz  $20 \times 113$ , pois cada um dos 20 dados possui seu respectivo OHLCV, 5 itens, e TI, 108 itens. Por fim, após o processamento na camada oculta, o valor previsto é apresentado na camada de saída do modelo.

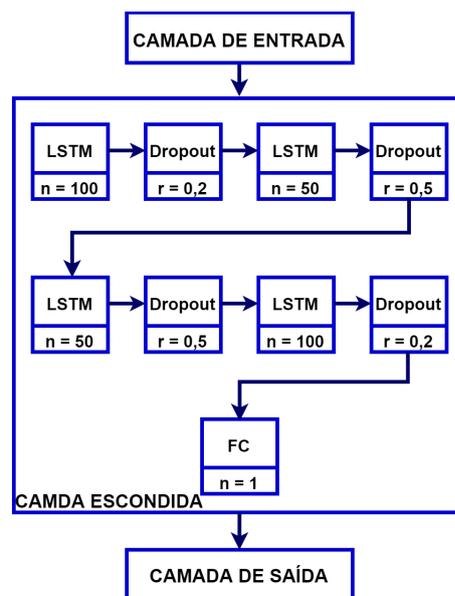


Figura 19 – Arquitetura do modelo LSTM

Fonte: Elaboração própria.

<sup>3</sup> <https://www.tensorflow.org>

<sup>4</sup> <https://keras.io>

### 3.5 Métricas de Avaliação do Modelo

As métricas de avaliação do modelo são usadas para mensurar a performance do algoritmo preditor após a fase de teste. Neste estudo foram utilizadas as métricas de acurácia, precisão, *recall* e *F-measure*, Equação 3.2 - 3.5, respectivamente. Como foram aplicadas com base em cada *trade*, caracterizam um importante indicador de desempenho financeiro.

$$A = \frac{t_p + t_n}{t_p + f_p + t_n + f_n} \quad (3.2)$$

$$P = \frac{t_p}{t_p + f_p} \quad (3.3)$$

$$R = \frac{t_p}{t_p + f_n} \quad (3.4)$$

$$F = 2 \frac{P * R}{P + R} \quad (3.5)$$

onde  $t_p$ ,  $t_n$ ,  $f_p$ , and  $f_n$  representam o verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo, nesta ordem.

Valores “verdadeiros” e “falsos” são obtidos por meio da previsão correta e incorreta, respectivamente. Por outro lado, classes positivas referem-se a ordens para “comprar” e negativas para “vender”. Enquanto a acurácia permite mensurar a taxa de acerto sobre o total previsto, a precisão restringe-se à taxa de acertos de cada classe, conforme mostrado na Equação 3.3 referente à classe positiva, sendo análoga para a classe negativa.

Embora estas sejam as métricas mais utilizadas na literatura, as últimas duas também foram consideradas para efeito de comparação. A partir do *recall*, que mensura quão frequentemente o preditor classifica corretamente, é possível calcular o *F-measure*, o qual pondera a precisão com o *recall* para proporcionar uma medida singular que indique a qualidade geral do modelo.

### 3.6 Sistema de Negociação Automatizado

O TS aplicado neste trabalho será explicado detalhadamente nesta seção, bem como as melhorias realizadas a partir do primeiro protótipo, mostrado em [Silva, Li e Pamplona \(2020\)](#). Primeiramente, a base para a construção do gerenciamento de risco (em inglês, *Risk Management* - RM) envolvem regras de *trading strategy*, como alvos para *stop loss* (SL) e *take profit* (TP).

Além disso, o RM também considera variações mínimas necessárias referente ao horizonte de previsão para abrir uma posição de “compra” ou “venda”, bem como as especificações para encerrar uma posição. Finalmente, é realizada a avaliação da rentabilidade, considerando todos os custos de transação inerentes.

Para possibilitar que o ATS fosse executado, tanto em ambiente simulado para *backtesting*, Figura 20, quanto em conta real, Figura 21, foi utilizada uma plataforma própria para execução de negociações com algoritmos automatizados, MetaTrader 5<sup>5</sup>. Além disso, para que os sistemas se comunicassem de forma autônoma, foi utilizada uma comunicação via “*socket*” para conexão da linguagens Python para MQL5 da plataforma MT5. Com isto, o *backtesting* realizado compreende três etapas distintas, previsões, gerenciamento de risco e avaliação financeira. Por outro lado, o teste em conta real abrange as previsões e avaliação do *slippage*. Por fim, é importante destacar que todo o processamento realizado dentro da plataforma MT5 é em linguagem MQL5.

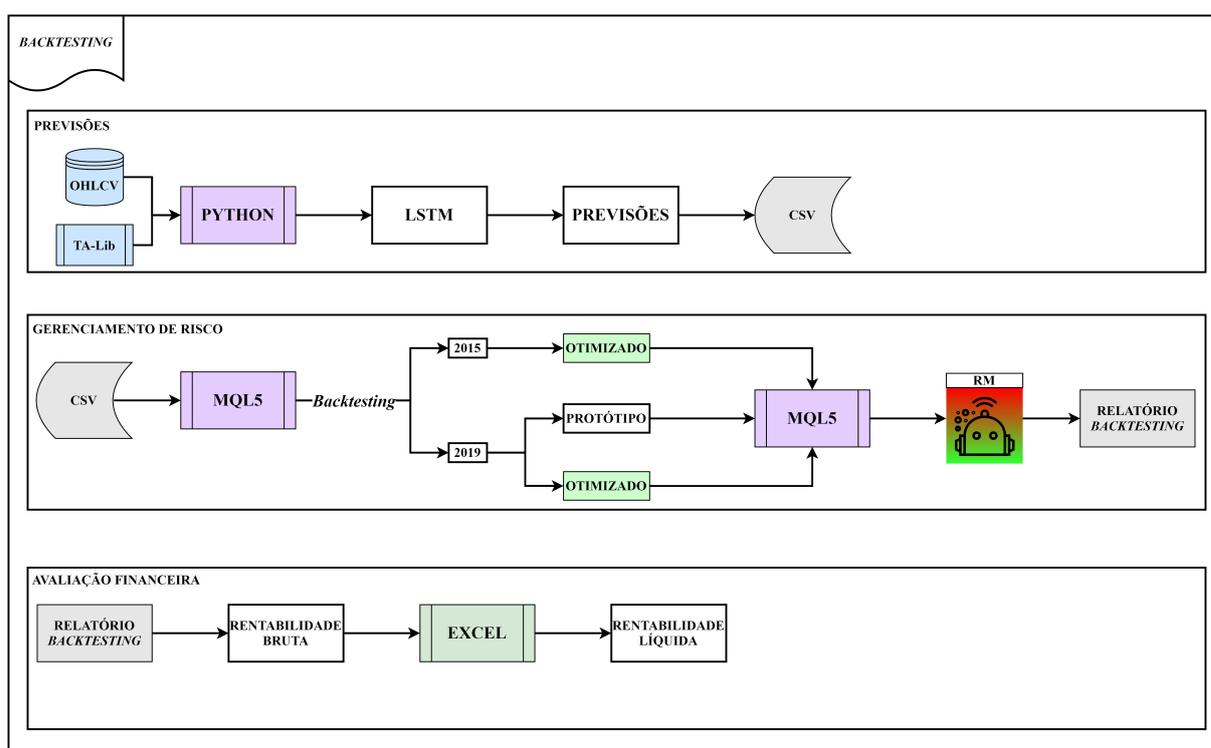


Figura 20 – Etapas do ATS em ambiente simulado (*backtesting*)

Fonte: Elaboração própria.

Conforme observado na Figura 20, a primeira etapa consiste em executar o modelo em Python com base nas variáveis de entrada “OHLCV” e TIs para gerar as previsões utilizando o modelo LSTM que por sua vez são armazenadas em um arquivo único “csv”. Na segunda etapa, este arquivo comunica-se com o MQL5 no módulo de *backtesting*, onde é selecionado o período desejado, sendo que em 2019 foi realizado um *backtesting* para o protótipo e um para o modelo otimizado e em 2015 somente para o modelo otimizado. Após a seleção do período desejado, o sistema em MQL5 inicia o processo de *backtesting* executando as estratégias de RM. Após a finalização, é gerado um relatório de todas as operações realizadas. Finalmente, os dados pertencentes ao relatório gerado são tratados a fim de encontrar a rentabilidade bruta

<sup>5</sup> <https://www.metatrader5.com/>

de cada operação. Estes dados por sua vez são exportados para um arquivo Excel<sup>®</sup> onde as fórmulas para cálculo manual da rentabilidade líquida.

Por outro lado, o teste em conta real não necessita de exportação da base de dados, uma vez que os dados são coletados em tempo real na MT5. Entretanto, a comunicação via *socket* é necessária para que o LSTM em Python gere a previsão e, novamente via *socket*, a retorne ao MQL5 que executa o RM, tudo de forma automática. É importante destacar que a comunicação entre os sistemas gera uma latência mínima, em torno de 3 segundos entre o fechamento do *candle* e ordem gerada na MT5. Com os resultados das operações é calculado o *slippage* que será utilizado no teste paramétrico para mensuração de seu impacto no mercado real.

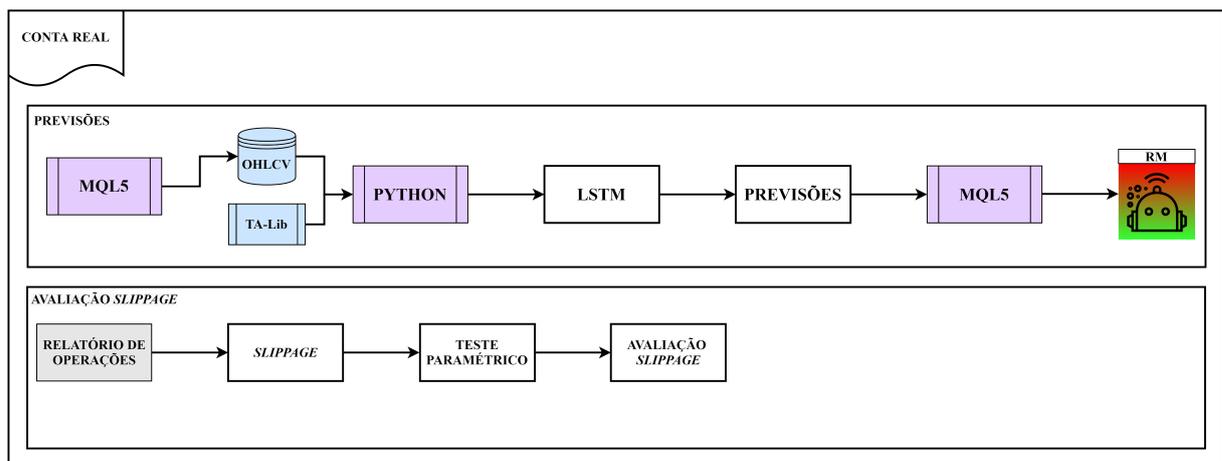


Figura 21 – Etapas do ATS em ambiente real

Fonte: Elaboração própria.

Referente à fase de RM, a importância do SL é crucial para evitar um alto *drawdown* (rebaixamento de saldo), muito útil em casos de movimentos atípicos no mercado causados por fatores macroeconômicos, como as chamadas *breaking news* (notícias relâmpago) e catástrofes. Por outro lado, em situações em que ocorrem *circuit breakers* ou o ativo entre em leilão, o que são mais raros de acontecer, infelizmente se atingir o ponto de SL, o ativo só poderá ser executado no retorno do mercado no valor que estiver.

Entretanto, como uma das características destes ativos é a alavancagem, as corretoras costumam reduzir a alavancagem em momentos críticos como os citados, a fim de garantir a liquidez do mercado. Por exemplo, no período em que ocorreu alta volatilidade no mercado com presença de *circuit breakers*, tendo início em 9 de março de 2020, os WINs que antes necessitam de margens por volta de vinte reais por contrato, passaram a ser negociados por dois mil reais cada.

Desconsiderando os cenários atípicos citados, que são historicamente raros, uma das maiores contribuições de se usar SL é evitar o fenômeno chamado “quebrar a conta”. Este conceito seria similar ao exemplificado, porém considerando movimentos diários de tendência forte do mercado contra uma posição aberta. Constantemente têm sido reportados casos em que robôs investidores, além de não serem lucrativos, consomem todo o saldo em conta do investidor

em um único dia, apontando a falta de uso de SL como uma das principais razões.

Por outro lado, o uso de TP também evita situações adversas. Como a volatilidade de índices de ações são altas em um único dia, o uso deste mecanismo ajuda a realizar o lucro da operação antes que uma posição vencedora se torne perdedora. Assim, a importância do uso destas duas estratégias básicas, parecem ser fundamentais para garantir que o modelo proposto seja capaz de obter rentabilidade real, como citado anteriormente.

### 3.6.1 Protótipo

Uma vez que os valores do WIN são representados por pontos de índice, com base em testes empíricos realizados foram considerados 200 pontos para SL e 400 para TP inicialmente. Em outras palavras, ao executar uma operação, automaticamente os alvos de SL e TP são acionados. Se a direção do ativo for contra a classe executada, a posição é automaticamente encerrada se atingir 200 pontos de WIN, marcando o SL. De forma análoga, se a direção do WIN for à favor da previsão executada, ao atingir 400 pontos de WIN, a operação também é automaticamente encerrada, contabilizando o TP.

Cinco *setups* diferentes utilizando o preditor LSTM foram construídos e avaliados neste trabalho. O objetivo foi demonstrar a melhora de resultados conforme estratégias mais sofisticadas são incorporadas no modelo. Deste modo, os dois primeiros modelos comparam o valor do horizonte de previsão com o valor *candle* fechado. Caso o horizonte seja superior ao último preço de fechamento, um sinal de compra é gerado. Em contrapartida, se o valor do horizonte de previsão for menor que o preço de fechamento, um sinal de venda é dado. A diferença entre os dois primeiros modelos encontra-se na execução das operações.

