RESSALVA

Atendendo solicitação do autor,
o texto completo desta tese será
disponibilizado somente a partir
de 17/02/2025

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de São José do Rio Preto

Rodrigo Koiti Ishizaka

Validação estatística da retração de Fibonacci para a seleção de carteira

São José do Rio Preto
2023

Rodrigo Koiti Ishizaka

Validação estatística da retração de Fibonacci para a seleção de carteira

Tese apresentada como parte dos requisitos para obtenção do título de Doutor em Matemática, junto ao Programa de Pós-Graduação em Matemática, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista "Júlio de Mesquita Filho", Câmpus de São José do Rio Preto.

Orientador: Prof. Dr. Geraldo Nunes Silva

Financiadora: CAPES

São José do Rio Preto
2023

I79v

Ishizaka, Rodrigo Koiti
Validação estatística da retração de Fibonacci para a seleção de carteira / Rodrigo Koiti Ishizaka. -- São José do Rio Preto, 2023
144 p.

Tese (doutorado) - Universidade Estadual Paulista (Unesp), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto
Orientador: Geraldo Nunes Silva

1. Applied mathematics. 2. Algoritmos. 3. Stocks Prices. 4. Otimização matemática. 5. Investimentos. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca do Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

Rodrigo Koiti Ishizaka

Validação estatística da retração de Fibonacci para a seleção de carteira

Tese apresentada como parte dos requisitos para obtenção do título de Doutor em Matemática, junto ao Programa de Pós-Graduação em Matemática, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista "Júlio de Mesquita Filho", Câmpus de São José do Rio Preto.

Financiadora: CAPES

Comissão Examinadora

Prof. Dr. Geraldo Nunes Silva
Orientador

Prof. Dr. Maurílio Boaventura
Departamento de Matemática - UNESP - São José do Rio Preto

Prof. Dr. Silvio Alexandre de Araujo
Departamento de Matemática - UNESP - São José do Rio Preto

Prof. Dr. Flávio Luiz de Moraes Barboza
FAGEN - UFU - Uberlândia

Prof. Dr. Vanderlei Bonato
CCMC-ICMC - USP - São Carlos

São José do Rio Preto
17 de fevereiro de 2023

Dedico aos meus pais e a mim.

AGRADECIMENTOS

Agradeço primeiramente à Deus, por ter me guiado e iluminado durante toda esta jornada.

Agradeço à minha família e em especial aos meus pais, Inês e Seiji, e ao meu irmão, Renato, que sempre foram essenciais na minha vida e o principal motivo por eu ter chegado até aqui. Obrigado por sempre estarem presentes me dando todo o suporte possível para que este sonho, e não só meu, se tornasse realidade. Obrigado por não medirem esforços, apesar da distância e das minhas inseguranças, por me incentivarem e, principalmente, por acreditarem em mim.

Agradeço, em especial, ao meu orientador Dr. Geraldo Nunes Silva por todo o suporte ao longo do doutorado. Agradeço todo o conhecimento compartilhado, conversas motivadoras, disponibilidade e empenho. Obrigado por acreditar na minha capacidade e por ser uma pessoa e profissional incrível. Sempre digo que sou privilegiado e que eu não poderia ter tido orientador melhor nesta etapa da minha vida.

Agradeço ao professor Dr. Flávio Barboza, Dr. Maurílio Boaventura, Dr. Silvio Araujo e Dr. Vanderlei Bonato por aceitarem o convite para compor a banca examinadora e contribuírem para o desenvolvimento deste trabalho. Agradeço também aos demais professores da instituição no qual tive contato e que também colaboraram com a minha formação.

Agradeço aos meus amigos da matemática aplicada e da vida por toda conversa, incentivo, desabafo e confraternizações: Eduardo Machado, Fabiola Villanueva, Gislaine Melega, Isadora Camillo, Júnior Augusto, Luana Lima, Mijael Hancco, Nicolas Assis, Paola Aquino, Rodrigo Barbosa, Thallis Machado, Valdir Mendes e Yen. Em especial, os meus agradecimentos ao Gustavo Marcato, Jennifer Borges e Karina Rampazzi, por confiar e sempre me apoiar em tudo, por me acolherem e por estarem presentes em todos os momentos. São pessoas incríveis que carrego em meu coração e continuarei carregando para a vida toda.

Agradeço também, e não menos importante, à minha amiga e parceira de primeiro

ano de doutorado, Camila Oliveira, que mesmo longe, teve a sua marca ao longo desses anos. Uma das primeiras pessoas a me acolher, vizinha, amiga e dona de um coração incrível, minha eterna gratidão.

Agradeço aos meus colegas e amigos, Ana Livia Rodero, Anderson Gonzaga, André Antunes, André Carvalho, Elaine Tavares, Eliton Moro, Jarne Donizetti, Heloísa Lopes, Livea Esteves, Otávio Perez, Plínio Sicuti, Ronísio Ribeiro, Samuel Paulino e Yino Carranza por todos os cafés, almoços, jogos e todo meio de distração ao longo desses anos.

Agradeço aos meus alunos e atualmente amigos, em especial à Beatriz, Eduardo, Fernanda, Larissa, Matheus, Milena, Mini, Pedro, Thaynara, Thiago e demais. Fizeram do Ibilce um lugar mais especial e acolhedor.

Agradeço aos amigos que tive o prazer de conhecer em Rio Preto, Arthur Belão e Eduardo Schäefer. Obrigado por todos os momentos fora da universidade. Foram essenciais tê-los comigo.

Agradeço aos meus amigos de mestrado Beatriz Carreira, Enrico Ambrósio, Jéssica Ventura, Leticia Berlandi, Letícia Silva, Marcos Viana, e Rafael Sterza. Agradeço, em especial, ao Laison Furlan e Maycon Calixto por todo o apoio e por sempre acreditarem quando nem eu mesmo acreditava. Palavras de incentivo nunca faltaram e se cheguei até aqui foi porque tive o prazer de conhecê-los.

Agradeço às minhas amigas de graduação que jamais me abandonaram, mesmo com toda a distância e as vendo pouquíssimo: Andressa Santos, Bruna Nascimento, Camila Leme e Elís Olivia. Grato, por tudo.

