

**UNIVERSIDADE FEDERAL DE MINAS GERAIS  
FACULDADE DE CIÊNCIAS ECONÔMICAS  
CENTRO DE PÓS-GRADUAÇÃO E PESQUISAS EM ADMINISTRAÇÃO**

**EDUARDO DE ABREU MORAES**

**ALGORITMO PARA OTIMIZAÇÃO DA ESTRATÉGIA DE INVESTIMENTO EM  
DESEMPENHO CONTRÁRIO**

Belo Horizonte/MG

Julho de 2021

EDUARDO DE ABREU MORAES

**ALGORITMO PARA OTIMIZAÇÃO DA ESTRATÉGIA DE INVESTIMENTO EM  
DESEMPENHO CONTRÁRIO**

Dissertação apresentada ao Centro de Pós-Graduação e Pesquisas em Administração da Faculdade de Ciências Econômicas da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do título de Mestre em Administração com ênfase em Finanças.

Orientador: Prof. Dr. Aureliano Angel Bressan

Belo Horizonte/MG

Julho de 2021

Ficha catalográfica

M827a 2021 Moraes, Eduardo de Abreu.  
Algoritmo para otimização da estratégia de investimento em desempenho contrário [manuscrito] / Eduardo de Abreu Moraes – 2021.  
98 f.: il., tabs.

Orientador: Aureliano Angel Bressan.  
Dissertação (mestrado) – Universidade Federal de Minas Gerais, Centro de Pós-Graduação e Pesquisas em Administração. Inclui bibliografia (f. 95-98).

1. Administração – Teses. 2. Finanças – Teses. 3. Bolsa de valores – Teses. I. Bressan, Aureliano Angel.. II. Universidade Federal de Minas Gerais. Centro de Pós-Graduação e Pesquisas em Administração. III. Título.

CDD: 658

Elaborado por Rosilene Santos CRB6/2527  
Biblioteca da FACE/UFMG. – RSS41/2022



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
FACULDADE DE CIÊNCIAS ECONÔMICAS  
CENTRO DE PÓS-GRADUAÇÃO E PESQUISAS EM ADMINISTRAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO

**ATA DE DEFESA DE DISSERTAÇÃO**

ATA DA DEFESA DE DISSERTAÇÃO DE MESTRADO EM ADMINISTRAÇÃO do Senhor **EDUARDO DE ABREU MORAES**, REGISTRO Nº 736/2021. No dia 30 de julho de 2021, às 16:00 horas, reuniu-se remotamente, por videoconferência, a Comissão Examinadora de Dissertação, indicada pelo Colegiado do Centro de Pós-Graduação e Pesquisas em Administração do CEPEAD, em 28 de julho de 2021, para julgar o trabalho final intitulado "**ALGORITMO PARA OTIMIZAÇÃO DA ESTRATÉGIA DE INVESTIMENTO EM DESEMPENHO CONTRÁRIO**", requisito para a obtenção do **Grau de Mestre em Administração**, linha de pesquisa: **Finanças**. Abrindo a sessão, o Senhor Presidente da Comissão, Prof. Dr. Aureliano Angel Bressan, após dar conhecimento aos presentes o teor das Normas Regulamentares do Trabalho Final, passou a palavra ao candidato para apresentação de seu trabalho. Seguiu-se a arguição pelos examinadores com a respectiva defesa do candidato. Logo após, a Comissão se reuniu sem a presença do candidato e do público, para julgamento e expedição do seguinte resultado final:

APROVAÇÃO

REPROVAÇÃO

O resultado final foi comunicado publicamente ao candidato pelo Senhor Presidente da Comissão. Nada mais havendo a tratar, o Senhor Presidente encerrou a reunião e lavrou a presente ATA, que será assinada por todos os membros participantes da Comissão Examinadora. Belo Horizonte, 30 de julho de 2021.

Prof. Dr. Aureliano Angel Bressan  
ORIENTADOR - CEPEAD/UFMG

Prof. Dr. Robert Aldo Iquiapaza Coaguila  
CEPEAD/UFMG

Prof. Dr. Cristiano Arbex Valle  
DCC/UFMG

Prof. Dr. Marcos Vinicius Lopes Pereira  
UFSJ/MG



Documento assinado eletronicamente por **Aureliano Angel Bressan, Professor do Magistério Superior**, em 30/07/2021, às 18:46, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

Documento assinado eletronicamente por **Cristiano Arbex Valle, Professor do Magistério Superior**,



em 30/07/2021, às 18:48, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Robert Aldo Iquiapaza Coaguila, Professor do Magistério Superior**, em 30/07/2021, às 18:48, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Marcos Vinicius Lopes Pereira, Usuário Externo**, em 02/08/2021, às 19:54, conforme horário oficial de Brasília, com fundamento no art. 5º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [https://sei.ufmg.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufmg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0860788** e o código CRC **A1B9C537**.