Por sua vez, o RM foi aplicado nos três últimos modelos. Basicamente, o RM é baseado no horizonte de previsão em relação ao *candle* fechado, proporcionando três classes distintas: (a) compra (*buy*), se a previsão for superior a 0,2%, Equação 3.6; (b) venda (*sell*), se for inferior a 0,2%, Equação 3.7; e (c) manter (*hold*), para valores intermediários onde a variação mínima de 0,2% não ocorreu. É importante destacar que esta variação mínima aplicada foi encontrada com base em testes empíricos e sua utilização objetiva minimizar falsos positivos.

$$P_{t+3} - P_t \geq 0.2\%P_t \quad (3.6)$$

$$P_{t+3} - P_t \leq -0.2\%P_t \quad (3.7)$$

onde  $P_{t+3}$  é o horizonte de previsão e  $P_t$  e o preço de fechamento do *candle*.

A escolha do horizonte de previsão  $P_{t+3}$  assemelha-se de Nelson, Pereira e Oliveira (2017), com a diferença de que a granularidade utilizada pelos autores foi de 15 minutos e neste trabalho foi de 5 minutos, mas que quando somados os 3 *candles*, resultam no mesmo horizonte de 15 minutos. Assim, os cinco modelos desenvolvidos são:

- **LSTM-N** utiliza uma abordagem ingênua baseada somente na previsão, ou seja, abre uma posição considerando o atual preço de mercado e encerra três *candles* à frente por meio de ordem a mercado. A Figura 22 mostra a estratégia LSTM-N.

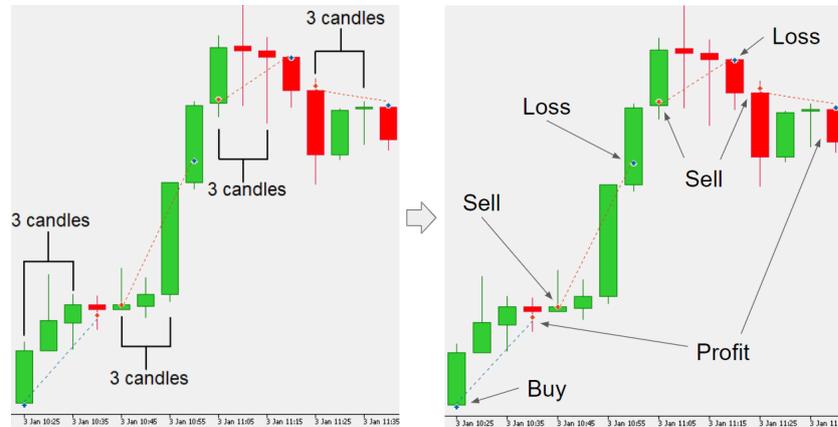


Figura 22 – Estratégia LSTM-N

Fonte: Elaboração própria.

- **LSTM-PH** é totalmente baseado no horizonte de previsão e utiliza o próprio valor previsto como SL e TP. Assim, se o sinal for compra, o modelo irá considerar o valor da previsão positivo como TP e negativo como SL. Para sinal de venda o oposto é verdadeiro. Esta estratégia pode ser vista na Figura 23.

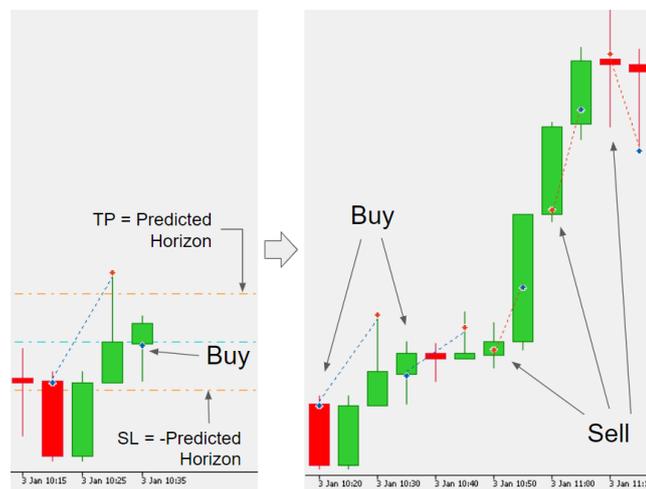


Figura 23 – Estratégia LSTM-PH

Fonte: Elaboração própria.

- **LSTM-RMO** utiliza a estratégia de RM e considera os alvos para as operações executadas como 400 TP e 200 SL, ilustrada na Figura 24.
- **LSTM-RMOD** utiliza a estratégia LSTM-RMO além de um RM diário, isto é, em caso de um acúmulo de pontos diários de 1.000 TP ou 400 SL, o algoritmo desliga automaticamente e retorna a operar somente no próximo dia.



Figura 24 – Estratégia LSTM-RMO

Fonte: Elaboração própria.

- **LSTM-RMODV** é baseado em um importante TI, amplamente utilizado por grandes investidores, chamados de *big players* ou *big sharks*. Esta análise é o Volume de Preço Médio Ponderado (em inglês, *Volume Weighted Average Price - VWAP*). Deste modo, se o sinal *buy* estiver abaixo do VWAP, nenhuma operação é realizada, mas se o sinal *buy* estiver acima dele, a operação é normalmente executada. No mesmo sentido, se o sinal *sell* estiver acima do VWAP, nenhuma operação é realizada, mas se o sinal *sell* estiver abaixo dele, a operação é normalmente executada. Assim, o LSTM-RMODV é demonstrado na Figura 25.

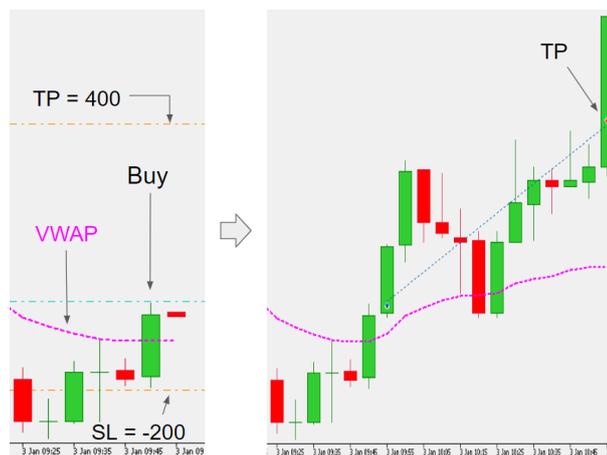


Figura 25 – Estratégia LSTM-RMODV

Fonte: Elaboração própria.

O indicador VWAP não consta na biblioteca TA-Lib e foi adicionado com o intuito de medir o impacto financeiro de sua aplicação sobre a estratégia LSTM-RMOD. Isto porque, os *traders* acreditam que se o preço de mercado estiver acima do VWAP, os *big players* estão interessados em um *bull market*. Por outro lado, se o preço estiver abaixo do VWAP, há interesse em *bear market*. Sendo assim, é possível analisar se no caso em estudo a estratégia é rentável.

### 3.6.2 Otimização Dinâmica

Com base na performance apresentada pela melhor estratégia empregada, um processo de otimização foi realizado para aprimorar o protótipo desenvolvido. Para isto, foi utilizado o algoritmo otimizador contido na plataforma MetaTrader 5, que adota o método conhecido como *grid search*, uma otimização em grade. Primeiramente, foram adicionadas as novas regras de *trading strategies*, *Break-even* e *Trailing Stop*, conforme indicado no estudo preliminar para trabalhos futuros. Em seguida, foi realizada uma série de otimizações com todos seus parâmetros de funcionamento, sendo 14 itens. Além disso, foi utilizado um novo *backtest* para considerar o movimento dinâmico dos *candles*, reproduzindo de forma mais fidedigna o movimento do mercado, o que aumenta a sua confiabilidade.

Inicialmente, um intervalo de valores mínimos e máximos foram definidos de para cada um dos 14 parâmetros selecionados, Quadro 10, com exceção dos “*Holds*” e “*Hold Time*”. Cada ciclo contendo um conjunto final de parâmetros apresentados na otimização foi testado em *backtest*. Após a coleta e análise dos resultados, um novo ciclo era iniciado. Quando a taxa de melhora por ciclo com base no critério rentabilidade atingiu a marca inferior a 10% em relação ao anterior e valores otimizados dos itens começaram a persistir, foi realizada a fase dois de otimização.

Nesta nova etapa de ciclos, foram realizadas otimizações alterando menos de cinco parâmetros por vez, levando em consideração os valores do *drawdown* e *Sharpe ratio*, para buscar a melhor relação possível. Estes ciclos foram realizados até que o modelo atingisse uma taxa de melhora inferior a 0,10% em relação ao anterior, encerrando assim as otimizações. Este modelo otimizado foi chamado de Algo-LSTM, sendo mostrado no Quadro 10, onde pode ser visto seu novo conjunto de parâmetros de melhor retorno financeiro e comparado com o modelo de melhor performance apresentado na fase protótipo, o LSTM-RMODV.

Quadro 10 – Parametrização realizada

Parametrização	LSTM-RMODV	Algo-LSTM
TP	400	1.100
SL	200	250
<i>Break-even</i>	<i>False</i>	<i>True</i>
<i>Break-even</i> pro zero (pts)	-	400
SL diário	400	500
TP diário	1.000	800
<i>Break-even</i> diário (acionar)	-	600
<i>Break-even</i> diário (setar)	-	200
<i>Trailing Classico</i> ( <i>stop + step</i> )	<i>False</i>	<i>True</i>
<i>Trailing Stop</i>	-	200
<i>Trailing Step</i>	-	400
Fator classificação	0,2%	50 pts
<i>Holds</i> (limpar memória)	4	4
<i>Hold Time</i>	20	20
Horário ATS <i>in</i>	09:05	09:05
Horário ATS <i>out</i>	17:30	12:30

Fonte: Elaboração própria.

Observa-se que os novos valores de SL e TP por operação passaram a ser, 250 e 1.100, respectivamente, enquanto seus valores diários foram alterados para 500 SL e 800 TP. Isto é, ao

executar uma operação, caso o estágio inicial de pontos seja zero – nenhum ponto acumulado anteriormente – e esta operação atingir 800 pontos a favor, o *trade* é automaticamente encerrado naquele dia, onde o mesmo ocorre em caso de 500 pontos contra. Por outro lado, 1.100 TP permite que pontos negativos acumulados anteriormente possam ser recuperados, podendo inclusive atingir o TP diário com uma única operação.

Referente ao *Break-even*, uma das formas de proteger o ganho pode ser utilizando esta estratégia de diversas formas diferentes. No Algo-LSTM, o primeiro *setup* para o *Break-even* diz respeito a quantidade necessária de pontos acumulados para acionar a ferramenta, sendo assim, 400. Em outras palavras, se a operação estiver com 400 pontos a favor, mas o preço mudar de direção antes de atingir o TP e retornar para o ponto de entrada da operação, o *trade* é encerrado, evitando a ocorrência de SL. No segundo *setup*, caso o acumulado de pontos diários atingir o valor de 600, o *Break-even* diário é acionado para 200 pontos acima da entrada, neste caso, se este ponto for atingido antes de realizar o TP, o *trade* daquele dia é encerrado com 200 pontos positivos.

Por outro lado, o *Trailing Stop* é empregado para acompanhar uma operação vencedora até seu TP. Assim, se durante um *trade*, independente da quantidade diária de pontos acumuladas, a operação atingir 600 pontos, o primeiro *Trailing Stop* é acionado para a posição de 200 pontos positivos, garantindo este ganho, o que conseqüentemente já ocorreria devido a estratégia de *Break-even* diário. Entretanto, no ganho de mais 400 pontos, ou seja, 1.000 pontos acumulados, a nova proteção é avançada para 800 pontos, o que significa que o *stop* 200 não permite que o preço retorne 200 pontos da marca alcançada. Neste caso, se a operação acumular 1.100 pontos, o alvo TP é atingido, caso contrário, 800 pontos serão garantidos pelo *setup*.

Outras importantes alterações ocorreram em relação ao intervalo de tempo para *trade* e a variação mínima necessária para considerar a abertura de posição. O modelo otimizado demonstrou que operar somente até 12:30 e considerar 50 pontos de diferença entre o horizonte de previsão e o preço de fechamento do *candle* reportam melhores retornos. Por fim, os *holds* parametrizados significam que se uma operação de classe positiva ou negativa for acionada, porém o preço não atingir seu ponto de execução e a próxima previsão for *hold*, após quatro vezes repetidas consecutivamente, a memória da ordem anterior é cancelada, aguardando a nova previsão.

Vale destacar que o uso do VWAP, considerando a rentabilidade final de cada otimização, não trouxe melhores resultados ao modelo, por isto foi desconsiderado. Além disso, o termo “otimização dinâmica” significa que todas os valores parametrizados para o RM são executados durante o desenvolvimento do *trade*, e não somente após o fechamento de cada *candle* ou encerramento de cada operação, outro ponto chave na melhora dos resultados. Por fim, apesar do ATS ser para *day-trade*, podendo trabalhar tanto na compra quanto na venda, para comprovar sua performance houve testes para um *bear market*, ano de 2015, onde também reportou resultados positivos.

### 3.7 Avaliação Financeira

Uma vez que somente a alta taxa de acurácia em previsões financeiras não definem um modelo de sucesso, é apresentado as métricas necessárias para avaliar a rentabilidade. Deste modo, quando a operação é finalizada, a rentabilidade é definida pela diferença entre o preço de abertura e encerramento da operação. Conhecendo este valor, o próximo passo é calcular os custos de transação baseados nos contratos operados, indicados pela representação matemática da Equação 3.8. Finalmente, é possível aplicar a taxa de imposto de renda de 20% (RF, 2019) para encontrar o lucro líquido.

$$R = p \times 0,2 \times c \quad (3.8)$$

onde  $R$  é o resultado final,  $p$  representa os pontos acumulados, o parâmetro fator de alavancagem é 0,2 e  $c$  é o número de contratos usados.