Agradeço aos meus amigos de infância e da vida: Bárbara Kushikawa, Beatriz Oliveira, Bruna Kushikawa, Caio Michelon, Camila Lima, Danilo Marcondes, Evander Girardi, Francieli Calderan, Francielli Okida, Igor Corrêa, Karine Calefi, Larissa Marques, Leonardo Baldim, Mirella Braga, Nathalia Fonseca, Paula Eduarda, Paula Franzini, Thaís Silvério e Yasmim Moreira por todo o apoio das mais variadas formas. Um agradecimento especial à Mayra Braga por ser a melhor, ser esse poço de intensidade e zelo e por sempre se preocupar comigo, à Luana Novais por ser essa pessoa incrível e a que mais incentiva as pessoas ao seu redor, e isso não foi diferente comigo (agradeço também a disponibilidade de sua máquina, dedico este trabalho também a você), ao João Marcelo e Tifany Mezenes por todo o cuidado e por estarem sempre

presentes e dispostos a deixar os dias de qualquer um mais leve e, por último, ao Leonardo Mello por todos os momentos e apoio nesse período que foi tão difícil. Vocês são essenciais e agradeço todos os dias por isso.

Agradeço ao IBILCE, por me proporcionar momentos tão maravilhosos e inesquecíveis, mesmo passando por momentos difíceis. À todos os servidores que tive contato, minha gratidão.

Agradeço ao Departamento de Matemática e Computação da UNESP, campus de Presidente Prudente, pela oportunidade de atuar no meio acadêmico como professor bolsista.

Agradeço à OBMEP por possibilitar o amparo financeiro, fornecido pela CAPES, ao longo de toda a minha formação.

Por fim, agradeço a todos que contribuíram, de forma direta ou indireta, para que este sonho fosse possível. Foi uma longa jornada e jamais conseguiria sem cada um de vocês.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

Nesta tese é apresentado um algoritmo baseado na análise técnica, principalmente na Retração de Fibonacci, com o objetivo de comprovar a sua eficiência no mercado de ações do Brasil. Esta ferramenta tem sido utilizada com frequência por investidores, entretanto existem poucos trabalhos na literatura que a avaliam. O desenvolvimento da estratégia consiste fortemente na identificação de uma reversão de tendência, o que é muito importante dado que o mais adequado é operar no início de uma tendência, e identificação de níveis de Fibonacci, que funcionam como *stop loss* e *take profit*. A estratégia é avaliada em 50 ativos que compõem principalmente o índice Ibovespa e validada através de testes estatísticos, o que é comprovada, a nível de 5%, que esta apresenta acurácia média de 67,37%. Outra abordagem proposta aqui é resolver um problema de programação linear binária para a seleção de uma carteira com restrição de cardinalidade baseada na estratégia desenvolvida. A composição da carteira só é alterada quando ativos que a compõem atingem níveis de preços estabelecidos por níveis de Fibonacci. Resultados empíricos, fora da amostra, revelam que a estratégia apresenta uma alta rentabilidade superando o índice Ibovespa e algumas outras presentes na literatura.

Palavras-chave: Algoritmo. Retração de Fibonacci. Análise Técnica. Seleção de carteira. Índice Ibovespa.

ABSTRACT

This thesis presents an algorithm based on technical analysis, mainly Fibonacci Retracement, with the aim to prove its efficiency in the Brazilian stock market. This tool has been frequently used by investors, however there are few works in the literature that evaluate it. The strategy development consists strongly in identifying a trend reversal, which is very important given that the most appropriate is to trade at the beginning of a trend, and identifying Fibonacci levels, which work as stop loss and take profit. The strategy is evaluated in 50 assets that compose mainly the Ibovespa index and validated through statistical tests, which is proven, at the 5% level, that it presents an average accuracy of 67.37%. Another approach proposed here is to solve a binary linear programming problem for portfolio selection with cardinality restriction based on the developed strategy. The portfolio composition is only changed when the assets that compose it reach levels established by Fibonacci levels. Empirical results, out-of-sample, reveal that the strategy presents a high profitability outperforming the Ibovespa index and some others present in the literature.

Keywords: Algorithm. Fibonacci retracement. Technical analysis. Portfolio selection. Ibovespa index.

Lista de Figuras

2.1 Atributos do *candlestick*. 30
2.2 Identificação de topos e fundos. 31
2.3 Rompimento de suporte. 32
2.4 Rompimento de resistência. 32
2.5 Sinal de reversão: martelo. 33
2.6 Sinal de reversão: envolvente. 33
2.7 Sinal de reversão: estrela. 34
2.8 Retração de Fibonacci. 37
2.9 Retração de Fibonacci invertida. 38
2.10 Região crítica para o teste de hipótese. 44

4.1 Fundo e topo identificados por *candle sticks*. 56
4.2 Sequência de fundos e topos significativos para identificação de uma tendência de baixa. 57
4.3 Identificação de uma reversão de alta com o rompimento de um topo significativo. 58
4.4 Identificação de uma reversão de baixa com o rompimento de um fundo significativo. 58
4.5 Formação de um Fibonacci de grau 1. 60
4.6 Formação de um Fibonacci de grau 2. 62
4.7 Formação de um Fibonacci de grau 3. 62
4.8 Fibonacci de grau 3 atingindo o *stop loss*. 63
4.9 Indicação da posição dos *candlesticks* para identificação de abertura de ordens. 65

5.1 Modelos de gerenciamento de ordens. 104
5.2 Retorno acumulado dos ativos pertecentes ao grupo A. 106
5.3 Retorno acumulado dos ativos pertecentes ao grupo B. 106
5.4 Retorno acumulado dos ativos pertecentes ao grupo C. 107
5.5 Retorno acumulado dos ativos pertecentes ao grupo D. 107
5.6 Comparação entre a estratégia operando em um único ativo e IBOV no intervalo II. 110
5.7 Comparação entre a estratégia operando em um único ativo e IBOV no intervalo III. 111
5.8 Comparação do retorno acumulado entre a estratégia C1 x C5 x IBOV no intervalo II. 115
5.9 Comparação do retorno acumulado entre a estratégia C1 x C5 x IBOV no intervalo III. 116

5.10 Comparação do retorno acumulado entre a estratégia C1 x C5 x IBOV no intervalo IV. 117
5.11 Comparação do retorno acumulado entre a estratégia C1 x C5 x IBOV no intervalo V. 118
5.12 Comparação do retorno acumulado entre a estratégia C5 x IBOV no intervalo de forward. 121

Lista de Tabelas

2.1 Razão entre o atual e antecessor para a verificação de ϕ. 35
2.2 Tabela de erro para o teste de hipótese. 42
2.3 Conclusão do teste de hipótese. 44