## RESUMO

A estratégia de investimento em desempenho contrário (geralmente referenciada como *contrarian investing*) consiste em identificar um movimento de uma maioria de investidores no mercado de ações e negociar de forma contrária a esse movimento. Apesar de existir literatura sobre o tema confirmando a eficácia da estratégia em gerar excesso de retorno em relação ao índice representativo de mercado, não se tem notícia de trabalho científico cujo objetivo tenha sido o de apresentar a melhor forma de se implementar a estratégia em determinado país. O presente trabalho se propôs a preencher essa lacuna ao estimar como cada parâmetro de implementação da estratégia contribui, em média, na geração de *Information Ratio*. Essas estimativas foram feitas por meio do Método dos Mínimos Quadrados Ordinários, executado sobre uma base de dados dos resultados de simulações (10.000 para o caso brasileiro e 1.200 para o caso estadunidense) de diferentes implementações aleatórias da estratégia. Essas simulações, por sua vez, foram realizadas através de um algoritmo que representa a implementação da estratégia. Com base nos coeficientes estimados pelo MQO foi possível identificar a combinação de parâmetros que maximiza a *Information Ratio*. Os resultados fora da amostra para o caso brasileiro foram no sentido de que esse procedimento de otimização da estratégia é capaz de gerar um *Information Ratio* maior que a média das simulações aleatórias, mas ainda assim negativo. No caso estadunidense os resultados foram inconclusivos por conta do pequeno número de simulações realizadas em função do alto custo computacional, relacionado ao tempo e capacidade de processamento.

Palavras-chave: investimento em desempenho contrário, valor contrário, gestão ativa, *information ratio*.

## **ABSTRACT**

The contrarian investing strategy consists of identifying a movement of a majority of investors in the stock market and trading against that movement. Although there is literature on the subject confirming the effectiveness of the strategy in generating excess return in relation to the market index, there seems to be no scientific work whose objective was to present the best way to implement the strategy in a given country . The present work aimed to fill this gap by estimating how each strategy implementation parameter contributes, on average, in the generation of Information Ratio. These estimates were made using the Ordinary Least Squares Method, performed on a database of simulation results (10,000 for the Brazilian case and 1,200 for the US case) of different random implementations of the strategy. These simulations were performed using an algorithm that represents the implementation of the strategy. Based on the coefficients estimated by the OLS, it was possible to identify the combination of parameters that maximizes the Information Ratio. The out-of-sample results for the Brazilian case were in the sense that this strategy optimization procedure is capable of generating an Information Ratio greater than the average of the random simulations, but still negative. In the US case, the results were inconclusive due to the small number of simulations performed due to the high computational cost, related to time and processing capacity.

Keywords: investment in opposite performance, opposite value, active management, information ratio.

## Índice de Tabelas

Tabela 1: Critérios de Formação na Literatura.....	27
Tabela 2: <i>Períodos</i> de Formação na Literatura.....	29
Tabela 3: Períodos de Maturação na Literatura.....	31
Tabela 4: Número de Ações na Literatura.....	34
Tabela 5: Critérios de Distribuição de Pesos na Literatura.....	36
Tabela 6: MQO, Brasil (com custos de transação). Variável dependente: information_ratio_anualizado.....	67
Tabela 7: MQO Heterocedasticidade Corrigida, Brasil (com custos de transação). Variável dependente: information_ratio_anualizado.....	68
Tabela 8: MQO Heterocedasticidade Corrigida, Brasil (com custos de transação). Variável dependente: uhat1.....	70
Tabela 9: VIF, MQO Heterocedasticidade Corrigida, Brasil (com custos de transação).....	71
Tabela 10: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, Brasil (com custos de transação).....	77
Tabela 11: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (com custos de transação).....	77
Tabela 12: MQO Heterocedasticidade Corrigida, Brasil (sem custos de transação). Variável dependente: information_ratio_anualizado.....	80
Tabela 13: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, Brasil ( <i>sem</i> custos de transação).....	81
Tabela 14: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (sem custos de transação).....	82
Tabela 15: MQO Heterocedasticidade Corrigida, EUA (com custos de transação). Variável dependente: information_ratio_anualizado.....	84
Tabela 16: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, <i>EUA</i> (com custos de transação).....	86
Tabela 17: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, <i>EUA</i> (com custos de transação).....	87