Por sua vez, o custo de transação é obtido com base no número de contratos operados e na quantidade de operações realizadas. O custo de se operar um mini contrato Bovespa é de 25 centavos por ordem. Partindo da premissa de que ao executar uma operação, obrigatoriamente ela deverá ser encerrada, considera-se que cada operação – entrada e saída – deverá ter um custo de 50 centavos. Esta representação matemática pode ser observada na Equação 3.9.

$$C = c \times 0,50 \times q \quad (3.9)$$

onde  $C$  é o custo final dado em reais,  $c$  é o número de contratos operados, o valor por operação é representado por 0,50 e  $q$  representa a quantidade de operações realizadas.

Conforme mencionado anteriormente, o *Sharpe ratio* é amplamente utilizado, em especial como avaliação de performance de fundos de investimento (SHARPE, 1966), também podendo ser aplicada neste tipo de mercado (SYU *et al.*, 2019). Sua representação é mostrada na Equação 3.10.

$$\text{Sharpe ratio}_i = \frac{\gamma_i - \gamma_f}{\sigma_i} \quad (3.10)$$

onde  $\gamma_i$  representa o retorno esperado e  $\gamma_f$  o retorno livre de risco (*risk free*) do mercado, sendo o excesso de retorno da estratégia. O denominador  $\sigma_i$  é o desvio padrão do retorno.

Neste estudo, a taxa livre de risco considerada foi a Selic. Adicionalmente, na segunda avaliação foi considerado o *benchmark* Ibovespa como uma variante do *Sharpe ratio*, que foi chamado de *Ibov ratio*. Assim, mesmo não se tratando de um ativo livre de risco, sua comparação foi interessante devido ao grau de risco ser inferior ao ativo em questão.

## 4 Resultados experimentais

Este capítulo foi dividido em três seções. A primeira Seção 4.1, irá apresentar os resultados referente ao protótipo, a segunda Seção 4.2, o modelo otimizado Algo-LSTM e por fim a última Seção 4.3, demonstra o impacto da taxa de erro no Algo-LSTM devido ao *slippage*.

### 4.1 Resultados Experimentais do Protótipo

Os resultados provenientes dos cinco modelos desenvolvidos foram avaliados e são apresentados nesta seção. Baseado nas métricas mostradas na Seção 3.5, a Tabela 2 apresenta os resultados da classe negativa obtidos para cada estratégia criada. Esta avaliação mensura a performance do algoritmo e reporta quão bem o modelo funciona como preditor.

Com base nestes resultados, é possível inferir que o melhor modelo foi o LSTM-N, devido aos melhores valores de acurácia, precisão, e *F-measure*, uma vez que o modelo LSTM-RMODV apresentou somente o melhor *recall*. Por outro lado, ao comparar os modelos que utilizam RM, observa-se que a utilização deste mecanismo, em especial o RM diário, permite reduzir a exposição ao risco. Adicionalmente, a utilização do VWAP ajudou a evitar falsas entradas, os  $f_p$  e  $f_n$ , ressaltando o LSTM-RMODV como melhor modelo utilizando RM.

Tabela 2 – Métricas de avaliação do modelo

Modelos LSTM	Acurácia	Precisão	Recall	F-measure
LSTM-N	<b>0,504</b>	<b>0,503</b>	0,549	<b>0,525</b>
LSTM-PH	0,441	0,433	0,461	0,446
LSTM-RMO	0,354	0,367	0,528	0,433
LSTM-RMOD	0,363	0,367	0,529	0,433
LSTM-RMODV	0,388	0,381	<b>0,636</b>	0,477

Fonte: Elaboração própria.

Entretanto, uma perspectiva interessante é ressaltada pelas métricas apresentadas na Tabela 3. O modelo LSTM-N apresentou a maior quantidade acumulada de pontos, porém também o maior número de operações e o maior *drawdown*, isto representa que a estratégia aplicada resultou no período mais longo de rebaixamento de saldo entre as demais. Assim, pode-se concluir que o LSTM-N demanda muitos *trades* para obter uma quantidade significativa de pontos acumuladas, o que consequentemente aumenta o risco devido ao alto valor do *drawdown*. Em contrapartida, observa-se que todos estes esforços resultam em um número acumulado de pontos próximo do LSTM-RMODV, porém utilizando menos recursos. Isto porque, comparando os dois cenários, o *drawdown* e o número de operações foi de 6 e 8 vezes menor, respectivamente, à favor do LSTM-RMODV. Além disso, o pior cenário foi proveniente do LSTM-PH, evidenciando que basear somente na previsão pode ser um problema na prática, que ressalta a importância do RM.

Tabela 3 – Métricas de desempenho financeiro

Modelos LSTM	Pontos acumulados	Drawdown	Número de operações
LSTM-N	<b>14.865</b>	17.250	5.227
LSTM-PH	-18.075	18.075	4.644
LSTM-RMO	500	12.650	1.364
LSTM-RMOD	8.720	5.750	905
LSTM-RMODV	<b>14.145</b>	<b>2.760</b>	<b>647</b>

Fonte: Elaboração própria.

Assim, pode-se inferir que altos valores para as demais métricas apresentadas na Tabela 3, exceto no quesito pontos acumulados, podem impactar negativamente a estratégia. Para ilustrar graficamente, a Figura 26 apresenta o acumulado de pontos de cada modelo, onde pode ser visto a relação entre os modelos citados.

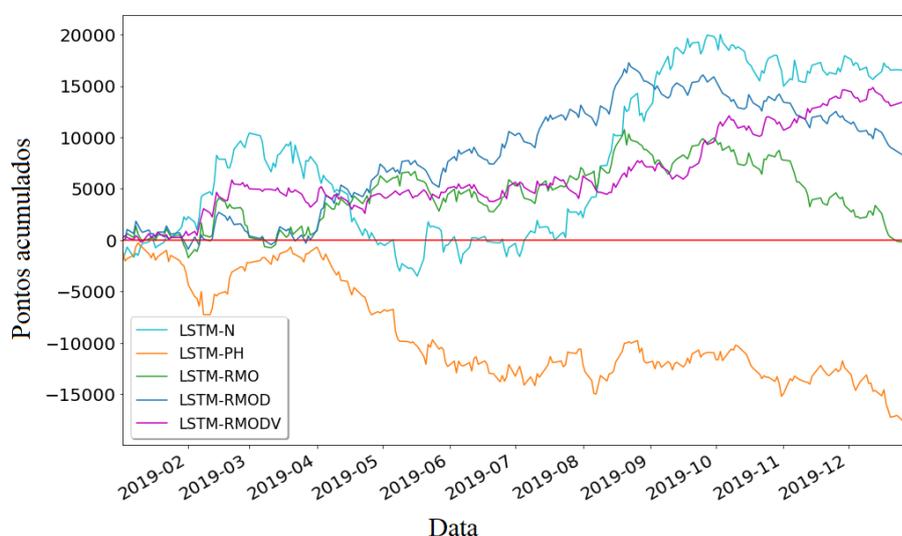


Figura 26 – Pontos acumulados em 2019

Fonte: Elaboração própria.

Dito isto, a avaliação financeira foi então calculada para cada caso e os resultados são demonstrados na Tabela 4, cuja unidade de medida adotada foi em moeda nacional, reais (R\$). Baseado neste resultados, fica claro que o modelo LSTM-N não é o melhor dentre os cinco dada a rentabilidade, ao invés disso, a melhor performance foi apresentada pelo LSTM-RMODV. Métricas financeiras dão suporte a avaliação financeira, a qual representa a mais importante análise, visto que o modelo proposto deve ser capaz de gerar rentabilidade no mundo real, em outras palavras, apresentar rentabilidade líquida atrativa ao investidor.

Tabela 4 – Avaliação financeira

Modelos LSTM	Capital investido	Rentabilidade bruta	Custos de transação	Rentabilidade líquida
LSTM-N	6.063,50	2.973,00	2.613,50	287,60
LSTM-PH	5.937,00	-3.615,00	2.322,00	-5.937,00
LSTM-RMO	3.212,00	100,00	682,00	-582,00
LSTM-RMOD	1.602,50	1.744,00	452,50	1.033,20
LSTM-RMODV	<b>875,50</b>	2.829,00	323,50	<b>2.004,40</b>
<b>Imposto de renda devido para a rentabilidade líquida = 20%</b>				

Fonte: Elaboração própria.

Primeiramente, foi possível calcular a necessidade de capital investido envolvendo as métricas financeiras resultantes de cada modelo LSTM  $i$ , conforme Equação 4.1. Quanto maior estes valores, maior a necessidade, como mostrado na primeira coluna.

$$Cap_i = (D_i \times q_i \times 0,2) + C_i \quad (4.1)$$

onde  $Cap_i$  é a necessidade inicial de capital investido,  $D_i$  representa *drawdown*,  $q_i$  é o número de contratos usados, o parâmetro fator de alavancagem é 0,2 e  $i$  representa cada modelo LSTM

Por meio da Equação 3.8 foi possível obter a rentabilidade bruta mostrada na terceira coluna da Tabela 4. Uma vez que o custo de transação é correlacionado positivamente ao número de operações, seu calculado foi realizado com base na Equação 3.9 e apresentado na quarta coluna da tabela. Finalmente, subtraindo o custo de transação da rentabilidade bruta é possível encontrar a rentabilidade final. Entretanto, ainda é preciso deduzir o imposto de renda de 20% desta diferença para assim obter a rentabilidade líquida apresentada na última coluna da tabela. Por fim, como a rentabilidade final do segundo e terceiro modelo foram negativas, não foi aplicado cálculo para IR.

Normalmente, a literatura considera um valor fixo de capital investido para comparação do resultado de diferentes modelos. Neste caso, como a necessidade inicial de capital investido contida na segunda coluna da Tabela 4 não foi considerada no cálculo para encontrar a rentabilidade líquida, o efeito de comparação foi preservado. Entretanto, o método convencional pode representar um problema ao considerar condições reais de mercado. Cada modelo possui características diferentes, onde a mensuração do capital inicial investido com base no desempenho financeiro se torna mais realista. Assim, o modelo matemático apresentado na Equação 4.1 pode configurar outra importante contribuição deste trabalho para a academia, porém para comprovar a hipótese levantada, estudos aprofundados fazem-se necessários.

Como mencionado anteriormente é visto de forma clara nesta fase, o modelo LSTM-N de fato apresenta performance financeira insatisfatória, não se tratando do melhor modelo em termos de rentabilidade real. Uma das razões que explica este fenômeno diz respeito aos altos números de operações que aumentam o custo de transação linearmente. Isto porque, a abordagem estratégica adotada é demasiadamente simples, com ausência de RM. O resultado disto é uma rentabilidade bruta superior aos outros cinco modelos – mas muito próximo ao LSTM-RMODV – porém, quando considerado todos os custos, cai para terceira posição entre eles. A rentabilidade líquida acumulada ao longo do período de teste dos modelos é apresentada na Figura 27 por meio da denominação “Lucro líquido” no eixo “y”.

Adicionalmente, considerando o capital investido, o risco-retorno do modelo LSTM-N não é bem aceito pelos investidores. Em vez disto, o LSTM-RMODV é mais atrativo. Ou seja, a proporção entre a rentabilidade líquida e capital investido é de 0,04 no LSTM-N enquanto passa a ser 2,28 no caso do LSTM-RMODV. Embora o *Sharpe ratio* calculado tenha sido de 0,082 para o LSTM-RMODV, os *traders* necessitam de menos capital investido para maiores retornos

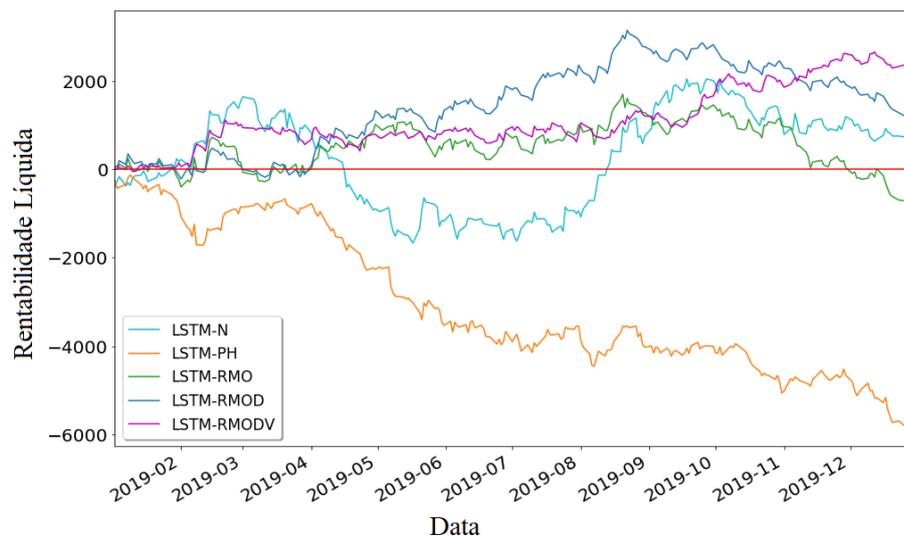


Figura 27 – Rentabilidade líquida acumulada em 2019

Fonte: Elaboração própria.

financeiros. Esta análise é importante para perfis de risco de investidores que se encaixam nesta modalidade, pois o LSTM-RMODV possui um risco atrelado, mas também é altamente rentável. Por fim, o LSTM-PH apresentou o pior caso, uma vez que teve um acumulado de pontos negativos.