4.1 Relação entre retração e alvo para a retração de Fibonacci invertida. 61
4.2 Posição de abertura de ordens para cada modelo. 66
4.3 Classificação da Tendência 69
4.4 Definição de Intervalos dos Dados. 78

5.1 Probabilidade conjunta de dois ativos. 81
5.2 $QR_{min} = 1$ para MGT1. 83
5.3 $QR_{min} = 2$ para MGT1. 83
5.4 $QR_{min} = 3$ para MGT1. 83
5.5 $QR_{min} = 4$ para MGT1. 83
5.6 $QR_{min} = 5$ para MGT1. 84
5.7 $QR_{min} = 6$ para MGT1. 84
5.8 $QR_{min} = 7$ para MGT1. 84
5.9 $QR_{min} = 8$ para MGT1. 84
5.10 $QR_{min} = 9$ para MGT1. 85
5.11 $QR_{min} = 10$ para MGT1. 85
5.12 $QR_{min} = 11$ para MGT1. 85
5.13 $QR_{min} = 12$ para MGT1. 85
5.14 $QR_{min} = 11$ para MGT2. 86
5.15 $QR_{min} = 11$ para MGT3. 86
5.16 $QR_{min} = 9$ para MGT. 87
5.17 Divisão de grupos de ativos. 87
5.18 $QR_{min} = 1$, Grupo A. 88
5.19 $QR_{min} = 2$, Grupo A. 88
5.20 $QR_{min} = 3$, Grupo A. 88
5.21 $QR_{min} = 4$, Grupo A. 88
5.22 $QR_{min} = 5$, Grupo A. 89
5.23 $QR_{min} = 6$, Grupo A. 89
5.24 Acurácia e quantidade de Fibonacci para a variação de QR_{min} e $S_{max} = 1.0$ para o Grupo A. 89
5.25 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 1$ para o Grupo A. 90
5.26 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 1$ para os Subgrupos de A. 90
5.27 Acurácia final de MT2 para o Grupo A. 91

5.28 Comparação das duas modelagens propostas para o grupo A. 91
5.29 Comparação dos modelos de treinamento para M ativos. 92
5.30 Fase de validação para M ativos para MT2. 92
5.31 Classificação dos ativos, parte I. 93
5.32 Classificação dos ativos, parte II. 94
5.33 Classificação dos ativos, parte III. 95
5.34 Grau de Fibonacci relevantes que permite a operação para cada grupo. . . 95
5.35 Acurácia e quantidade de Fibonacci para a variação de QR_{min} e $S_{max} = 1.0$ para o Grupo A. 96
5.36 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 1$ para o Grupo A. 96
5.37 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 1$ para os Subgrupos de A. 97
5.38 Comparação das duas modelagens propostas para o grupo A. 97
5.39 Acurácia e quantidade de Fibonacci para a variação de QR_{min} e $S_{max} = 1.0$ para o Grupo B. 97
5.40 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 4$ para o Grupo B 98
5.41 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 4$ para os Subgrupos de B. 98
5.42 Comparação das duas modelagens propostas para o grupo B. 98
5.43 Acurácia e quantidade de Fibonacci para a variação de QR_{min} e $S_{max} = 1.0$ para o Grupo C. 99
5.44 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 7$ para o Grupo C. 99
5.45 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 7$ para os Subgrupos de C. 99
5.46 Comparação das duas modelagens propostas para o grupo C. 100
5.47 Acurácia e quantidade de Fibonacci para a variação de QR_{min} e $S_{max} = 1.0$ para o Grupo D. 100
5.48 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 9$ para o Grupo D 100
5.49 Acurácia e quantidade de Fibonacci para a variação de S_{max} e $QR_{min} = 9$ para os Subgrupos de D. 101
5.50 Comparação das duas modelagens propostas para o grupo D. 101
5.51 Comparação dos modelo de treinamento para M ativos. 101
5.52 Fase de validação para M ativos. 102
5.53 Fase de teste no intervalo III, para MT2. 102
5.54 Teste de Hipótese de acordo com os graus de Fibonacci. 104
5.55 Retorno para MGO. 105
5.56 Retorno dos ativos operados individualmente. 108
5.57 Retorno em termos percentuais dos modelos de otimização para a operação de um único ativo no intervalo I. 109
5.58 Análise de retorno e risco para o conjunto de dados II. 110
5.59 Análise de retorno e risco para o conjunto de dados III. 111
5.60 Análise de retorno e risco para o conjunto de dados IV e V. 112
5.61 Retorno em termos percentuais do IBOV e MGC3 para a operação de um único ativo. 112

5.62 Retorno em termos percentuais dos modelos de otimização para a operação de carteira no intervalo I, para CP1. 113
5.63 Retorno em termos percentuais dos modelos de otimização para a operação de carteira no intervalo I para CP2. 113
5.64 Retorno em termos percentuais para a operação de carteira C5. 114
5.65 Comparação entre C1 x C5 x IBOV para o Intervalo II. 115
5.66 Comparação entre C1 x C5 x IBOV para o Intervalo III. 116
5.67 Comparação entre C1 x C5 x IBOV para o Intervalo IV. 117
5.68 Comparação entre C1 x C5 x IBOV para o Intervalo V. 118
5.69 Comparação entre C1 x C5 x IBOV no período de oito anos. 119
5.70 Análise comparativa de trabalhos existentes na literatura. 119
5.71 Análise comparativa em período de pandemia COVID-19 (02/01/2020 a 17/07/2020). 120
5.72 Comparação entre C5 x IBOV para o intervalo de forward. 121

A.1 Lista de ativos para o treinamento da estratégia. 132
A.2 Divisão dos ativos em grupos de acordo com o seu desempenho na aplicação da metodologia. 133
A.3 Nomenclatura dos subgrupos de ativos. 134
A.4 Divisão dos ativos em subgrupos. 135
A.5 Relação dos ativos selecionados com bom desempenho para a metodologia divididos em subgrupos. 136