Tabela 18: MQO Heterocedasticidade Corrigida, EUA (sem custos de transação). Variável dependente: <code>information_ratio_anualizado</code> .....	90
Tabela 19: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, <i>EUA</i> (sem custos de transação).....	91
Tabela 20: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, <i>EUA</i> (com custos de transação).....	91

## Índice de Figuras

Figura 1: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (com custos de transação).....	78
Figura 2: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (sem custos de transação).....	83
Figura 3: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (com custos de transação).....	88
Figura 4: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (sem custos de transação).....	92

## SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>10</b>
1.1. “INVESTIMENTO EM VALOR CONTRÁRIO” OU “INVESTIMENTO EM DESEMPENHO CONTRÁRIO”?.....	10
1.2. IDEIA GERAL DA ESTRATÉGIA DE INVESTIMENTO EM DESEMPENHO CONTRÁRIO.....	10
1.3. DA IMPORTÂNCIA DO TEMA PARA OS FUNDOS DE GESTÃO ATIVA.....	11
1.4. DO PROBLEMA DE PESQUISA.....	13
1.5. OBJETIVO DO TRABALHO.....	14
<b>2. REFERENCIAL TEÓRICO.....</b>	<b>16</b>
2.1. CONTEXTUALIZAÇÃO TEÓRICA E MEDIDAS DE DESEMPENHO.....	16
2.2. DOS FUNDOS DE GESTÃO ATIVA E DO <i>INFORMATION RATIO</i> .....	19
<b>3. REVISÃO DE LITERATURA.....</b>	<b>21</b>
3.1. HISTÓRICO DA ESTRATÉGIA DE INVESTIMENTO EM DESEMPENHO CONTRÁRIO.....	21
3.2. LACUNAS NA LITERATURA.....	27
3.2.1. Critério de Formação (seleção das ações).....	27
3.2.2. Período de Formação.....	29
3.2.3. Período de Maturação.....	30
3.2.4. Número de Ações.....	34
3.2.5. Distribuição dos Pesos.....	36
3.2.6. Tamanho da Amostra para o Cálculo da Distribuição de Pesos.....	39
3.2.7. Período para Rebalanceamento.....	40
3.2.8. Custos de Transação.....	42
<b>4. METODOLOGIA.....</b>	<b>44</b>
4.1. PAÍSES ESTUDADOS.....	44
4.2. PANORAMA DA METODOLOGIA EMPREGADA NO PRESENTE TRABALHO.....	44
4.3. HIPÓTESE GERAL.....	44
4.3.1. Sucesso do Algoritmo no Brasil.....	45
4.3.2. Sucesso do Algoritmo nos Estados Unidos da América.....	45
4.5. O ALGORITMO DE SIMULAÇÕES.....	46

4.5.1. <i>Formalização dos Parâmetros</i> .....	47
4.5.2. <i>Estimativa dos Custos de Transação</i> .....	56
4.5.3. <i>Do Sistema de Manutenção da Liquidez</i> .....	58
4.5.4. <i>Drawdown máximo</i> .....	60
4.5.5. <i>Descrição do Algoritmo de Simulações</i> .....	60
4.5.6. <i>Gráficos e Dados gerados pelo Algoritmo de Simulações</i> .....	62
4.6. OTIMIZAÇÃO DOS PARÂMETROS DE IMPLEMENTAÇÃO DA ESTRATÉGIA DE INVESTIMENTO EM DESEMPENHO CONTRÁRIO.....	64
<b>5. RESULTADOS</b> .....	<b>67</b>
5.1. BRASIL.....	67
5.1.1. <i>Com custos de transação</i> .....	67
5.1.2. <i>Sem custos de transação</i> .....	80
5.1.3. <i>Conclusão Brasil</i> .....	84
5.2. ESTADOS UNIDOS.....	84
5.2.1. <i>Com Custos de Transação</i> .....	84
5.2.2. <i>Sem Custos de Transação</i> .....	90
5.2.3. <i>Conclusão Estados Unidos</i> .....	93
5.3. CONCLUSÃO GERAL DO TRABALHO.....	93
<b>6. BIBLIOGRAFIA</b> .....	<b>95</b>