Dito isto, embora todo o estudo tenha sido desenvolvido considerando o lote mínimo para negociação, uma unidade de contrato, para aprimorar o estudo a Tabela 5 mostra cinco cenários simulados baseados no número de contratos operados. Esta abordagem visa comparar o modelo LSTM-RMODV com a conhecida técnica *buy and hold*, B&H. Para isto, o mesmo valor de necessidade de capital investido foi considerado para os dois cenários. Para o B&H, deve-se considerar a taxa de crescimento de 30%, sendo o resultado do *benchmark* Ibovespa durante o ano 2019, mesmo período de teste do modelo. Estes resultados foram comparados com os dados do modelo de sucesso, LSTM-RMODV, com o objetivo de encontrar a relação de risco-retorno entre eles.

Conforme apresentado na tabela, os resultados proporcionados pelo ATS por meio da estratégia aplicada demonstram que o método *day-trading* é atrativo. Além disso, o modelo apresentou uma taxa de rentabilidade de 228,94% sobre o valor investido, enquanto o B&H alcançou somente os 30% referente ao retorno anual do *benchmark*. Este resultado foi possível devido ao fator de alavancagem característica deste tipo de contrato e operação. A Tabela 5 também revela que a razão entre as duas estratégias comparadas é de 7,7 vezes.

## 4.2 Resultados Experimentais do Algo-LSTM

Diante do modelo LSTM-RMODV ter apresentado os melhores retornos em termos de rentabilidade real, inclusive reportando resultado 94% superior ao segundo melhor modelo,

Tabela 5 – Simulação de alavancagem do LSTM-RMODV contra a técnica B&amp;H

Número de contratos	Capital investido	Benchmark	Rentabilidade líquida B&H	Rentabilidade líquida LSTM-RMODV
1	875,50	1.138,15	262,00	2.004,40
5	4.377,50	5.690,75	1.309,98	10.022,00
10	8.755,00	11.381,50	2.619,96	20.044,00
50	43.775,00	56.907,50	13.099,78	100.220,00
100	87.550,00	113.815,00	26.199,56	200.440,00

Razão LSTM-RMODV:B&H = 7,7

Fonte: Elaboração própria.

LSTM-RMOD, o modelo de sucesso foi utilizado para os ciclos de otimização realizados, dispensando assim, a necessidade de considerar os demais.

Com base no novo conjunto de parâmetros, o modelo Algo-LSTM alcançou resultados superiores tanto em relação aos indicadores de performance financeira, quanto em resultado líquido. Além disso, apresentou resultado positivo no período de teste de 2015, em que o Ibovespa desvalorizou 12,31%.

Entretanto, como não foi possível realizar o teste no período completo de 2015 devido a disponibilidade de dados da plataforma MetaTrader 5, foi considerada somente a variação do Ibovespa correspondente ao mesmo período de teste realizado. Deste modo, entre 28/04/2015 a 28/12/2015, o Ibovespa desvalorizou 21,21%, sendo o valor do *benchmark* aplicado nesta fase da avaliação.

Primeiramente, foram apresentadas todas as métricas de avaliação de performance do algoritmo nos períodos testados para comparação entre os dois modelos. A Tabela 6 apresenta os valores referentes à classe de compra, onde pode ser observado que no anos de 2019 o modelo Algo-LSTM obteve performance superior em todas as métricas apresentadas quando comparado ao protótipo desenvolvimento. Por outro lado, a Tabela 7 exhibe os valores proporcionados pela classe de venda. Considerando que a diferença apresentada para a medida *F-measure* entre os modelos é de apenas 2%, pode-se dizer que apenas o Algo-LSTM não apresentou melhores resultados apenas para a métrica *Recall*. Por fim, é importante destacar que devido às propriedades da acurácia, seu valor é o mesmo independente da classe considerada.

Tabela 6 – Métricas de avaliação do modelo para classe de compra

Ano	Modelo	Acurácia	Precisão	Recall	F-measure
2015	Algo-LSTM	0,454	0,444	0,338	0,384
2019	LSTM-RMODV	0,388	0,405	0,193	0,262
	Algo-LSTM	<b>0,439</b>	<b>0,472</b>	<b>0,364</b>	<b>0,411</b>

Fonte: Elaboração própria.

Tabela 7 – Métricas de avaliação do modelo para classe de venda

Ano	Modelo	Acurácia	Precisão	Recall	F-measure
2015	Algo-LSTM	0,454	0,460	0,571	0,510
2019	LSTM-RMODV	0,388	0,381	<b>0,636</b>	0,477
	Algo-LSTM	<b>0,439</b>	<b>0,417</b>	0,528	0,466

Fonte: Elaboração própria.

Embora as métricas citadas demonstrem que o Algo-LSTM desempenha performance superior, os resultados mostrados na avaliação financeira contida no Quadro 11 permitem comprovar quantitativamente esta melhoria. O primeiro resultado refere-se ao à rentabilidade operacional, Equação 3.8, onde deduzindo os custos de transação presentes no parâmetro seguinte, encontra-se a rentabilidade bruta e posterior rentabilidade líquida considerando a alíquota de imposto de renda devida. A valorização apresentada refere-se à rentabilidade líquida obtida sobre o investimento inicial e as razões mensuram quão superior os modelos utilizando LSTM superaram o B&H. Para efeito de comparação real, a técnica B&H foi aplicada em todos os cenários devido às particularidades de cada modelo em cada ano analisado, 2015 e 2019.

Primeiramente, enquanto o mesmo valor inicial investido em 2015 resultou em prejuízos financeiros de 21,21% no B&H, o modelo conseguiu alcançar rentabilidade interessante nos oito meses de teste realizado, sendo 112,81% sobre o investimento. Importante destacar que para a rentabilidade líquida foi descontado o imposto de renda apenas para o *day-trade* em 20%, enquanto nenhum imposto foi considerado no B&H visto que os valores são inferiores a 20 mil reais.

Por sua vez, o aumento sofrido no *drawdown* do Algo-LSTM, é justificado pelo *backtest* dinâmico, que agora considera toda a volatilidade inerente. Embora o acréscimo deste parâmetro, resultando na razão antes de 7,7 para 7,0, tenha impacto direto na necessidade de capital investido, o valor ainda não ultrapassa o limite de dois mil reais por contrato, o que normalmente é requerido para robôs investidores. Além disso, o Algo-LSTM foi mais efetivo utilizando menos recursos que o LSTM-RMODV. O modelo reportou 63% mais pontos acumulados com uma redução de 27% na quantidade de operações, o que resultou em um aumento de 74% da rentabilidade final, visto que os custos de transação foram reduzidos, gerando assim, a razão de 1,7 vezes mais que o modelo anterior.

Quadro 11 – Avaliação econômica comparativa entre Algo-LSTM e B&H

Parâmetros	2015		2019			
	Algo-LSTM	B&H versus Algo-LSTM	LSTM-RMODV	B&H versus LSTM-RMODV	Algo-LSTM	B&H versus Algo-LSTM
Pontos	10.610	-	14.145	-	<b>22.980</b>	-
Benchmark	-	<b>-21,21%</b>	-	30%	-	30%
Drawdown	6.319	-	2.760	-	7.199	-
Operações	282	1	647	1	<b>471</b>	1
Capital	1.404,85	1.404,85	875,50	875,50	1.675,30	1.675,30
Rentabilidade Op.	2.122,00	<b>-297,97</b>	2.829,00	262,65	4.596,00	502,59
Custo	141,00	0,82	323,50	0,65	235,50	1,25
Rentabilidade bruta	1.981,00	<b>-298,78</b>	2.505,50	262,00	4.360,50	501,34
Rentabilidade líquida	1.584,80	<b>-298,78</b>	2.004,40	262,00	<b>3.488,40</b>	501,34
Valorização	112,81%	<b>-21,27%</b>	228,94%	29,93%	208,23%	29,93%
Razão LSTM:B&H			7,7		7,0	
<b>Razão Algo-LSTM:LSTM-RMODV = 1,7</b>						

Fonte: Elaboração própria.

Com isto, foram calculados os respectivos *Sharpe ratio* de todos os modelos adotados. Diante do modelo Algo-LSTM ter atingido melhores resultados, consequentemente isto refletiu

no seu índice, apresentando valores superiores no ano de 2019 tanto considerando a Selic como taxa livre de risco, como o *benchmark*, visto na Tabela 8. Em relação a 2015, é possível observar que o modelo reportou melhor resultado na análise com base no *benchmark* visto a valorização negativa do índice neste período.

Tabela 8 – Avaliação de performance do investimento

	Algo-LSTM (2015)	LSTM-RMODV (2019)	Algo-LSTM (2019)
<b>Selic</b>			
Sharpe ratio	0,12	0,08	<b>0,13</b>
<b>Benchmark</b>			
Ibov ratio	0,16	0,05	<b>0,07</b>

Fonte: Elaboração própria.

### 4.3 Resultados Experimentais da Taxa de Erro em Conta Real

Esta última análise de resultados, corresponde à sétima etapa do modelo conceitual mostrado na Figura 16. Nesta avaliação foi realizada uma testagem em conta real do Algo-LSTM, a fim de mensurar os impactos produzidos pelo *slippage* nas operações. O teste compreendeu 38 dias úteis entre 14 de abril a 08 de junho de 2020.

É importante destacar que em 09 de março de 2020 houve a primeira tentativa de colocar o modelo em produção, mas como citado anteriormente, foi o mesmo dia em que ocorreu o primeiro *circuit breaker* de 2020 na B3 (B3, 2020a). No dia posterior ocorreu mais uma tentativa, porém a alta volatilidade apresentada impossibilitou a análise apropriada do *slippage*, conforme explanado na Seção 5.2.

O teste com conta real utilizou uma conta real propriamente dita contendo recursos financeiros reais em moeda nacional. A escolha de não utilizar recurso virtual, possível em conta “demo”, foi devido ao fato de que houvesse a mensuração autêntica do *slippage*, uma vez que a conta demo possui características semelhantes ao sistema de *backtest* por não abranger a demanda real do mercado no momento das execuções das ordens.

Para cálculo do impacto do *slippage*, uma abordagem paramétrica foi utilizada uma vez que a amostra coletada é considerada grande, além de apresentar uma distribuição normal (MONTGOMERY; RUNGER, 2010). Assim, para encontrar o intervalo de confiança (IC) foi realizado o teste *t-Student*, Equação 4.2. Assim, com base na média amostral ( $\bar{x}$ ), desvio padrão amostral ( $s$ ) e número de amostras ( $n$ ), foi possível calcular com um nível de 95% de confiança de que o IC do *slippage* foi de  $[-15,18 ; 17,18]$ , Equação 4.3

$$IC = \left[ \bar{x} - t \left( \frac{s}{\sqrt{n}} \right); \bar{x} + t \left( \frac{s}{\sqrt{n}} \right) \right] \quad (4.2)$$

$$IC = \left[ 1 - 2,0452 \left( \frac{43,32}{\sqrt{30}} \right); 1 + 2,0452 \left( \frac{43,32}{\sqrt{30}} \right) \right] = [-15,18; 17,18] \quad (4.3)$$

Isto significa que há 95% de probabilidade da média do resultado anual do *trade* em conta real sofra variação entre -15 a +17 pontos em relação ao fornecido pelo *backtest*. Sabendo que os resultados de pontos acumulados anuais do Algo-LSTM foram de 10.610 em 2015 e 22.980 em 2019, então é possível afirmar que o *slippage* a longo prazo não influencie no resultado final.

## 5 Considerações finais

Nesta dissertação, o objetivo principal foi avaliar a rentabilidade líquida e propor novas estratégias de negociação com RM conhecidas como *trading strategy* para um ATS baseado em CI. Isto porque foi identificada uma lacuna existente na literatura referente à avaliação real dos modelos, colocando em dúvida a confiabilidade dos preditores na prática, uma vez que há diversos fatores de mercado que podem impactar o resultado final das operações.

Ao realizar uma extensa investigação da literatura sobre as técnicas de CI mais implementadas para previsão de séries temporais financeiras, foi identificada a rede LSTM como estado-da-arte em DL. Devido ao desenvolvimento da programação estar fora do escopo deste trabalho, sua estrutura base foi desenvolvida em parceria com um desenvolvedor e pesquisador da área, possibilitando a total customização do ATS de acordo com os interesses deste trabalho, o que não seria possível, utilizando a opção de *softwares* de código fechado. Isto possibilitou que o foco da pesquisa concentrasse na construção das estratégias de gerenciamento de risco, otimização e análises financeiras citadas.

Inicialmente, foram desenvolvidas cinco estratégias distintas utilizando o algoritmo LSTM como base. Assim, foram gerados cinco modelos diferentes para análise e comparação. Todos os modelos foram executados em *backtest* e avaliados em termos de rentabilidade líquida, a qual considera os custos de transação inerentes e IR devido. Durante os testes experimentais, foi possível demonstrar que a utilização de técnicas de *trading strategy* com um correto RM ajudaram a evitar falsas entradas, minimizando perdas e reduzindo custos operacionais, que possuem influência direta na rentabilidade.

Posteriormente, o modelo que obteve melhor performance dentre os cinco, o LSTM-RMODV, foi submetido à diversas melhorias. Entre elas, a implementação das técnicas de *Break-even* e *Trailing Stop*, indicadas como sugestões para trabalhos futuros no estudo preliminar, e uma série de otimizações do *trading strategy*. Com isto, foi possível obter um conjunto de parâmetros que trouxe melhores resultados ao ATS, dando origem ao novo modelo denominado Algo-LSTM. Em última etapa, a avaliação do *slippage* em relação ao *backtest* foi de suma importância para demonstrar a diferença entre um ambiente real e simulado. Com isto, foi possível inferir que a longo prazo e utilizando as estratégias propostas, o impacto do *slippage* não foi significativo para o resultado final.

Por fim, embora as métricas de acurácia, precisão, *recall* e *F-measure* para avaliação financeira do modelo tenham sido aprimoradas por meio do Algo-LSTM, ainda há espaço para melhorias. Entretanto, conforme demonstrado pelos resultados, mesmo em casos em que estas métricas não sejam tão altas, é possível obter um modelo rentável utilizando estratégias eficazes de gerenciamento de risco.