B.1 Acurácia e quantidade de Fibonacci para variação de QR_{min} e $S_{max} = 1.0$ para o Grupo B. 137
B.2 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 4$ para o Grupo B 137
B.3 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 4$ para os Subgrupos de B. 138
B.4 Acurácia final de MT2 para o Grupo B. 138
B.5 Comparação das duas modelagens propostas para o grupo B. 138
B.6 Acurácia e quantidade de Fibonacci para variação de QR_{min} e $S_{max} = 1.0$ para o Grupo C. 139
B.7 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 7$ para o Grupo C. 139
B.8 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 7$ para os Subgrupos de C. 139
B.9 Acurácia final de MT2 para o Grupo C. 140
B.10 Comparação das duas modelagens propostas para o grupo C. 140
B.12 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 9$ para o Grupo D 141
B.13 Acurácia e quantidade de Fibonacci para variação de S_{max} e $QR_{min} = 9$ para os Subgrupos de D. 141
B.11 Acurácia e quantidade de Fibonacci para variação de QR_{min} e $S_{max} = 1.0$ para o Grupo D. 141
B.14 Acurácia final de MT2 para o Grupo D. 142
B.15 Comparação das duas modelagens propostas para o grupo D. 142
B.16 Acurácia final de MT2 para o Grupo A após a seleção de ativos. 143
B.17 Acurácia final de MT2 para o Grupo B após a seleção de ativos. 143

B.18 Acurácia final de MT2 para o Grupo C após a seleção de ativos. 144
B.19 Acurácia final de MT2 para o Grupo D após a seleção de ativos. 144

Lista de Algoritmos

1 Algoritmo para o gerenciamento de ordens. 67
2 Algoritmo para o cálculo de retorno. 68
3 Algoritmo geral da estratégia de Fibonacci. 70
4 Algoritmo para a Carteira. 76

Lista de Siglas

CP	Conjunto de Parâmetros
CS	Critério de Seleção
ETFs	*Exchange Traded Funds*
HME	Hipótese de Mercados Eficientes
MD	Máximo *Drawdown*
MGC	Modelo de Gerenciamento de Carteira
MGO	Modelo de Gerenciamento de Ordens
MGT	Modelo de Gerenciamento de Tendência
MT	Modelo de Treinamento
PPL	Problema de Programação Linear
RC	Região Crítica

Sumário

1 Introdução **27**

2 Conceitos Preliminares **29**
2.1 Análise Técnica **29**
2.1.1 Aplicações da Sequência de Fibonacci 35
2.2 Estatística **38**
2.3 Carteira **44**

3 Revisão Bibliográfica **47**
3.1 Análise Técnica **47**
3.2 Estratégias **50**
3.3 Carteira **51**

4 Metodologia **55**
4.1 Metodologia Computacional **55**
4.1.1 Pré-processamento dos dados 55
4.1.2 Identificação de uma reversão 56
4.1.3 Formação de Fibonacci 59
4.1.4 Grau do Fibonacci 61
4.1.5 Abertura de ordens 63
4.1.6 Gerenciamento de tendência 68
4.1.7 Aplicação da estratégia 69
4.1.8 Otimização de carteira 71
4.1.9 Medidas de risco 77
4.2 Fundamentação Estatística **77**
4.2.1 Considerações iniciais 77
4.2.2 Conjunto de variáveis aleatórias independentes 78
4.2.3 Fase de treinamento 78
4.2.4 Fase de validação 79
4.2.5 Fase de teste 80
4.2.6 Carteiras 80

5 Resultados **81**
5.1 Independência das variáveis aleatórias **81**
5.2 Modelo de gerenciamento de tendência **82**
5.3 Classificação dos ativos **87**
5.4 Teste de hipótese unilateral para a proporção **103**
5.5 Modelo de gerenciamento de ordens **104**

5.6 Aplicação da estratégia por ativo 105
5.6.1 Análise dos ativos individualmente 105
5.6.2 Análise da operação de um único ativo 108
5.7 Carteira 113
5.7.1 Comparação entre a estratégia e índice Ibovespa 114
5.7.2 Análise comparativa com trabalhos existentes na literatura 119
5.7.3 Forward 120

6 Conclusão 123

Referências 125

Apêndice A Lista de Ativos 131

Apêndice B Resultados Complementares 137

1 Introdução

Ao longo dos anos, cada vez mais, pessoas de todas as faixas etárias, independente de gênero, etnia, religião ou status social, tem aderido ao mercado financeiro. Segundo dados da B3, a quantidade de pessoas que investem na bolsa de valores do Brasil aumentou cerca de 1,5 milhão em um período de um ano, totalizando 4,2 milhões de investidores em 2022. Com isso, segundo Edwards, Magee e Bassetti (1999), a busca para descobrir metodologias seguras para avaliar a tendência do mercado é constante, bem como descobrir qual ação comprar e qual o momento certo de fazê-la.

Após a definição da Teoria Dow, considerada um marco na área de finanças, estudos referentes ao mercado financeiro foram surgindo. De acordo com Fama (1970), dentre os estudos que já existiam, a Hipótese de Mercado Eficientes (HME), considerada um dos estudos centrais da pesquisa científica em finanças e mercado de capitais, que, por sua vez, ressurgiu sob a rúbrica "*theory of random walks*", foi resgatada e ganhou mais atenção após sessenta anos. Fama (1965) descreve esta teoria sugerindo que o preço dos ativos refletem toda informação disponível no mercado e constata que as mudanças de preços são independentes, ou seja, os preços passados não influenciam nos preços futuros. Entretanto, a HME confronta outra área de estudos, a análise técnica, e alguns autores rejeitam, sob algumas condições, esta teoria: Lo e MacKinlay (1988), Frennberg e Hansson (1993), Ayadi e Pyun (1994) , Tabak (2003), Charles e Darné (2009) e Wang, Zhang e Zhang (2015).

Existem diversos estudos referentes a investimentos, basicamente divididos em duas escolas: análise técnica e análise fundamentalista. Baseando-se em uma delas ou na combinação das duas, os investidores criam as suas próprias estratégias de investimentos. Além disso, estas podem ser desenvolvidas para investimentos de curto, médio e longo prazo utilizando algoritmos de aprendizagem de máquina. Com o avanço das tecnologias de informação e a rapidez de transmissão de dados, bem como a análise destes por algoritmos computacionais, é possível implementar estratégias, que são utilizadas pelos investidores através de operações manuais, e fazê-las de forma automatizada.

Apesar de contar com uma diversidade de pessoas que apresentam um perfil de investimento diferente, todos buscam uma ponderação entre uma maior rentabilidade e menor risco. A ideia, então, é oferecer para os investidores a partir de um algoritmo, uma estratégia rentável, com suporte científico, a fim de promover segurança e satisfação dos mesmos. Aqui, é proposta uma estratégia baseada na análise técnica e trabalhos como de Brock, Lakonishok e LeBaron (1992), Osler e Chang (1995) e Neely, Weller e Dittmar (1997) apresentam suporte para esta ferramenta de estudo.