## 1. INTRODUÇÃO

### 1.1. “Investimento em valor contrário” ou “investimento em desempenho contrário”?

O presente trabalho se debruça sobre um tema que é denominado na literatura de língua inglesa *contrarian investment* ou *contrarian strategies*. Como o trabalho seminal que tratou sobre o tema (DE BONDT; THALER, 1985) o fez pela ótica do *overreaction effect*<sup>1</sup>, isto é, da reação exagerada dos agentes que, segundo o artigo, faria com que o preço do ativo se descolasse do valor intrínseco do mesmo, a estratégia passou a ser classificada como uma espécie de estratégia do gênero *value investing*. É por isso que autores como, por exemplo, Damodaran (2012, p. 4) se referem à estratégia pela expressão “*contrarian value investing*”. Por sua vez, essa expressão é geralmente traduzida para o português como “investimento em valor contrário”, como ocorre, por exemplo, em Saturnino (2011). Todavia, considerando o advento dos modelos multifatoriais de precificação de ativos, a expressão “investimento em valor contrário” pode remeter o leitor à ideia de investir contrariamente ao fator “*book-to-market*”, presente tanto no Modelo de Três Fatores de Fama e French (1993) quanto no Modelo de Cinco Fatores de Fama e French (2015). Portanto, buscando representar de forma mais fidedigna a ideia do *contrarian investing* conforme tratado na literatura internacional, o presente trabalho irá adotar a expressão já apresentada no título: “investimento em desempenho contrário”.

### 1.2. Ideia geral da Estratégia de Investimento em Desempenho Contrário

A estratégia de investimento em desempenho contrário consiste, em linhas gerais, em identificar um movimento de uma maioria de investidores no mercado de ações e negociar de forma contrária a esse movimento (HANSEN, 2015, p. 25). O pressuposto geral da estratégia de investimento em desempenho contrário é o de que, em um primeiro momento, agentes erram na precificação das ações e, em um momento posterior, acontece uma correção dessa precificação.

Conforme será apresentado na seção 3.1 (página 21), existem evidências na literatura de que a implementação da estratégia de investimento em desempenho contrário pode propiciar ao investidor retornos (não ajustados por risco) acima do mercado. Também existem

---

1 Em Lemos e Costa (1996) essa expressão foi traduzida para o português como “efeito sobre-reação”. No entanto, a expressão “sobre-reação” ou “sobrerreação” não consta no dicionário Michaelis Online ([michaelis.uol.com.br/](http://michaelis.uol.com.br/)). Além disso, no Cambridge Dictionary inglês-português ([dictionary.cambridge.org/dictionary/english-portuguese](http://dictionary.cambridge.org/dictionary/english-portuguese)), “overreact” é traduzido como “reagir de forma exagerada” ou “exagerar”. Dessa forma, o presente trabalho utilizará a expressão “reação exagerada” ao invés de “sobrerreação”.

na literatura lacunas (vide seção 3.2) sobre quais seriam os melhores parâmetros para implementação da estratégia. O presente trabalho pretende contribuir ao debate acadêmico ao desenvolver um algoritmo que procura otimizar a implementação da estratégia de investimento em desempenho contrário.

### 1.3. Da Importância do tema para os Fundos de Gestão Ativa

Considerando que a implementação da estratégia de investimento em desempenho contrário é complexa; considerando que o presente trabalho adota uma abordagem econométrica e computacional dificilmente aplicável por um investidor pessoa física; e considerando que a estratégia de investimento em desempenho contrário não visa replicar algum índice de mercado; o presente estudo terá como foco as gestoras de fundos de investimento em ações que realizam a gestão ativa. E o objetivo desse tipo de fundo é superar o desempenho de determinado *benchmark* (GRINOLD; KAHN, 2019, p. 14). Conforme será melhor explicado na seção 2.2, a medida de desempenho adequada para mensurar a gestão ativa é o *Information Ratio*<sup>2</sup> (vide Eq. 1).

Como qualquer firma, uma gestora de fundos de investimento em ações possui o objetivo de maximizar receitas e minimizar custos. Uma das fontes de receitas das gestoras é a taxa de performance, que é cobrada quando o fundo apresenta um retorno superior ao seu *benchmark* (o que necessariamente também acontece quando ele apresenta *Information Ratio*, conforme definida na Eq. 1, positiva). Alguns dos custos de uma gestora são recursos humanos (como analistas e gestores) e fornecedores de dados sobre as ações e suas empresas (demonstrativos contábeis consolidados, *betas*, fatores para alimentar modelos multifatoriais de precificação, etc). Se uma gestora conseguir implementar com sucesso uma regra de investimentos que gera retornos consistentemente acima do *benchmark* (o que ensejará a cobrança da taxa de performance) e, ao mesmo tempo, demande poucos recursos humanos, ela estará contribuindo para a maximização do seu lucro.