Diante dos resultados apresentados, foi possível concluir que a dissertação atingiu seu objetivo principal, uma vez que foram propostas as cinco estratégias de negociação com RM

citadas e avaliada a rentabilidade líquida dos modelos. Com isso, foi possível revelar resultados positivos tanto em *bull* quanto *bear market*, ressaltando a importância do RM como fator decisivo no resultado final, isto é, os modelos que utilizaram RM tiveram melhor performance financeira, evidenciando que quanto melhor a estratégia, melhor a rentabilidade líquida, como observado no modelo final Algo-LSTM.

Além disso, os resultados alcançados pelos modelos propostos, superaram significativamente o uso da técnica B&H em todos os cenários avaliados, inclusive o *bear market* de 2015. Ainda que, considerando um cenário altista em que o *benchmark* apresentou um retorno positivo anual de 30%, o modelo proposto o superou em uma razão de 7 vezes mais, provando sua performance superior. Diante do exposto, foi respondida a questão de pesquisa colocada inicialmente, ou seja, é possível obter rentabilidade líquida positiva com um modelo preditor baseado em análise técnica e CI utilizando estratégias de negociação e gerenciamento de risco apropriadas ao mercado de capitais.

## 5.1 Contribuições

Primeiramente foram pontuadas três importantes contribuições em relação aos resultados alcançados. Em primeiro lugar, foram desenvolvidos e apresentados cinco diferentes *setups* para avaliação da rentabilidade líquida do ATS estudado, uma significativa contribuição, uma vez que foi de desenvolvimento próprio deste trabalho. Adicionalmente, foi proposto um modelo final com um novo conjunto de parâmetros otimizados de RM. A segunda relevante contribuição, concentra-se na avaliação da rentabilidade líquida do ATS baseado em CI e TIs utilizando as estratégias desenvolvidas. Assim, foi demonstrada a rentabilidade líquida positiva em diferentes características de mercado, *bull* e *bear market*. A última interessante contribuição refere-se à avaliação do *slippage* do modelo final, importante ponto para testar a robustez do *backtest* realizado, que revelou ter impactos discretos no modelo apresentado.

Referente à academia, a utilização de técnicas de *trading strategy* englobadas no ATS demonstraram ser eficazes, contribuindo para a escassez de estudos que as consideram. Indo além, o presente trabalho comprovou sua eficácia por meio do teste em conta real, conforme mencionado. Segundo a revisão da literatura e análise bibliométrica realizada, ainda não foram encontrados pesquisas que realizem testes em conta real.

Do ponto de vista amplo, ressalta-se também que como o método apresentado e avaliado é baseado em um sistema autônomo, o fator psicológico foi totalmente eliminado. Adicionalmente, os resultados demonstraram que mesmo em situações de mercado altista, o modelo pode superar a performance do *benchmark* de referência, se tornando assim, um importante candidato a formação de portfólios eficientes de investimento, bem como fundos quantitativos.

Finalmente, o modelo e a avaliação financeira propostos trouxeram uma nova contribuição não só para a academia, preenchendo diversos *gaps* existentes, como citados anteriormente, mas também puderam fornecer uma nova forma de negociação para investidores, em especial

PFs. Isto porque a aplicação prática do estudo permite que investidores possam considerá-lo em processos de tomada de decisão, tanto em relação ao *day-trade* em si, como, reforçando, para criação de portfólio diversificado de investimentos e fundos quantitativos.

Embora a codificação do algoritmo utilizada neste estudo não tenha sido divulgada completamente devido à propriedade intelectual do desenvolvedor, foi exposto com clareza e objetividade todos os parâmetros utilizados em sua construção, como a arquitetura do algoritmo preditor, o RM e avaliação financeira, proporcionando um guia transparente. Assim, foram apresentadas todas as configurações do RM utilizadas, revelando o conjunto de sucesso para o algoritmo de melhor performance, o Algo-LSTM. Todas as etapas e parâmetros do algoritmo preditor foram apresentadas e quantificadas. Por fim, foi exposta a avaliação econômica completa aplicada de acordo com o ambiente real em estudo.

Todos estes fatores exibidos tornam o experimento replicável para demais pesquisadores que queiram testar com outros modelos e mercados futuramente. Esta é mais uma das maiores contribuições deste trabalho, visto que a literatura indica que TS de sucesso tendem a ser mantidos em sigilo.

## 5.2 Limitações do Trabalho

Visto o cenário ocorrido ao longo de 2020 com início em 9 de março, em que a B3 sofreu episódios de *circuit breakers*<sup>1</sup>, é importante ressaltar que momentos atípicos como estes, que ultrapassam inclusive estudos avançados de *stress test*, trazem limitações aos parâmetros desenvolvidos para este modelo.

Isto porque, em ambiente real há a ocorrência de *spreads* de mercado, como visto na Seção 4.3. A diferença nestes casos isolados de *circuit breaker* e leilão do Ibovespa em 2020, encontra-se no fato de que o *spread* de mercado em relação ao ATS que normalmente seria de 1x, tranquilamente suportado pelo algoritmo, pode passar a ser de 1000x, por exemplo.

Por outro lado, essa limitação torna-se positiva, uma vez que permite ao operador sofrer a perda somente do evento ocorrido. Deste modo, não é obrigado a carregar posições que sofreram perdas significativas por longos períodos de tempos, como todos os meses em que perdurou a queda do Ibovespa até que houvessem sinais de retorno aos patamares anteriores.

Embora essa limitação não evite que o modelo sofra as possíveis perdas superiores ao gerenciamento de risco implementado, devido a eventualidade do ocorrido, pode-se considerar como casos isolados que dificilmente são superados tanto por inteligência humana como artificial, por se tratar de evento consideravelmente externo ao mercado.

<sup>1</sup> O *circuit breaker* é uma ação operacional da B3 que ocorre em momentos de forte queda de preços com base na variação do Ibovespa, impedindo os negócios enquanto perdurar o procedimento (B3, 2020a)

### 5.3 Sugestões para Trabalhos Futuros

Uma vez que a série de otimizações realizadas cessaram ao atingir 0,07% de melhora em relação ao último ciclo, é possível concluir que neste quesito o modelo possa ter atingido o seu potencial máximo. Assim, como primeira sugestão para trabalhos futuros, a utilização de outro modelo contendo camadas mais sofisticadas podem resultar em melhorias às métricas de acurácia, precisão, *recall* e *F-measure*, minimizando falsas entradas.

Segundo, como foi utilizado um grande número de indicadores técnicos, recomenda-se um estudo estatístico para exclusão de possíveis redundâncias que afetem o desempenho do modelo. Além disso, uma melhor seleção também pode ser encontrada por meio de algoritmos próprios de otimização. Por outro lado, a utilização de notícias e indicadores macroeconômicos como parâmetros de entrada, configuram pontos interessantes a serem considerados.

Adicionalmente, como solução para as limitações do modelo devido à alta volatilidade do mercado, recomenda-se adicionar estratégias de gerenciamento de risco para evitar que o algoritmo esteja posicionado em operações dentro deste contexto. Para isto, o monitoramento do índice “VIX”, conhecido como índice do medo, pode ser uma alternativa eficaz.

Por último, para trazer maior robustez ao modelo e desfrutar de uma maior base para testes, sugere-se utilizar dados de mercados mais maduros, como o S&P500, para treinamento e validação. Deste modo, a fase de teste pode ser realizada no mercado local utilizando integralmente sua base de dados, visto que normalmente as corretoras fornecem somente os últimos cinco anos devido aos altos custos envolvidos no armazenamento destas informações.

## Referências

- ADEBIYI, A. A.; ADEWUMI, A. O.; AYO, C. K. Comparison of arima and artificial neural networks models for stock price prediction. **Journal of Applied Mathematics**, Hindawi, v. 2014, 2014. Citado 3 vezes nas páginas 37, 38 e 40.
- AMORIM, A. J.; ZANE, A. P. d. S.; GUILLEN, A.; AMARAL, D.; SILVA, R. O. d. M. da; TOLEDO, L. A. Home broker e bm&f bovespa: Um estudo de caso. **REA-Revista Eletrônica de Administração**, v. 10, n. 1, 2011. Citado na página 23.
- ASSOCIAÇÃO BRASILEIRA DE FINTECHS. **Pesquisa Fintech Deep Dive 2019**. 2019. Acesso em: 09 de out. 2020. Citado na página 27.
- ATSALAKIS, G. S.; VALAVANIS, K. P. Surveying stock market forecasting techniques–part ii: Soft computing methods. **Expert Systems with Applications**, Elsevier, v. 36, n. 3, p. 5932–5941, 2009. Citado 2 vezes nas páginas 18 e 38.
- B3 S.A. - BRASIL, BOLSA, BALCÃO. **Relações com Investidores - Apresentação mensal B3 - abril 2019**. 2019. Disponível em: <<http://ri.bmfbovespa.com.br/ptb/s-5-ptb.html?idioma=ptb>>. Acesso em: 10 de jul. 2019. Citado 2 vezes nas páginas 22 e 23.
- \_\_\_\_\_. **Relações com Investidores - Relatório Anual 2018**. 2019. Disponível em: <<http://ri.bmfbovespa.com.br/ptb/s-20-ptb.html?idioma=ptb>>. Acesso em: 09 de jul. 2019. Citado 2 vezes nas páginas 17 e 23.
- \_\_\_\_\_. **Índice Bovespa - Futuro de Ibovespa**. 2019. Disponível em: <[http://www.b3.com.br/pt\\_br/produtos-e-servicos/negociacao/renda-variavel/futuro-de-ibovespa.htm](http://www.b3.com.br/pt_br/produtos-e-servicos/negociacao/renda-variavel/futuro-de-ibovespa.htm)>. Acesso em: 10 de jul. 2019. Citado na página 24.
- \_\_\_\_\_. **Índice Bovespa - Futuro Mini de Ibovespa**. 2019. Disponível em: <[http://www.b3.com.br/pt\\_br/produtos-e-servicos/negociacao/renda-variavel/futuro-mini-de-ibovespa.htm](http://www.b3.com.br/pt_br/produtos-e-servicos/negociacao/renda-variavel/futuro-mini-de-ibovespa.htm)>. Acesso em: 10 de jul. 2019. Citado na página 24.
- \_\_\_\_\_. **Aviso ao mercado - Circuit breaker**. 2020. Disponível em: <[http://www.b3.com.br/pt\\_br/noticias/aviso-ao-mercado-8AE490C870BF0D5D0170BF7FBAE91DA7.htm](http://www.b3.com.br/pt_br/noticias/aviso-ao-mercado-8AE490C870BF0D5D0170BF7FBAE91DA7.htm)>. Acesso em: 01 de fev. 2021. Citado 2 vezes nas páginas 68 e 72.
- \_\_\_\_\_. **Busca de Corretoras**. 2020. Disponível em: <[http://www.b3.com.br/pt\\_br/produtos-e-servicos/participantes/busca-de-participantes/busca-de-corretoras/](http://www.b3.com.br/pt_br/produtos-e-servicos/participantes/busca-de-participantes/busca-de-corretoras/)>. Acesso em: 30 de ago. 2020. Citado na página 23.
- \_\_\_\_\_. **Histórico pessoas físicas**. 2020. Disponível em: <[http://www.b3.com.br/pt\\_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/historico-pessoas-fisicas/](http://www.b3.com.br/pt_br/market-data-e-indices/servicos-de-dados/market-data/consultas/mercado-a-vista/historico-pessoas-fisicas/)>. Acesso em: 10 de ago. 2020. Citado na página 17.
- BAHRAMMIRZAEI, A. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. **Neural Computing and Applications**, Springer, v. 19, n. 8, p. 1165–1195, 2010. Citado 2 vezes nas páginas 37 e 38.

BANCO CENTRAL DO BRASIL - BC. **Copom reduz taxa Selic para 9,25% a.a.** 2017. Disponível em: <<https://www.bcb.gov.br/detalhenoticia/16217/nota>>. Acesso em: 14 de abr. 2020. Citado na página 16.

\_\_\_\_\_. **Comunicados do Copom.** 2020. Disponível em: <<https://www.bcb.gov.br/controleinflacao/comunicadoscopom>>. Acesso em: 14 de abr. 2020. Citado na página 16.

\_\_\_\_\_. **Copom reduz taxa Selic para 2,00% a.a.** 2020. Disponível em: <<https://www.bcb.gov.br/detalhenoticia/17148/nota>>. Acesso em: 10 de ago. 2020. Citado na página 17.

\_\_\_\_\_. **Taxas de juros básicas – Histórico.** 2020. Disponível em: <<https://www.bcb.gov.br/controleinflacao/historicotaxasjuros>>. Acesso em: 14 de abr. 2020. Citado na página 16.

BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, MCB UP Ltd, v. 22, n. 2, p. 241–264, 2002. Citado na página 48.

BRASILEIRO, R. C.; SOUZA, V. L.; FERNANDES, B. J.; OLIVEIRA, A. L. Automatic method for stock trading combining technical analysis and the artificial bee colony algorithm. In: IEEE. **2013 IEEE Congress on Evolutionary Computation**. Cancun, Mexico, 2013. p. 1810–1817. Citado 3 vezes nas páginas 38, 40 e 41.

BRITO, R. F. D.; OLIVEIRA, A. L. A probabilistic and dynamic chart pattern recognition hybrid system applied to foreign exchange rate prediction. In: IEEE. **2016 International Joint Conference on Neural Networks (IJCNN)**. Vancouver, BC, Canada, 2016. p. 1112–1119. Citado 2 vezes nas páginas 38 e 40.