A estratégia desenvolvida, utiliza, principalmente, técnicas para a análise de alvos através da retração de Fibonacci. Tal ferramenta tem sido muito utilizada pelos investidores, entretanto não existem muitos trabalhos na literatura que comprovam a sua eficiência. Isto deve-se ao fato da retração de Fibonacci ser subjetiva, visto que depende de pontos inseridos por diferentes investidores. Tsinaslanidi, Guijarro e Voukelatos (2022) inves-

tigam esta ferramenta e fornecem evidência contra o seu uso, reforçando que diferentes abordagens devem ser adotadas. Para contornar este problema de subjetividade, aqui é proposta como alternativa uma estratégia para a identificação de uma reversão, mostrando que a retração de Fibonacci, ao contrário de Tsinaslanidi, Guijarro e Voukelatos (2022), é eficiente.

O embasamento científico para desenvolver e validar as estratégias de investimentos é realizado através de métodos e estudos estatísticos e utiliza dados históricos de ativos, principalmente de ações da bolsa de valores do Brasil que eram compreendidas no índice Ibovespa no período de estudo, para a sua validação e teste.

Além de desenvolver uma estratégia para operação no mercado financeiro, estudos são realizados através de sua aplicação para diferentes modelos de investimentos. Os estudos se estendem para o problema de seleção de carteira, onde é suposto adquirir um retorno mais alto e menor risco quando comparado com as demais alternativas. Aqui é mostrado que, de fato, isso ocorre.

Assim, o presente trabalho contribui com a criação de um algoritmo capaz de identificar a reversão de uma tendência baseado em conceitos da análise técnica e aplica estratégias para a abertura de ordens e seleção de carteira que auxiliam na tomada de decisão.

A metodologia apresenta performance satisfatória para um conjunto de ativos que foram estudados através da aplicação do algoritmo em dados passados e também para dados coletados em tempo real, sendo esta última possível através da integração entre as plataformas que disponibilizam os dados e de execução. Os resultados obtidos superam trabalhos existentes na literatura e também o *benchmark* Ibovespa, sustentando, então, a geração de um produto rentável que pode ser aplicado no mercado financeiro.

Além disso, contribui com a investigação da retração de Fibonacci no mercado de ações do Brasil cuja validação é dada através de métodos estatísticos. Tal investigação reforça a eficiência deste indicador técnico, bem como também da análise técnica.

Nesta tese, o Capítulo 2 apresenta os conceitos preliminares, principalmente referentes à análise técnica, utilizados para o desenvolvimento do trabalho. O Capítulo 3 traz uma breve revisão bibliográfica sobre o tema, desde o seu surgimento até os trabalhos atuais para a análise técnica e problema de seleção de carteira, já o Capítulo 4 trata de toda a modelagem da estratégia desenvolvida, apresentando de forma detalhada todas as ferramentas utilizadas ao longo da metodologia, principalmente de um ponto de vista computacional. O Capítulo 5 mostra como esta foi validada através de fundamentos estatísticos, bem como as suas considerações iniciais para a validação da metodologia. Além disso, apresenta os resultados obtidos através da aplicação da estratégia em dados históricos ainda não vistos dos ativos no qual foram constatados boa performance, e faz uma análise do risco e retorno anual obtido comparando com outras estratégias propostas na literatura e/ou *benchmark*. Por fim, o Capítulo 6 apresenta as considerações finais deste trabalho.

6 Conclusão

Nesta tese é apresentada como principal contribuição a implementação de um algoritmo capaz de identificar a reversão de uma tendência através de dados do mercado de ações do Brasil, aplicando diferentes estratégias baseadas em conceitos da análise técnica que auxiliam na tomada de decisão. O algoritmo, ainda, contribui para os estudos de seleção de carteira, propondo novas estratégias para a escolha de ativos, apresentando performance satisfatória em dados passados através da aplicação do algoritmo via *backtest* e também para dados coletados em tempo real. Com resultados que superam trabalhos existentes na literatura e também o *benchmark*, fornece ainda um produto que pode ser aplicado no mercado financeiro.

Outra contribuição está na aplicação de indicadores técnicos como a Retração de Fibonacci. Existem muitos trabalhos que relatam e comprovam a relevância da análise técnica, entretanto trabalhos que investigam este indicador são pouco encontrados na literatura. Uma das principais dificuldades de avaliar os níveis de Fibonacci é que estes são subjetivos, isto porque cada investidor pode propor diferentes pontos iniciais para traçar esta técnica e encontrar diferentes níveis de preços para uma mesma proporção de Fibonacci. Para contornar este problema é proposta uma metodologia baseada na identificação de reversão de tendência, no qual tendem a encontrar pontos específicos que, de fato, podem ocorrer uma reversão.

Com a aplicação da estratégia em dados de ações do mercado do Brasil, selecionados em sua maior parte por ativos que compõem o índice Ibovespa, é possível notar um desempenho satisfatório para 50 ativos, dado que a operação é realizada somente quando existe uma consolidação na tendência identificada. A estratégia é validada através de testes estatísticos, provando, a nível de significância de 5%, uma acurácia média de 67,37%. Portanto, o trabalho contribui também com estudos na área da análise técnica, principalmente referente à retração de Fibonacci, considerando o mercado de ações do Brasil para dados de tempo de negociação de 15 minutos.

A partir do desenvolvimento da estratégia, a sua aplicação pode ser realizada de diversas formas. São expostos neste trabalho os seguintes resultados: i) a aplicação de todo o capital disponível em apenas um ativo ao longo de um período especificado; ii) a aplicação de todo o capital disponível em apenas um ativo, sendo este alternado quando um ativo atingir os níveis de Fibonacci definidos como *stop loss* ou alvo do Fibonacci de grau k_{max} de cada ativo; iii) a aplicação de todo o capital distribuídos em cinco ativos que podem ser substituídos da mesma forma que o item anterior, o que formaliza o problema de seleção de carteira. Os dois últimos casos consistem em resolver um problema de programação linear binária com restrição de cardinalidade.

No primeiro caso, verifica-se que pode não haver investimento em todo o período especificado e a rentabilidade pode ser baixa. Diferente do item ii) onde existe investimento em todo o período e com uma rentabilidade maior que i), entretanto o investidor está exposto a um maior risco. Uma forma de contornar este problema é investigar o problema de seleção de carteira. Através dos resultados obtidos em iii) é possível notar que a rentabilidade é ainda maior e pode alcançar um retorno anualizado de 35,17% sendo exposto a um menor risco, como visto na Subseção 5.7.1.