Essa busca de um bom “custo/benefício” no exercício da atividade econômica de gestão de recursos de terceiros é um dos motivos que faz com que o CAPM (SHARPE, 1964; LINTNER, 1965) continue sendo mais utilizado fora da academia do que modelos multifatoriais como o Modelo de Três Fatores de Fama e French (1993). É o que se depreende de Bartholdy e Peare (2005, p. 15), que concluem que, apesar das recomendações da

---

2 O termo “*Information Ratio*” não costuma ser traduzido para o português, seja na praxe do mercado financeiro seja em trabalhos acadêmicos. Um exemplo é o trabalho de De Oliveira Filho (2015). Seria, no entanto, possível utilizar a expressão “índice de informação”. Mas, no presente trabalho, optou-se por manter a expressão em língua inglesa.

academia para que seja utilizado o Modelo de Três Fatores de Fama e French (1993), esse modelo não tem um desempenho suficientemente melhor que o CAPM para justificar o custo adicional e o trabalho extra de se coletar os dados para adotá-lo. O mesmo raciocínio pode ser aplicado ao Modelo de Cinco Fatores de Fama e French (2015) ou a outros modelos multifatoriais.

Uma vez que se saiba que a estratégia de investimento em desempenho contrário funciona (pelo menos historicamente) para determinado mercado, o desafio do gestor refere-se a como implementá-la da melhor forma possível partindo do pressuposto de que a sua finalidade é a de maximizar o *Information Ratio* do fundo e, conseqüentemente, a cobrança de taxa de performance e a receita de sua gestora.

Ocorre que os artigos que foram objeto da revisão bibliográfica apresentada na seção 3, objetivaram constatar a existência e investigar as causas dos retornos acima do mercado quando da adoção da estratégia de investimento em desempenho contrário, e não sobre a melhor forma de implementar a estratégia em determinado mercado.

É nesse sentido que o presente estudo se justifica. Foi desenvolvido um algoritmo para determinação da melhor maneira de se implementar a estratégia de investimento em desempenho contrário em determinado mercado com o objetivo de maximizar o *Information Ratio* dos fundos de investimento. Além disso, o algoritmo foi construído de modo que tanto a sua implementação quanto a regra de negociação dele resultante não dependam de decisões discricionárias do gestor, de *valuation* das empresas incluídas no portfólio, ou de qualquer informação além dos retornos históricos de todas as ações disponíveis para a compra, do retorno histórico do *benchmark* e do retorno histórico da taxa livre de risco do mercado em análise.

A estratégia de investimento em desempenho contrário pode ser implementada tanto para posições compradas (adquirindo ações perdedoras, isto é, que desempenharam mal no passado, e esperando que elas passem a desempenhar bem) quanto para posições vendidas (realizando a venda a descoberto de ações vencedoras, isto é, que desempenharam bem no passado, e esperando que elas passem a desempenhar mal). O presente estudo se restringe somente a posições compradas de implementação da estratégia, de modo que tanto na revisão da literatura quanto na metodologia da pesquisa o foco será exclusivamente nesse tipo de implementação. Trata-se de uma opção metodológica da presente pesquisa considerando que a modelagem da estratégia em investimento em desempenho contrário, da forma como será feita no presente estudo (isto é, com dados diários e calculando o custo de transação de cada compra e venda), já é bastante complexa em sua versão comprada. Incluir a venda a

descoberto no presente trabalho torná-lo-ia demasiadamente complexo, pois seria necessário estimar também o custo do aluguel das ações para realizar as vendas a descoberto.

#### **1.4. Do problema de pesquisa**

O que se percebe, ao analisar os trabalhos sobre a estratégia de investimento em desempenho contrário, é que, desde o artigo seminal de De Bondt e Thaler (1985), os estudos científicos (apresentados na seção 3.1) sobre o tema se dedicaram basicamente a constatar se a estratégia é capaz de gerar ganhos anormais em determinado país e quais seriam as causas desses ganhos. Apesar das variações nas técnicas de pesquisa e abordagens metodológicas, os objetivos de todos os trabalhos analisados sobre o tema são praticamente os mesmos. Não se tem notícia de estudo sobre a estratégia de investimento em desempenho contrário cujo objetivo tenha sido o de apresentar a melhor forma de se implementar a estratégia em determinado país. Ou ainda, não se sabe de trabalho acadêmico que tenha apresentado um método que auxilie investidores (individuais, institucionais ou gestoras) a determinar os parâmetros ótimos de implementação da estratégia em determinado mercado.