BRITO, R. F. de; OLIVEIRA, A. L. Comparative study of forex trading systems built with svr+ghsom and genetic algorithms optimization of technical indicators. In: IEEE. **2012 IEEE 24th International Conference on Tools with Artificial Intelligence**. Athens, Greece, 2012. v. 1, p. 351–358. Citado 2 vezes nas páginas 38 e 40.

BROCK, W.; LAKONISHOK, J.; LEBARON, B. Simple technical trading rules and the stochastic properties of stock returns. **The Journal of finance**, Wiley Online Library, v. 47, n. 5, p. 1731–1764, 1992. Citado na página 26.

BROOKS, C. **Introductory econometrics for finance**. Cambridge, UK: Cambridge university press, 2019. 724 p. Citado na página 37.

CAVALCANTE, R. C.; BRASILEIRO, R. C.; SOUZA, V. L.; NOBREGA, J. P.; OLIVEIRA, A. L. Computational intelligence and financial markets: A survey and future directions. **Expert Systems with Applications**, Elsevier, v. 55, p. 194–211, 2016. Citado 9 vezes nas páginas 16, 17, 18, 19, 20, 36, 48, 49 e 50.

CHADEGANI, A. A.; SALEHI, H.; YUNUS, M.; FARHADI, H.; FOOLADI, M.; FARHADI, M.; EBRAHIM, N. A. A comparison between two main academic literature collections: Web of science and scopus databases. **Asian Social Science**, v. 9, n. 5, p. 18–26, 2013. Citado na página 27.

CHAGUE, F.; DE-LOSSO, R.; GIOVANNETTI, B. Day trading for a living? **SSRN Electronic Journal**, FGV, São Paulo, 2019. Citado 3 vezes nas páginas 19, 20 e 47.

CHEN, J. High-frequency trading (hft). In: INVESTOPEDIA. **Algorithmic Trading**. 2019. Disponível em: <<https://www.investopedia.com/terms/h/high-frequency-trading.asp>>. Acesso em: 27 de ago. 2020. Citado na página 17.

\_\_\_\_\_. Slippage. In: INVESTOPEDIA. **Trading Skills Essentials - Trading Basic Education**. 2020. Disponível em: <<https://www.investopedia.com/terms/s/slippage.asp>>. Acesso em: 21 de ago. 2020. Citado na página 49.

CHENG, V. C.; LAU, S. K.; WOO, P. C.; YUEN, K. Y. Severe acute respiratory syndrome coronavirus as an agent of emerging and reemerging infection. **Clinical microbiology reviews**, Am Soc Microbiol, v. 20, n. 4, p. 660–694, 2007. Citado na página 16.

CINTRA, M. A. M.; FARHI, M. A crise financeira e o global shadow banking system. **Novos estudos CEBRAP**, SciELO Brasil, n. 82, p. 35–55, 2008. Citado na página 33.

CVM - COMISSÃO DE VALORES MOBILIÁRIOS. **Pesquisa CVM sobre novas tecnologias financeiras (FINTECH)**. 2016. Disponível em: <[http://www.cvm.gov.br/export/sites/cvm/noticias/anexos/2017/20170606\\_relatorio\\_pesquisa\\_FINTECH.pdf](http://www.cvm.gov.br/export/sites/cvm/noticias/anexos/2017/20170606_relatorio_pesquisa_FINTECH.pdf)>. Acesso em: 09 de jul. 2019. Citado 2 vezes nas páginas 17 e 27.

\_\_\_\_\_. **O mercado de valores mobiliários brasileiro**. Rio de Janeiro, 2019. Citado 4 vezes nas páginas 22, 23, 24 e 26.

\_\_\_\_\_. **Ofício Circular nº 2/2019/CVM/SIN**. Rio de Janeiro, 2019. Citado na página 27.

DISTRITO. **Fintech Mining Report**. 2020. Acesso em: 09 de out. 2020. Citado na página 27.

D'SOUZA, D. Markets plunge following massive drop in oil prices. In: INVESTOPEDIA. **News - Markets News**. 2020. Disponível em: <<https://www.investopedia.com/global-stock-markets-plunge-on-oil-price-slide-as-coronavirus-fears-spread-4799123>>. Acesso em: 15 de abr. 2020. Citado na página 16.

GERLEIN, E. A.; MCGINNITY, M.; BELATRECHE, A.; COLEMAN, S. Evaluating machine learning classification for financial trading: An empirical approach. **Expert Systems with Applications**, Elsevier, v. 54, p. 193–207, 2016. Citado 2 vezes nas páginas 38 e 40.

GLANTZ, M.; KISSELL, R. L. **Multi-asset risk modeling: techniques for a global economy in an electronic and algorithmic trading era**. [S.l.]: Academic Press, 2013. Citado na página 17.

GONZALEZ, R. T.; PADILHA, C. A.; BARONE, D. A. C. Ensemble system based on genetic algorithm for stock market forecasting. In: IEEE. **2015 IEEE Congress on Evolutionary Computation (CEC)**. Sendai, Japan, 2015. p. 3102–3108. Citado 2 vezes nas páginas 38 e 40.

GREFF, K.; SRIVASTAVA, R. K.; KOUTNÍK, J.; STEUNEBRINK, B. R.; SCHMIDHUBER, J. Lstm: A search space odyssey. **IEEE transactions on neural networks and learning systems**, IEEE, v. 28, n. 10, p. 2222–2232, 2016. Citado 3 vezes nas páginas 46, 82 e 83.

GUTMAN, L. F. D.; JOIA, L. A.; JR, V. A. M. Antecedentes da intenção de uso de sistemas de home broker sob a ótica dos investidores do mercado acionário. **Revista de Administração**, Elsevier, v. 49, n. 2, p. 353–368, 2014. Citado na página 23.

HAWAWINI, G.; VIALLET, C. **Finance for executives: Managing for value creation**. São Paulo: Cengage Learning, 2010. 574 p. Citado 2 vezes nas páginas 16 e 25.

- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997. Citado 2 vezes nas páginas 45 e 82.
- HSU, M.-W.; LESSMANN, S.; SUNG, M.-C.; MA, T.; JOHNSON, J. E. Bridging the divide in financial market forecasting: machine learners vs. financial economists. **Expert Systems with Applications**, Elsevier, v. 61, p. 215–234, 2016. Citado 4 vezes nas páginas 37, 38, 39 e 40.
- HUANG, Q.; WANG, T.; TAO, D.; LI, X. Biclustering learning of trading rules. **IEEE transactions on Cybernetics**, IEEE, v. 45, n. 10, p. 2287–2298, 2014. Citado 3 vezes nas páginas 17, 38 e 40.
- IBM BIG DATA ANALYTICS HUB. **The Four V's of Big Data**. 2020. Disponível em: <<https://www.ibmbigdatahub.com/infographic/four-vs-big-data>>. Acesso em: 22 de ago. 2020. Citado na página 42.
- IMF, M. F. Fiscal adjustment in an uncertain world. **Fiscal Monitor International Monetary Fund - April 2013**, Washington, D.C, v. 93, 2013. Citado na página 33.
- JAIN, A. K.; MAO, J.; MOHIUDDIN, K. M. Artificial neural networks: A tutorial. **Computer**, IEEE, v. 29, n. 3, p. 31–44, 1996. Citado 4 vezes nas páginas 42, 43, 44 e 46.
- JIA, W.; CHEN, W.; XIONG, L.; HONGYONG, S. Quantitative trading on stock market based on deep reinforcement learning. In: IEEE. **2019 International Joint Conference on Neural Networks (IJCNN)**. Budapest, Hungary, 2019. p. 1–8. Citado na página 47.
- KUMAR, D.; MEGHWANI, S. S.; THAKUR, M. Proximal support vector machine based hybrid prediction models for trend forecasting in financial markets. **Journal of Computational Science**, Elsevier, v. 17, p. 1–13, 2016. Citado 2 vezes nas páginas 18 e 38.
- KUMAR, G.; JAIN, S.; SINGH, U. P. Stock market forecasting using computational intelligence: A survey. **Archives of Computational Methods in Engineering**, Springer, p. 1–33, 2020. Citado 2 vezes nas páginas 18 e 19.
- LIANG, H.; WANG, J.-J.; XUE, Y.; CUI, X. It outsourcing research from 1992 to 2013: A literature review based on main path analysis. **Information & Management**, Elsevier, v. 53, n. 2, p. 227–251, 2016. Citado 2 vezes nas páginas 27 e 32.
- LIN, C.-S.; CHIU, S.-H.; LIN, T.-Y. Empirical mode decomposition–based least squares support vector regression for foreign exchange rate forecasting. **Economic Modelling**, Elsevier, v. 29, n. 6, p. 2583–2590, 2012. Citado na página 16.
- LU, L. Y.; LIU, J. S. A novel approach to identify the major research themes and development trajectory: The case of patenting research. **Technological Forecasting and Social Change**, Elsevier, v. 103, p. 71–82, 2016. Citado na página 27.
- MARCONI, M. d. A.; LAKATOS, E. M. **Introduction to time series analysis and forecasting**. São Paulo: Atlas, 2003. 310 p. Citado na página 48.
- MARTINS, R. A.; MELLO, J. B. P.; TURRIONI, C. H. **Guia para elaboração de monografia e TCC em engenharia de produção**. São Paulo: Editora Atlas SA, 2014. 224 p. Citado na página 48.

MCCARTHY, J.; MINSKY, M. L.; ROCHESTER, N.; SHANNON, C. E. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. **AI magazine**, v. 27, n. 4, p. 12–12, 2006. Citado na página 41.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943. Citado 2 vezes nas páginas 41 e 42.

MINISTÉRIO DA ECONOMIA, SECRETARIA ESPECIAL DA RECEITA FEDERAL DO BRASIL. **RECEITA FEDERAL: Imposto Sobre a Renda Pessoa Física - Perguntas e Respostas**. 2019. Disponível em: <<http://receita.economia.gov.br/interface/cidadao/irpf/2019/perguntao/perguntas-e-respostas-irpf-2019.pdf>>. Acesso em: 01 de dez. 2019. Citado na página 61.

MITROFF, I. I.; BETZ, F.; PONDY, L. R.; SAGASTI, F. On managing science in the systems age: two schemas for the study of science as a whole systems phenomenon. **Interfaces**, INFORMS, v. 4, n. 3, p. 46–58, 1974. Citado na página 48.

MONGEON, P.; PAUL-HUS, A. The journal coverage of web of science and scopus: a comparative analysis. **Scientometrics**, Springer, v. 106, n. 1, p. 213–228, 2016. Citado na página 27.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. Hoboken, New Jersey: John Wiley & Sons, 2008. 469 p. Citado 5 vezes nas páginas 18, 20, 25, 37 e 43.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied statistics and probability for engineers**. United States of America: John Wiley & Sons, 2010. 792 p. Citado na página 68.

MOOR, J. The dartmouth college artificial intelligence conference: The next fifty years. **Ai Magazine**, v. 27, n. 4, p. 87–87, 2006. Citado na página 41.

MURPHY, J. J. **Technical analysis of the financial markets: A comprehensive guide to trading methods and applications**. New York Institute of Finance: Penguin, 1999. 586 p. Citado 2 vezes nas páginas 18 e 26.

NELSON, D. M.; PEREIRA, A. C.; OLIVEIRA, R. A. de. Stock market's price movement prediction with lstm neural networks. In: IEEE. **2017 International Joint Conference on Neural Networks (IJCNN)**. Anchorage, AK, USA, 2017. p. 1419–1426. Citado 6 vezes nas páginas 39, 40, 46, 47, 49 e 56.

OLAH, C. Understanding lstm networks, 2015. URL <http://colah.github.io/posts/2015-08-Understanding-LSTMs>, 2015. Citado 5 vezes nas páginas 44, 45, 46, 82 e 83.

ORIANI, F. B.; COELHO, G. P. Evaluating the impact of technical indicators on stock forecasting. In: IEEE. **2016 IEEE Symposium Series on Computational Intelligence (SSCI)**. Athens, Greece, 2016. p. 1–8. Citado 2 vezes nas páginas 38 e 40.

PARAS, M. K.; PAL, R.; EKWALL, D. Systematic literature review to develop a conceptual framework for a reuse-based clothing value chain. **The International Review of Retail, Distribution and Consumer Research**, Taylor & Francis, v. 28, n. 3, p. 231–258, 2018. Citado na página 27.

PINTO, É. A. N.; SCHNITMAN, L.; REIS, R. A. A fuzzy based recommendation system for stock trading. In: SPRINGER. **North American Fuzzy Information Processing Society Annual Conference**. Salvador, Brazil, 2018. p. 324–335. Citado 2 vezes nas páginas 38 e 40.

PODSIADŁO, M.; RYBIŃSKI, H. Rough sets in economy and finance. In: **Transactions on Rough Sets XVII**. [S.l.]: Springer, 2014. p. 109–173. Citado na página 38.

RADEEROM, M. Building a trade system by genetic algorithm and technical analysis for thai stock index. In: SPRINGER. **Asian Conference on Intelligent Information and Database Systems**. Pathumtani, Thailand, 2014. p. 414–423. Citado 2 vezes nas páginas 38 e 40.

RODRÍGUEZ-GONZÁLEZ, A.; GARCÍA-CRESPO, Á.; COLOMO-PALACIOS, R.; IGLESIAS, F. G.; GÓMEZ-BERBÍS, J. M. Cast: Using neural networks to improve trading systems based on technical analysis by means of the rsi financial indicator. **Expert systems with Applications**, Elsevier, v. 38, n. 9, p. 11489–11500, 2011. Citado 2 vezes nas páginas 38 e 40.

ROTELA, P. J.; PAMPLONA, E. d. O.; SALOMON, F. L. R. Portfolio optimization: efficiency analysis. **Revista de Administração de Empresas**, SciELO Brasil, v. 54, n. 4, p. 405–413, 2014. Citado na página 16.