Além disso, a estratégia proposta para o problema de seleção de carteira quando comparada com o índice Ibovespa, supera o *benchmark* em todos os períodos de teste analisados, com

exceção do risco no intervalo II. Embora este seja menor do que o risco obtido pela estratégia, ambos encontram-se bem próximos. E mais, de acordo com trabalhos encontrados na literatura e que envolviam a aplicação de diferentes abordagens utilizando o mercado de ações do Brasil, a estratégia supera todos os trabalhos apresentando uma rentabilidade maior, exceto quando comparada a duas abordagens de Paiva et al. (2019), que por sua vez apresentam um risco maior para ambas, e Conegundes e Pereira (2020).

Portanto, além de propor o desenvolvimento de um algoritmo para operação e seleção de carteira que apresenta alta rentabilidade, este trabalho também contribui na investigação da Retração de Fibonacci no mercado de ações do Brasil, fornecendo evidência, também, para a análise técnica.

Como sugestões de trabalhos futuros destacam-se:

- Busca por uma maior quantidade de ativos para a aplicação da metodologia e aumento da quantidade de ativos que compõem a carteira;
- Aplicação de diferentes problemas de otimização para a seleção de carteira;
- Aplicação e validação da estratégia para diferentes mercados de ações;
- Implementação de *trailing stops*, onde o *stop loss* é modificado quando um dado preço é atingido, com o objetivo de limitar as perdas;
- Aplicação de *deep learning* como proposto por Conegundes e Pereira (2020) para melhorar ainda mais a rentabilidade da metodologia.

Referências

ALHASHEL, B.; ALMUDHAF, F.; HANSZ, J. Can technical analysis generate superior returns in securitized property markets? evidence from east asia markets. *Pacific-Basin Finance Journal*, v. 47, p. 92–108, 2018.

ALLEN, F.; KARJALAINEN, R. Using genetic algorithms to find technical trading rules. *Journal of Financial Economics*, v. 51, p. 245–271, 1999.

ANGHEL, D. A reality check on trading rule performance in the cryptocurrency market: Machine learning vs. technical analysis. *Finance Research Letters*, v. 39, n. 101655, 2021.

ARENALES, M. et al. *Pesquisa operacional*. Rio de Janeiro: Elsevier Editora Ltda, 2011.

ARNONE, S.; LORASCHI, A.; TETTAMANZI, A. A genetic approach to portfolio selection. *Neural Network World*, v. 3, n. 6, p. 597–604, 1993.

ARUN, M. The merton problem with a drawdown constraint on consumption. *working paper*, 2013.

AVRAMOV, D.; KAPLANSKI, G.; SUBRAHMANYAM, A. Moving average distance as a predictor of equity returns. *Review of Financial Economics*, v. 39, n. 2, p. 127–145, 2021.

AYADI, O.; PYUN, C. An application of variance ratio test to the korean securities market. *Journal of Banking and Finance*, v. 18, n. 4, p. 643–658, 1994.

AYALA, J. et al. Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, v. 255, p. 107119, 2021.

BANIK, S. et al. Lstm based decision support system for swing trading in stock market. *Knowledge-Based Systems*, v. 239, n. 107994, 2022.

BARROSO, B.; CARDOSO, R.; MELO, M. Performance analysis of the integration between portfolio optimization and technical analysis strategies in the brazilian stock market. *Expert Systems With Applications,*, v. 186, n. 115687, 2021.

BLUME, L.; EASLEY, D.; O'HARA, M. Market statistics and technical analysis: The role of volume. *The Journal of Finance*, v. 49, n. 1, p. 153–181, 1994.

BOYER, C. *A history of mathematics*. United States of America: John Wiley & Sons, Inc, 1968.

BREEDEN, D. An intertemporal asset pricing model with stochastic consumption and investment opportunities. *Journal of Financial Economics*, v. 7, n. 3, p. 265–296, 1979.

BROCK, W.; LAKONISHOK, J.; LEBARON, B. Simple technical trading rules and the stochastic properties of stock returns. *Journal of Finance*, v. 47, p. 1731–1764, 1992.

BROWN, C. *Fibonacci Analysis: bloomberg market essentials*. United States of America: Bloomberg Press, 2010.

BROWN, D.; JENNINGS, R. On technical analysis. *Review of Financial Studies*, v. 2, p. 527–551, 1989.

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

CHANG, T.-J. et al. Heuristics for cardinality constrained portfolio optimisation. *Computers Operations Research*, v. 27, p. 1271–1302, 2000.

CHARLES, A.; DARNé, O. Variance ratio tests of random walk: An overview. *Journal of Economics Surveys*, v. 23, n. 3, p. 503–527, 2009.

CHARWAND, M.; GITIZADEH, M.; SIANO, P. A new active portfolio risk management for an electricity retailer based on a drawdown risk preference. *Energy*, v. 118, n. 1, p. 387 – 398, 2017.

CHEKHLOV, A.; URYASEV, S.; ZABARANKIN, M. Portfolio optimization with drawdown constraints. *Research report, Department of Industrial and Systems Engineering, University of Florida*, 2000.

CHEN, T.-L.; CHEN, F.-Y. An intelligent pattern recognition model for supporting investment decisions in stock market. *Information Sciences*, v. 346–347, p. 261–274, 2016.

COHEN, G. Algorithmic trading and financial forecasting using advanced artificial intelligence methodologies. *Mathematics, 10: 3302*, 2022.

CONEGUNDES, L.; PEREIRA, A. Beating the stock market with a deep reinforcement learning day trading system. *In Proceedings of the 2020 International Joint Conference on Neural Networks (IJCNN)*, p. 1–8, 2020.

CORREA, S. *Probabilidade e Estatística*. Belo Horizonte: PUC Minas Virtual, 2003.

CORREIA, J. *Operando na Bolsa de Valores utilizando análise técnica*. Brasil: Novatec Editora Ltda, 2008.

DAWSON, E.; STEELEY, J. On the existence of visual technical patterns in the UK stock market. *Journal of Business Finance Accounting*, v. 30, p. 263–293, 2003.

DENG, G.; LIN, W.; LO, C. Markowitz-based portfolio selection with cardinality constraints using improved particle swarm optimization. *Expert Systems with Applications*, v. 39, n. 4, p. 4558–4566, 2012.