O Problema de Pesquisa sobre o qual a presente investigação se debruça é justamente esse: *é possível, e vale a pena, desenvolver e implementar um Algoritmo de Otimização da Estratégia de Investimento em Desempenho Contrário com o objetivo de maximizar o Information Ratio de um portfólio?*

Além disso, considerando o já mencionado objetivo dos trabalhos sobre o tema, importantes variáveis de implementação da estratégia de investimento em desempenho contrário são tratadas de maneira pouco aprofundada (vide seção 3.2). Na realidade, a falta de artigos que tratam da otimização para implementação da estratégia de investimento em desempenho contrário e a falta de artigos que tratam com maior profundidade de seus parâmetros de implementação referem-se a uma mesma lacuna na literatura. É importante notar que, quando os trabalhos científicos objeto da revisão de literatura (seção 3) concluem que a estratégia é ou não eficaz em determinado mercado, na verdade o que eles estão concluindo é se determinadas implementações da estratégia, com seus respectivos parâmetros, se mostraram eficazes ou não em determinado mercado. Ou seja, o que cada um desses trabalhos faz é tomar uma pequena amostra de uma enorme<sup>3</sup> população de diferentes combinações de parâmetros de implementação da estratégia, analisar o desempenho dessa amostra, e daí tecerem conclusões sobre a eficácia ou não da estratégia como um todo.

---

3 Como existem vários parâmetros de implementação da estratégia, e como eles podem assumir valores bastante diversos, o número de possíveis implementações da estratégia é de fato muito grande.



Portanto, é possível que trabalhos que concluíram que a estratégia não é eficaz em determinado mercado tivessem chegado a conclusões diferentes, se tivessem adotado outros parâmetros de implementação.

### 1.5. Objetivo do trabalho

O objetivo do presente trabalho é desenvolver um algoritmo de otimização que auxilie gestoras de fundos de investimentos a implementar a estratégia de investimento em desempenho contrário no mercado de ações somente com posições compradas. Ao ser aplicado a determinado mercado acionário, o método irá gerar uma regra de negociação para implementação da estratégia de investimento em desempenho contrário específica para aquele mercado. A regra de negociação gerada pelo método nada mais será do que a indicação dos parâmetros ótimos para implementar a estratégia naquele mercado. Espera-se que essa regra de negociação seja capaz de gerar *Information Ratio* positiva ao ser implementada (conforme justificado na seção 2.2). Importante ressaltar que o objetivo do presente estudo não é desenvolver uma regra de negociação por si só, mas um algoritmo gerador de regras de negociação.

Em linhas gerais, a estratégia de investimento em desempenho contrário consiste em criar uma carteira com ações perdedoras, isto é, que desempenharam mal em comparação com outras ações e aguardar que a reversão no desempenho de pelo menos parte das ações faça a carteira como um todo desempenhar acima do mercado. As medidas de desempenho adotadas no presente trabalho são apresentadas na seção 4.5.1.1. Nesse contexto, e considerando o objetivo de maximizar o *Information Ratio* do portfólio, o algoritmo desenvolvido por ocasião do presente trabalho responde às seguintes perguntas (objetivos específicos do presente trabalho) quanto à implementação da estratégia de investimento em desempenho contrário em determinado mercado (a explicação dos parâmetros é fornecida na seção 3.2):

- 1.5.1. Qual Critério de Formação deve ser utilizado?
- 1.5.2. Qual Período de Formação adotar?
- 1.5.3. Qual Período de Maturação utilizar?
- 1.5.4. Qual deve ser a Fração do Total de Ações Disponíveis a ser adquirida?
- 1.5.5. Qual é a melhor forma de Distribuição dos Pesos (participação percentual) de cada ativo na carteira?
- 1.5.6. Qual deve ser o tamanho da amostra ao se calcular a matriz variâncias e covariâncias?

1.5.7. Qual deve ser o Período para Rebalanceamento ao longo do Período de Maturação?

É muito importante ressaltar que cada uma dessas perguntas não será respondida através de um estudo individual. Todas elas serão endereçadas simultaneamente, em conjunto, pois o algoritmo desenvolvido no presente trabalho responde a todas essas perguntas de uma só vez. É necessário e natural que assim seja pois o algoritmo gera regras de negociação otimizadas da estratégia de investimento em desempenho contrário; ademais, é preciso que sejam definidos todos esses parâmetros ao se implementar a estratégia na prática.