SETH, S. Basics of algorithmic trading: Concepts and examples. In: INVESTOPEDIA. **Algorithmic Trading**. 2020. Disponível em: <<https://www.investopedia.com/articles/active-trading/101014/basics-algorithmic-trading-concepts-and-examples.asp>>. Acesso em: 27 de ago. 2020. Citado 2 vezes nas páginas 17 e 19.

\_\_\_\_\_. The world of high-frequency algorithmic trading. In: INVESTOPEDIA. **Algorithmic Trading**. 2020. Disponível em: <<https://www.investopedia.com/articles/investing/091615/world-high-frequency-algorithmic-trading.asp>>. Acesso em: 27 de ago. 2020. Citado na página 17.

SEZER, O. B.; OZBAYOGLU, A. M. Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. **Applied Soft Computing**, Elsevier, v. 70, p. 525–538, 2018. Citado 2 vezes nas páginas 39 e 40.

SHARPE, W. F. Mutual fund performance. **The Journal of business**, JSTOR, v. 39, n. 1, p. 119–138, 1966. Citado na página 61.

SI, W.; LI, J.; DING, P.; RAO, R. A multi-objective deep reinforcement learning approach for stock index future's intraday trading. In: IEEE. **2017 10th International Symposium on Computational Intelligence and Design (ISCID)**. Hangzhou, China, 2017. v. 2, p. 431–436. Citado 2 vezes nas páginas 46 e 47.

SI, Y.-W.; YIN, J. Obst-based segmentation approach to financial time series. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 26, n. 10, p. 2581–2596, 2013. Citado 2 vezes nas páginas 18 e 36.

SILVA, T. R.; LI, A. W.; PAMPLONA, E. d. O. Automated trading system for stock index using lstm neural networks and risk management. In: IEEE. **2020 International Joint Conference on Neural Networks (IJCNN)**. WCCI 2020, Glasgow, UK, 2020. p. 1–8. Citado 2 vezes nas páginas 52 e 53.

SILVER, D.; HUANG, A.; MADDISON, C. J.; GUEZ, A.; SIFRE, L.; DRIESSCHE, G. V. D.; SCHRITTWIESER, J.; ANTONOGLU, I.; PANNEERSHELVAM, V.; LANCTOT, M. *et al.* Mastering the game of go with deep neural networks and tree search. **nature**, Nature Publishing Group, v. 529, n. 7587, p. 484–489, 2016. Citado na página 42.

SYU, J.-H.; WU, M.-E.; LEE, S.-H.; HO, J.-M. Modified orb strategies with threshold adjusting on taiwan futures market. In: IEEE. **2019 IEEE Conference on Computational Intelligence for Financial Engineering & Economics (CIFER)**. Shenzhen, China, 2019. p. 1–7. Citado na página 61.

TEIXEIRA, L. A.; OLIVEIRA, A. L. I. D. A method for automatic stock trading combining technical analysis and nearest neighbor classification. **Expert systems with applications**, Elsevier, v. 37, n. 10, p. 6885–6890, 2010. Citado 6 vezes nas páginas 18, 19, 38, 40, 41 e 49.

TROIANO, L.; VILLA, E. M.; LOIA, V. Replicating a trading strategy by means of lstm for financial industry applications. **IEEE transactions on industrial informatics**, IEEE, v. 14, n. 7, p. 3226–3234, 2018. Citado na página 47.

TVERSKY, A.; KAHNEMAN, D. Judgment under uncertainty: Heuristics and biases. **science**, American association for the advancement of science, v. 185, n. 4157, p. 1124–1131, 1974. Citado 3 vezes nas páginas 19, 20 e 47.

VANSTONE, B.; FINNIE, G. An empirical methodology for developing stockmarket trading systems using artificial neural networks. **Expert systems with Applications**, Elsevier, v. 36, n. 3, p. 6668–6680, 2009. Citado 3 vezes nas páginas 18, 19 e 25.

\_\_\_\_\_. Enhancing stockmarket trading performance with anns. **Expert Systems with Applications**, Elsevier, v. 37, n. 9, p. 6602–6610, 2010. Citado na página 49.

WANG, J.-Z.; WANG, J.-J.; ZHANG, Z.-G.; GUO, S.-P. Forecasting stock indices with back propagation neural network. **Expert Systems with Applications**, Elsevier, v. 38, n. 11, p. 14346–14355, 2011. Citado 3 vezes nas páginas 36, 38 e 40.

WANG, X.; FANG, Z.; SUN, X. Usage patterns of scholarly articles on web of science: a study on web of science usage count. **Scientometrics**, Springer, v. 109, n. 2, p. 917–926, 2016. Citado na página 27.

WHITE, H. Economic prediction using neural networks: The case of ibm daily stock returns. In: IEEE. **IEEE 1988 International Conference on Neural Networks**. San Diego, CA, USA, 1988. p. 451–458. Citado na página 38.

WORLD BANK. **SEMIANNUAL REPORT OF THE LATIN AMERICA AND CARIBBEAN REGION- The Economy in the Time of Covid-19**. 2020. 64 p. Citado na página 16.

WORLD HEALTH ORGANIZATION - WHO. **WHO Director-General’s opening remarks at the media briefing on COVID-19 - 11 March 2020**. 2020. Disponível em: <<https://www.who.int/dg/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>>. Acesso em: 14 de abr. 2020. Citado na página 16.

WU, Y.-p.; MAO, J.-m.; LI, W.-f. Predication of futures market by using boosting algorithm. In: IEEE. **2018 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)**. Chennai, India, 2018. p. 1–4. Citado 3 vezes nas páginas 38, 39 e 40.

ZHOU, F.; ZHANG, Q.; SORNETTE, D.; JIANG, L. Cascading logistic regression onto gradient boosted decision trees for forecasting and trading stock indices. **Applied Soft Computing**, Elsevier, v. 84, p. 105747, 2019. Citado 3 vezes nas páginas 38, 39 e 40.

# APÊNDICE A – Aspectos técnicos acerca da rede LSTM

Neste apêndice é apresentado um passo a passo sobre o funcionamento de uma célula de memória LSTM baseado nos estudos de Hochreiter e Schmidhuber (1997), Greff *et al.* (2016) e no detalhamento fornecido por Olah (2015). Primeiramente, a Figura 28 e as Equações A.1 - A.6 apresentam elementos que devem ser elucidados. Os retângulos amarelos representam a camada neural contendo uma função de ativação, onde  $S$  é a função *sigmoid* ( $\sigma$ ) e o *tanh* a *tanh function*. Quanto aos portões,  $f_t$  é o *forget gate*,  $i_t$  é o *input gate* e  $o_t$  é o *output gate*. A unidade de *bias* é representada por  $b$ . Cada vetor de segmento de reta transporta informações, sendo os encontros as concatenações e bifurcações as cópias. Por fim os círculos representam os operadores matemáticos indicados dentro. Todo este processamento ocorre em cada célula de memória A.

Uma vez que a  $\sigma$  retorna valores entre 0 e 1, os valores zeros serão esquecidos, enquanto valores 1 irão fluir pela célula de memória. Esta representação matemática é mostrada no  $f_t$ , Equação A.1. Conforme mostrado, a informação nos vetores  $x_t$  e  $h_{t-1}$  serão concatenadas, multiplicadas pelo peso  $W_f$  e depois adicionadas a respectiva  $b$ , para então, o resultado final ser submetido a  $\sigma$  que decidirá se o valor será esquecido ou transportado. Caso o valor seja maior que um, será multiplicado ao vetor  $C_{t-1}$ , fluindo pela linha horizontal superior de A, caso contrário, será descartado. De forma análoga ocorre o cálculo das unidades  $i_t$ , Equação A.2, e  $c_t$ , Equação A.3, com seus respectivos pesos e bias, porém, utilizando a *tanh function* em  $c_t$ . Nesta etapa, o parâmetro  $c_t$  fornece prováveis informações que basicamente poderão substituir a informação esquecida anteriormente. A multiplicação de  $i_t$  por  $c_t$  é transportada ao vetor horizontal onde será somada a multiplicação de  $C_{t-1}$  por  $f_t$  para  $C_t$ , Equação A.4. Semelhantemente, ocorre o cálculo do portão  $o_t$  na Equação A.5, que será multiplicado pelo valor correspondente ao vetor  $C_t$ , por sua vez submetido a *tanh function*, compondo assim a Equação A.6 que permitirá a cópia da informação final para duas saídas distintas. Todo este complexo processamento de dados ocorre milhares de vezes, porém de forma eficiente, permitindo a facilidade do resgate de informações relevantes em dado momento.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (\text{A.1})$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (\text{A.2})$$

$$c_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (\text{A.3})$$

$$C_t = f_t \times C_{t-1} + i_t \times c_t \quad (\text{A.4})$$

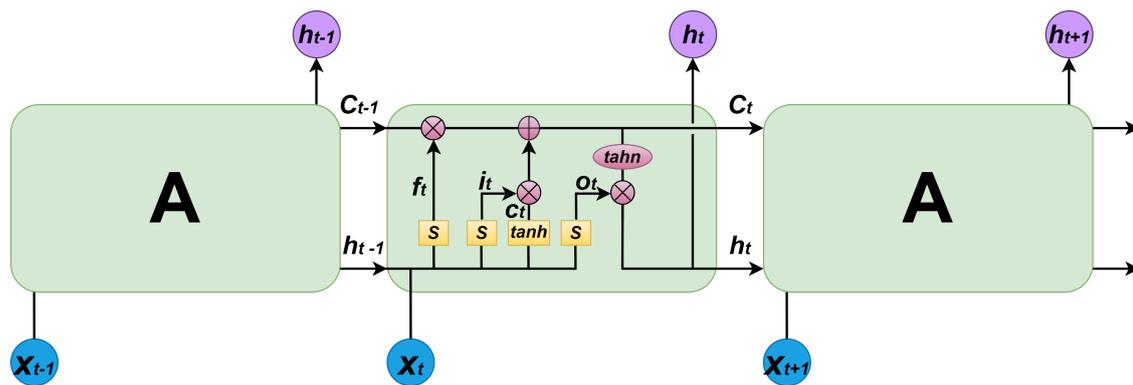


Figura 28 – Rede *Long short-term memory*  
 Fonte: Adaptada de (GREFF *et al.*, 2016; OLAH, 2015).

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \tag{A.5}$$

$$h_t = o_t \times \tanh(C_t) \tag{A.6}$$

## APÊNDICE B – Operações em conta real

B.1 Operação do dia 22 de abril de 2020

B.1.1 *Take Profit - 1 Gain*



Figura 29 – Compra pendurada  
 Fonte: Elaboração própria.