EDWARDS, R.; MAGEE, J.; BASSETTI, W. *Technical analysis of the financial markets*. United States of America: CRC Press LLC, 1999. ISBN 0-7352-0066-1.

EVANS, M.; ROSENTHAL, J. *Probability and Statistics: The Science of Uncertainty*. Toronto: University of Toronto, 2009.

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

FAMA, E. Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, v. 5, p. 383–417, 1970.

FIORUCCI, J.; SILVA, G.; BARBOZA, F. Reaction trend system with garch quantiles as action points. *Expert Systems With Applications*, v. 198, n. 116750, 2022.

FREITAS, F.; SOUZA, A.; ALMEIDA, A. Prediction-based portfolio optimization model using neural networks. *Neurocomputing,*, v. 72, n. 10–12, p. 2155–2170, 2009.

FRENNBERG, P.; HANSSON, B. Testing the random walk hypothesis on swedish stock prices: 1919-1990. *Journal of Banking and Finance*, v. 17, n. 1, p. 175–191, 1993.

GAUCAN, V. How to use fibonacci retracement to predict forex market. *Journal of Knowledge Management, Economics and Information Technology*, v. 1, n. 2, p. 2 – 12, 2011.

GLYNN, P.; IGLEHART, D. Trading securities using trailing stops. *Management Science*, v. 41, p. 1096–1106, 1995.

GURRIB, I.; NOURANI, M.; BHASKARAN, R. Energy crypto currencies and leading us energy stock prices: are fibonacci retracements profitable? *Financial Innovation*, v. 8, n. 1, p. 1–27, 2022.

HASSANNIAKALAGER, A.; SERMPINIS, G.; STASINAKIS, C. Trading the foreign exchange market with technical analysis and bayesian statistics. *Journal of Empirical Finance*, v. 63, p. 230–251, 2021.

HU, W. et al. A formal approach to candlestick pattern classification in financial time series. *Applied Soft Computing*, v. 84, n. 105700, 2019.

HUDSON, R.; URQUHART, A. Technical trading and cryptocurrencies. *Annals of Operations Research*, v. 297, n. 1, p. 191–220, 2021.

INVESTING. Investing.com. c2007-2023. Disponível em: <https://br.investing.com/equities/>. Acesso em: 17 de mar. 2021.

JARDINE, M. *Charting Techniques, Strategies and Simple Applications*. Columbia: Marketplace Books, 2003. ISBN 1-59280-061-0.

JEARANAITANAKIJ, K.; PASSAYA, B. Predicting short trend of stocks by using convolutional neural network and candlestick patterns. In: 2019 4th international conference on information technology (InCIT). IEEE, p. 159–162, 2019.

JENSEN, M.; BENINGTON, G. Random walks and technical theories: Some additional evidence. *Journal of Finance*, v. 25, n. 2, p. 469–482, 1970.

JEON, J.; OH, J. Finite horizon portfolio selection problem with a drawdown constraint on consumption. *Journal of Mathematical Analysis and Applications*, v. 506, n. 125542, 2021.

JEON, J.; PARK, K. Portfolio selection with drawdown constraint on consumption: a generalization model. *Mathematical Methods of Operations Research*, v. 93, n. 1, p. 243–289, 2021.

KARAMERA, D.; OJAH, K.; COLE, J. Random walks and market efficiency tests: evidence from emerging equity markets. *Review of Quantitative Finance Accounting*, v. 13, p. 171–188, 1999.

KHAN, K.; REHMAN, W.; SAIF, O. Predicting key reversal points through fibonacci retracements. *Journal of Management Info*, v. 9, n. 3, p. 299–310, 2022.

KONNO, H. Piecewise linear risk function and portfolio optimization. *Journal of the Operations Research Society of Japan*, v. 33, n. 2, p. 139–156, 1990.

KONNO, H.; WIJAYANAYAKE, A. Mean-absolute deviation portfolio optimization model under transaction costs. *Journal of the Operations Research Society of Japan*, v. 42, n. 4, p. 422–435, 1999.

KONNO, H.; WIJAYANAYAKE, A. Portfolio optimization problem under concave transaction costs and minimal transaction unit constraints. *Mathematical Programming*, v. 89, p. 233–250, 2001.

KONNO, H.; YAMAZAKI, H. Mean-absolute deviation portfolio optimization model and its application to tokyo stock market. *Management Science*, v. 37, n. 5, p. 519–531, 1991.

LEE, C.; GLEASON, K.; MATHUR, I. Efficiency tests in the french derivatives market. *Journal of Banking and Finance*, v. 24, p. 787–807, 2000.

LENTO, C. Tests of technical trading rules in the asian-pacific equity markets: A bootstrap approach. *Academy of Financial and Accounting Studies Journal*, v. 11, n. 2, 2007.

LI, X.; YU, X.; ZHANG, Q. Optimal consumption and life insurance under shortfall aversion and a drawdown constraint. *Insurance: Mathematics and Economics*, v. 108, n. 2, p. 25–45, 2023.

LIN, C.; LIU, Y. Genetic algorithms for portfolio selection problems with minimum transaction lots. *European Journal of Operational Research*, v. 185, p. 393–404, 2008.

LINTNER, J. Security prices, risk and maximal gains from diversification. *Journal of Finance*, v. 20, n. 4, p. 587–615, 1965.

LIVIO, M. *Razão áurea, a história de phi, um número surpreendente*. Rio de Janeiro: Record, 2006.

LO, A.; MACKINLAY, A. Stock market prices do not follow random walks: Evidence from a simple specification test. *The Review of Financial Studies*, v. 1, n. 1, p. 41–66, 1988.

LO, A.; MAMAYSKY, H.; WANG, J. Foundations of technical analysis: computational algorithms, statistical inference, and empirical implementation. *The Journal of Finance*, v. 55, n. 4, p. 1705–1765, 2000.

LUSINDAH, L.; SUMIRAT, E. Implementation of fibonacci retracements and exponential moving average (ema) trading strategy in indonesia stock exchange. *European Journal of Business and Management Research*, v. 6, n. 4, p. 402–408, 2021.

MACIEL, L. A new approach to portfolio management in the brazilian equitymarket: Does assets efficiency level improve performance? *The Quarterly Review of Economics and Finance,*, v. 81, p. 38–56, 2021.