## 2. REFERENCIAL TEÓRICO

### 2.1. Contextualização Teórica e Medidas de Desempenho

Para justificar a importância do tema tratado no presente trabalho, é necessário apresentar de que modo ele se relaciona com o debate sobre teoria moderna do portfólio. Essa discussão se inicia em Markowitz (1952) que demonstra que, uma vez definidos quais ativos serão incluídos em um portfólio, o investidor deve distribuir os pesos dos ativos na carteira de modo a obter um portfólio eficiente, isto é, um portfólio que propicie o maior retorno estimado para um dado nível de risco estimado ou, equivalentemente, o menor risco estimado para um dado nível de retorno estimado. O conjunto de portfólios eficientes é denominado fronteira eficiente. A concepção de risco presente em Markowitz (1952) é a de variância dos retornos de uma ação, de modo que o que ele propõe é que seja feita uma otimização da média-variância dos retornos estimados ao distribuir as participações percentuais dos ativos em uma carteira.

Diante desse paradigma teórico de que a performance de um portfólio pode ser resumida ao retorno esperado e à variância esperada, Sharpe (1966, p. 123) propôs uma medida de desempenho que conjugasse essas duas dimensões e que ele batizou de *reward-to-variability ratio*. Posteriormente, a medida ficou conhecida como Índice Sharpe (vide Eq. 10). Anos depois, ainda fundamentando-se sobre o paradigma da média-variância de Markowitz (1952), Sharpe (1994) propôs uma atualização do Índice Sharpe com o objetivo de torná-lo mais adequado a um espectro mais amplo de aplicações. No entanto, o próprio Sharpe (1994) reconheceu que alguns autores já utilizavam o termo *Information Ratio* para se referir a uma medida de desempenho que equivaleria a essa nova versão do Índice Sharpe.

Pouco antes do advento do Índice Sharpe, foi desenvolvido o CAPM (*Capital Asset Pricing Model*) por Sharpe (1964) e Lintner (1965). Esse modelo estabelece que o excesso de retorno (em comparação à taxa livre de risco) de um ativo financeiro é determinado pelo coeficiente *beta* que representa a sensibilidade dos retornos de um ativo (ou de um portfólio) em função de variações do excesso de retorno do mercado. Segundo o CAPM, o *beta* seria, considerando um portfólio suficientemente diversificado, a única fonte de risco relevante ao se determinar o retorno esperado de um ativo. É por isso que o *beta* é considerado uma medida de risco relativo (em relação ao mercado) ou uma medida de risco sistêmico (não diversificável).

E foi baseando-se no CAPM que Jensen (1968, p. 8) desenvolveu uma medida de desempenho (que posteriormente ficou conhecida como Alfa de Jensen) que consiste na

diferença entre o retorno observado de um ativo e o retorno estimado desse ativo segundo o CAPM.

Em 1970 foi publicado o artigo “Efficient Capital Markets: a Review of Theory and Empirical Work”. Nesse artigo, parte-se da definição de que é eficiente um mercado de capitais cujos preços reflitam completamente toda informação disponível (FAMA, 1970, p. 383). O trabalho categoriza os estudos empíricos que testam a Hipótese de Mercado Eficiente de três formas: fraca, semiforte e forte. Na forma fraca, são enquadrados os testes cujas informações relevantes seriam somente os preços (e retornos) históricos dos ativos. Na forma semiforte, enquadram-se os testes cujas informações relevantes são, além dos preços, qualquer outra informação obviamente pública (como relatórios anuais). Por fim, na forma forte, enquadram-se os testes que levam em consideração a existência de acesso monopolístico a informações relevantes por parte de um investidor ou grupo de investidores (FAMA, 1970, p. 388).

Uma das principais contribuições do trabalho de FAMA (1970) foi justamente a de ter categorizado as acepções da Hipótese de Mercado Eficiente (fraca, semiforte e forte), o que lançou bases teóricas claras para as investigações empíricas quanto às anomalias (também chamadas de falhas ou ineficiências) de mercado, ou seja, fenômenos que contradizem a Hipótese de Mercado Eficiente.

Um dos trabalhos que alegaram ter encontrado anomalias de mercado foi justamente o de De Bondt e Thaler (1985), que apresentou evidências empíricas de uma suposta ineficiência do tipo fraca chamada de *overreaction effect* e que estaria relacionada a reversões nos desempenhos das ações.