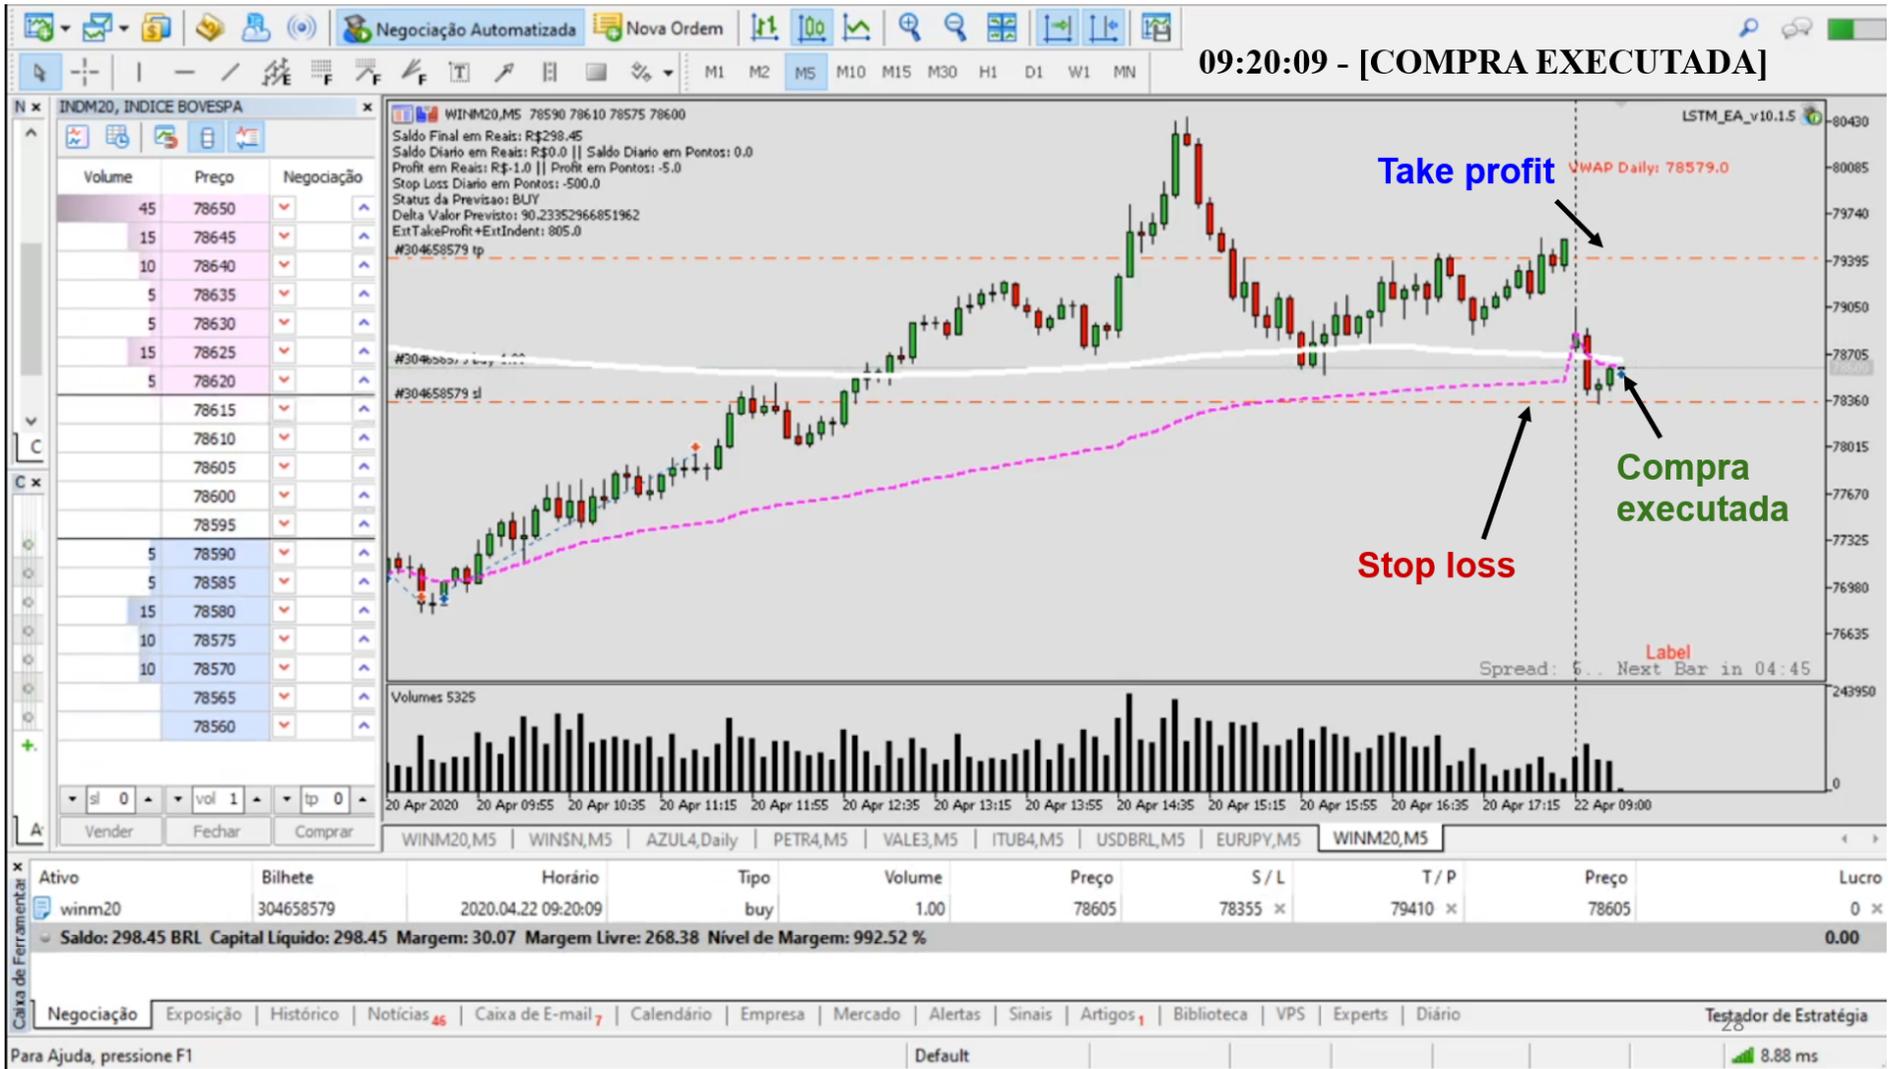


Figura 30 – Compra executada  
 Fonte: Elaboração própria.



Figura 31 – Break-even acionado  
 Fonte: Elaboração própria.



Figura 32 – Trailing Stop acionado  
 Fonte: Elaboração própria.



Figura 33 – TP e *slippage* apresentados  
 Fonte: Elaboração própria.

## B.2 Operação do dia 20 de abril de 2020

### B.2.1 1 *Stop* e 1 *Gain*



Figura 34 – Compra executada

Fonte: Elaboração própria.



Figura 35 – SL acionado  
Fonte: Elaboração própria.



Figura 36 – Compra pendurada  
 Fonte: Elaboração própria.



Figura 37 – Break-even acionado

Fonte: Elaboração própria.



Figura 38 – Trailing Stop acionado  
 Fonte: Elaboração própria.



Figura 39 – Segundo *Trailing Stop* acionado  
 Fonte: Elaboração própria.



Figura 40 – TP e slippage apresentados

Fonte: Elaboração própria.

## B.3 Operação do dia 23 de abril de 2020

### B.3.1 1 *Trailing* - 1 *Stop*



Figura 41 – Compra pendurada  
 Fonte: Elaboração própria.



Figura 42 – Break-even acionado

Fonte: Elaboração própria.



Figura 43 – Trailing Stop acionado  
 Fonte: Elaboração própria.



Figura 44 – Stop acionado

Fonte: Elaboração própria.



Figura 45 – Venda pendurada  
 Fonte: Elaboração própria.



Figura 46 – SL e slippage apresentados  
 Fonte: Elaboração própria.

## B.4 Operação do dia 24 de abril de 2020

### B.4.1 1 *Loss* com *Spread*



Figura 47 – Compra pendurada  
Fonte: Elaboração própria.



Figura 48 – Movimentando ordem de compra

Fonte: Elaboração própria.



Figura 49 – Compra executada

Fonte: Elaboração própria.

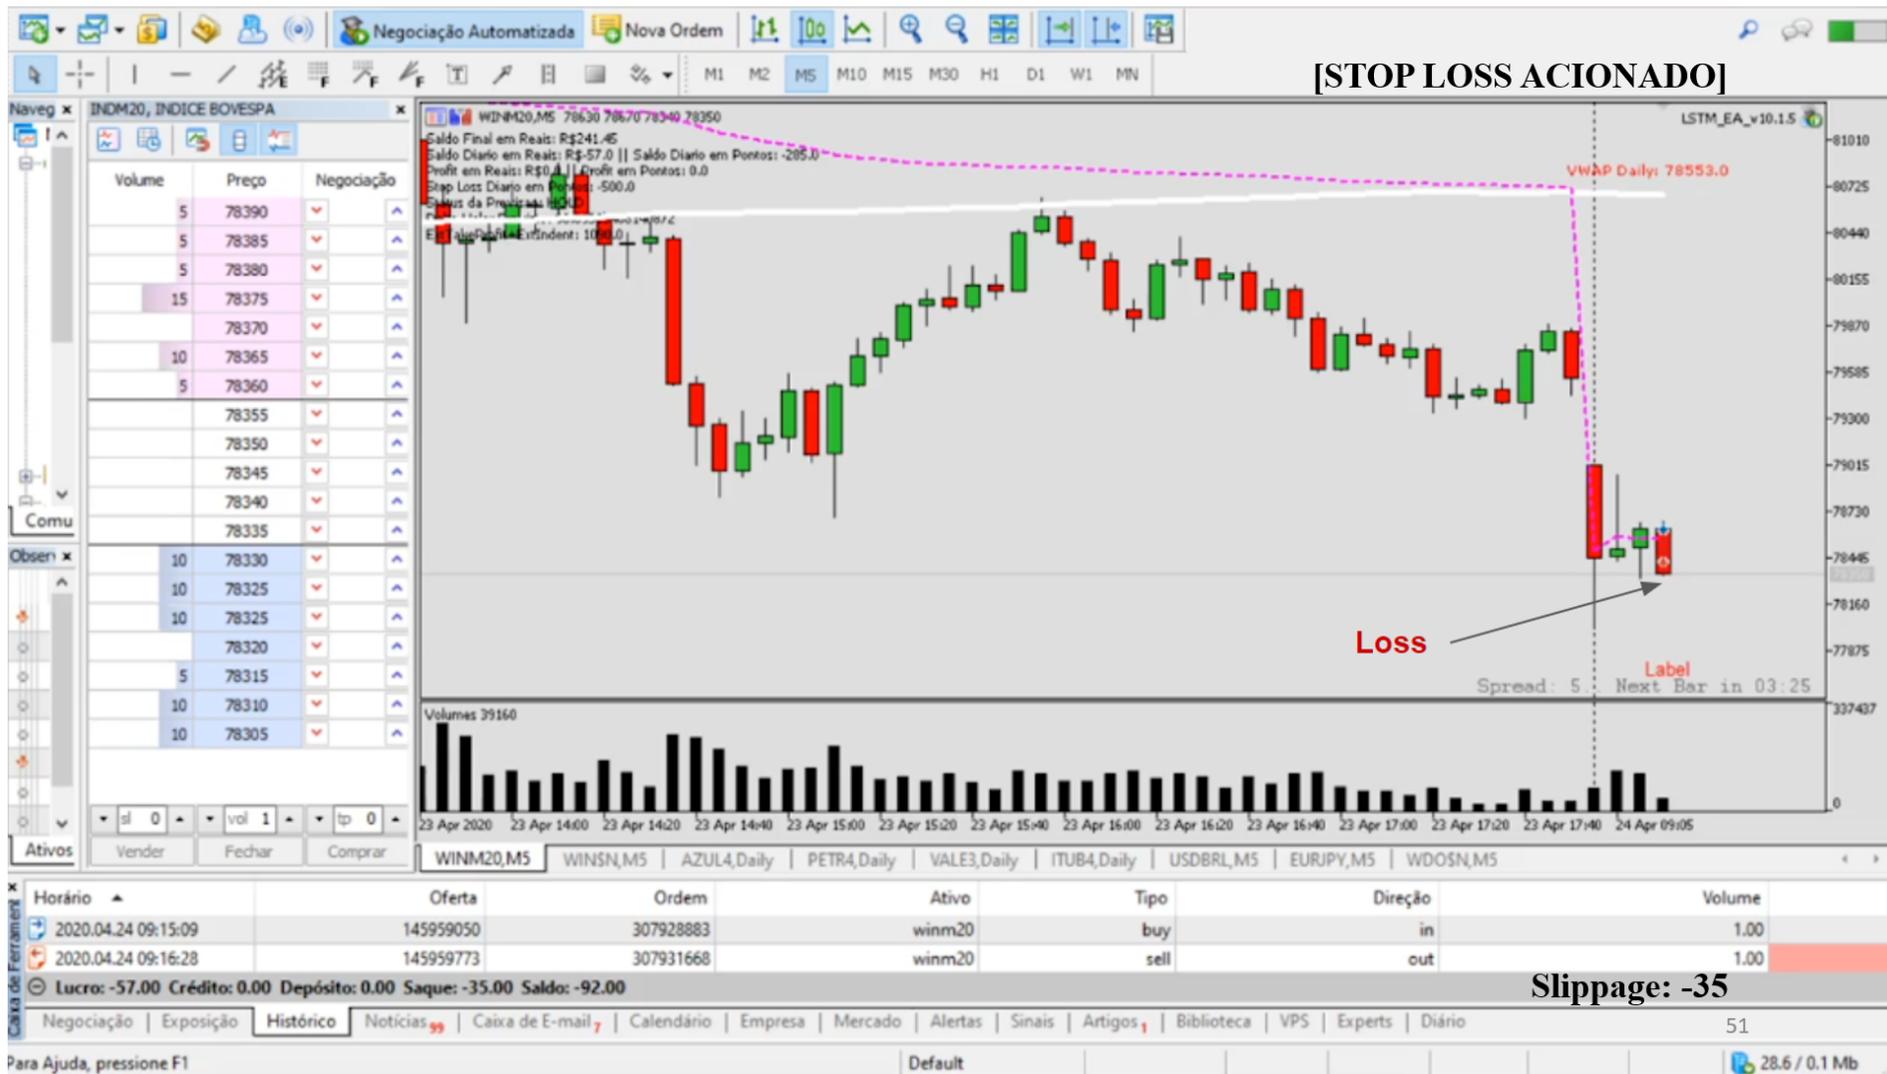


Figura 50 – SL acionado  
Fonte: Elaboração própria.



Figura 51 – Segunda compra executada

Fonte: Elaboração própria.



Figura 52 – Segundo SL acionado  
Fonte: Elaboração própria.

## B.5 Primeira tentativa de operação na real, 09 de março de 2020

### B.5.1 *Circuit breaker*



Figura 53 – Compra executada com TP

Fonte: Elaboração própria.



Figura 54 – TP e alto *slippage* diário apresentado  
 Fonte: Elaboração própria.

# ANEXO A – Artigo publicado

Conferences > 2020 International Joint Conf... 

## Automated Trading System for Stock Index Using LSTM Neural Networks and Risk Management

Publisher: IEEE

Cite This

 PDF

Thalita R. Silva ; Audeliano W. Li ; Edson O. Pamplona [All Authors](#)

123  
Full  
Text Views



### Abstract

#### Document Sections

- I. Introduction
- II. Background and Related Work
- III. Methodology
- IV. Experimental Results
- V. Conclusion

#### Authors

#### Figures

#### References

#### Keywords

#### Metrics

#### Footnotes

### Abstract:

Financial time series predictions are a challenge due to their nonlinear and chaotic nature. In recent decades, many researchers and investors have studied methods to improve quantitative analysis. In the field of artificial intelligence, sophisticated machine learning techniques, such as deep learning showed better performance. In this paper, an automated trading system is built to predict future trends of stock index prices. Using an LSTM-based agent to learn temporal patterns in the data, the algorithm triggers automatic trades according to the historical data, technical analysis indicators, and risk management. The results demonstrate that the proposed method, called LSTM-RMODV, shows better performance when compared with other methods, including the buy-and-hold technique. The proposed method also works in bear or bull market conditions, showing a rate over net income based on invested capital of 228.94%. That is, despite the low accuracy, the algorithm is capable of generating consistent profits when all the transaction costs are considered.

**Published in:** [2020 International Joint Conference on Neural Networks \(IJCNN\)](#)

**Date of Conference:** 19-24 July 2020

**INSPEC Accession Number:** 20006098

**Date Added to IEEE Xplore:** 28 September 2020

**DOI:** [10.1109/IJCNN48605.2020.9207278](#)

► **ISBN Information:**

**Publisher:** IEEE

► **ISSN Information:**

**Conference Location:** Glasgow, United Kingdom, United Kingdom

### I. Introduction