MARKOWITZ, H. Portfolio selection. *The Journal of Finance*, v. 7, n. 1, p. 77–91, 1952.

MENDONçA, G. et al. Multi-attribute decision making applied to financial portfolio optimization problem. *Expert Systems with Applications11*, v. 158, n. 113527, 2020.

MERTON, R. An intertemporal capital asset pricing model. *Econometrica*, v. 41, n. 5, p. 867–887, 1973.

MONDAL, P.; SHIT, L.; GOSWAMI, S. Study of effectiveness of time series modeling (arima) in forecasting stock prices. *International Journal of Computer Science, Engineering and Applications*, v. 4, n. 2, p. 13–29, 2014.

MURPHY, J. *Technical analysis of stock trends*. United States of America: New York Institute of Finance, 2001. ISBN 1-57444-292-9.

NEELY, C.; WELLER, P.; DITTMAR, R. Is technical analysis in the foreign exchange market profitable? a genetic programming approach. *Journal of Financial and Quantitative Analysis*, v. 32, p. 405–426, 1997.

NISON, S. *Japanese candlestick charting techniques: a contemporary guide to the ancient investment techniques of the Far East*. New York: New York Institute of Finance, 2001. ISBN 0-7352-0181-1.

OSLER, C.; CHANG, P. Head and shoulders: Not just a flaky pattern, Staff Report Nº 4. *Federal Reserve Bank of New York*, 1995.

PAIVA, F. et al. Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, v. 115, p. 635–655, 2019.

PARK, C.; IRWIN, S. The profitability of technical analysis: A review. *University of Illinois at Urbana-Champaign*, 2004.

PETRUSHEVA, N.; JORDANOSKI, I. Comparative analysis between the fundamental and technical analysis of stocks. *Journal of Process Management and New Technologie*, v. 4, n. 2, p. 26–31, 2016.

PICASSO, A. et al. Technical analysis and sentiment embeddings for market trend prediction. *Expert Systems with Applications*, v. 135, p. 60–70, 2019.

ROBERTS, H. Stock-market "patterns"and financial analisys: methodological suggestions. *The Journal of Finance*, v. 14, n. 1, p. 1–10, 1959.

ROCKEFELLER, B. *Technical analysis for dummies*. Indiana: Wiley Publishing, Inc, 2011. ISBN 978-0470-88800-1.

RUBESAM, A. Machine learning portfolios with equal risk contributions: Evidence from the brazilian market. *Emerging Markets Review*, v. 51, n. 100891, 2022.

SANT'ANNA, L.; FILOMENA, T.; CALDEIRA, J. Index tracking and enhanced indexing using cointegration and correlation with endogenous portfolio selection. *The Quarterly Review of Economics and Finance*, v. 65, p. 146–157, 2017.

SETHI, N. et al. Fibonacci retracement in stock market. *In: 5th International conference on next generation computing technologies (NGCT)*, 2019.

SHANAEV, S.; GIBSON, R. Can returns breed like rabbits? econometric tests for fibonacci retracements. *SSRN Electronic Journal*, 2022.

SHARPE, W. Capital asset prices: A theory of market equilibrium under conditions of risk. *The Journal of Finance*, v. 19, n. 3, p. 425–442, 1964.

SHASTRI, K.; SHASTRI, K. Do stock prices follow random walks: an analysis of the tokyo stock exchange. *Working Paper Series Carnegie Mellon H. John Heinz III School*, v. 41, 1994.

SOLEIMANI, H.; GOLMAKANI, H.; SALIMI, M. Markowitz-based portfolio selection with minimum transaction lots, cardinality constraints and regarding sector capitalization using genetic algorithm. *Expert Systems with Applications*, v. 36, p. 5058–5063, 2009.

SPERANZA, M. Linear programming models for portfolio optimization. *Finance*, v. 14, p. 107–123, 1993.

TABAK, B. The random walk hypothesis and the behaviour of foreign capital portfolio flows: The brazilian stock market case. *Applied Financial Economics*, v. 13, n. 5, p. 369–378, 2003.

TAYLOR, M.; ALLEN, H. The use of technical analysis in the foreign exchange market. *Journal of International Money and Finance*, v. 11, p. 304–314, 1992.

THOMÉ NETO, C.; LEAL, R.; ALMEIDA, V. Um índice de mínima variância de ações brasileiras. *Economia Aplicada,*, v. 15, n. 4, p. 535–557, 2011.

TOBIN, J. Liquidity preference as behavior towards risk. *The Review of Economic Studies*, v. 25, n. 2, p. 65–86, 1958.

TORRUBIANO, R.; SUÁREZ, A. A memetic algorithm for cardinality-constrained portfolio optimization with transaction costs. *Applied Soft Computing*, v. 36, p. 125–142, 2015.

TSINASLANIDI, P.; GUIJARRO, F.; VOUKELATOS, N. Automatic identification and evaluation of fibonacci retracements: Empirical evidence from three equity markets. *Expert Systems with Applications*, v. 187, n. 115893, 2022.

WAN, Y.; SI, Y. A formal approach to chart patterns classification in financial time series. *Information Sciences*, v. 411, p. 151–175, 2017.

WANG, J.; CHAN, S. Stock market trading rule discovery using pattern recognition and technical analysis. *Expert Systems with Applications,*, v. 33, p. 304–315, 2007.

WANG, J.; ZHANG, D.; ZHANG, J. Mean reversion in stock prices of seven asian stock markets: Unit root test and stationary test with fourier functions. *International Review of Economics and Finance*, v. 37, p. 157–164, 2015.

WARBURTON, A.; ZHANG, Z. A simple computational model for analyzing the properties of stop-loss, take-profit, and price breakout trading strategies. *Computers Operations Research*, v. 33, p. 32–42, 2006.

WOLFE, P. The simplex method for quadratic programming. *Econometrica*, v. 27, p. 382–398, 1959.

ZABARANKIN, M.; PAVLIKOV, K.; URYASEV, S. Capital asset pricing model (capm) with drawdown measure. *European Journal of Operational Research*, v. 234, n. 2, p. 508 – 517, 2014.

ZAPRANIS, A.; TSINASLANIDIS, P. A novel, rule-based technical pattern identification mechanism: Identifying and evaluating saucers and resistant levels in the us stock market. *Expert Systems with Applications*, v. 39, p. 6301–6308, 2012.

ZHANG, Q. Stock trading: an optimal selling rule. *SIAM Journal on Control and Optimization*, v. 40, n. 1, p. 64–87, 2001.