Ao perceberem que o CAPM de Sharpe (1964) e Lintner (1965) era incapaz de descrever satisfatoriamente os retornos das ações americanas, Fama e French (1993) propuseram um novo modelo de precificação que ficou conhecido como Modelo de Três Fatores de Fama-French. Esse modelo estabelece que, além do fator geral de mercado (o excesso de retorno do mercado em relação à taxa livre de risco), existem ainda outras duas fontes de risco relevantes para se determinar o retorno de uma ação: um fator relacionado ao tamanho da firma e um fator relacionado à proporção *book-to-market*, isto é, a razão entre o valor contábil e o valor de mercado. Segundo Fama e French (1996), esse modelo de três fatores explicava satisfatoriamente uma série de fenômenos que vinham sendo apontados na literatura como anomalias de mercado, entre eles as reversões estudadas por De Bondt e Thaler (1985).

A partir da proposição do Modelo de Três Fatores de Fama-French, a ideia por trás do Alfa de Jensen (isto é, a diferença entre o retorno observado de um ativo e o retorno previsto pelo CAPM) também passou a ser aplicada ao novo modelo. Diante de um paradigma de um modelo de três fatores, Alfa é a diferença entre o retorno observado e o retorno previsto por esse modelo multifatorial. O mesmo raciocínio se aplica ao Modelo de Cinco Fatores de Fama-French (2015), que, além dos três fatores já apresentados em Fama e French (1993), incorporou fatores relacionados à lucratividade e aos investimentos observados nas firmas.

O que se conclui desse breve panorama histórico é que qualquer medida de desempenho de um ativo fundamenta-se em algum modelo. O Índice Sharpe (1966) e o *Information Ratio* (SHARPE, 1994) apoiam-se em Markowitz (1952) e na ideia de que o risco de um ativo é igual à variância de seus retornos. O Alfa de Jensen firma-se sobre o CAPM de Sharpe (1964) e Lintner (1965) e, conseqüentemente, é uma medida ajustada pelo risco sistêmico (*beta*) do ativo. E quando se adotam paradigmas de modelos multifatoriais, conseqüentemente passa-se a levar em consideração o desempenho previsto por esses modelos ao se mensurar o desempenho observado de um ativo. Para além dessas medidas acima mencionadas, existem inúmeras outras, cada uma delas focando em determinada dimensão ou característica do ativo, conseqüentemente, cumprindo um determinado objetivo de mensuração. Há que se notar, no entanto, que diferentes medidas de desempenho apresentam diferentes dificuldades de implementação. O Índice Sharpe, por exemplo, é muito mais simples de ser calculado do que o Alfa de um modelo multifatorial.

Este panorama histórico evidencia que a própria identificação de anomalias de mercado evolui à medida que avançam os modelos de precificação. Por mais que o conceito de anomalia permaneça o mesmo desde Fama (1970), isto é, situações em que os preços não refletem toda informação disponível, a forma de identificar essas anomalias evoluiu. Uma estratégia de investimento que fosse capaz de gerar, regularmente, Alfa de Jensen positivo poderia ser interpretada como uma estratégia que estivesse explorando alguma anomalia ou falha de mercado, uma vez que isso significaria que existiriam informações disponíveis que poderiam ser utilizadas para se obter um retorno maior que o esperado. No entanto, pela ótica de algum modelo multifatorial, essa mesma estratégia poderia se mostrar incapaz de gerar Alfa positivo e, portanto, não haveria uma falha de mercado sendo explorada.

Essa contextualização é importante para dizer que o presente trabalho, apesar de se debruçar sobre uma estratégia de investimento (estratégia em desempenho contrário) que explora uma suposta falha de mercado (*overreaction*, ou seja, reação exagerada dos agentes), não tem por escopo averiguar se a implementação dessa estratégia é capaz de gerar Alfa (seja

pela ótica do CAPM ou de modelos multifatoriais). O alfa de Jensen será analisado, mas somente em caráter complementar. Isto porque (conforme explicado na seção 1.3) o foco do presente trabalho são os fundos de investimento de gestão ativa. E é possível que fundos cobrem taxa de performance mesmo sem gerar Alfa positivo caso eles gerem *Information Ratio* positivo. Ou seja, a rigor, o presente estudo não é uma investigação sobre a existência de uma anomalia de mercado (que, no atual estado da arte, demandaria que se testasse se a estratégia é capaz de gerar Alfa considerando o Modelo de Cinco Fatores de Fama-French (2015)). O presente estudo debruçar-se-á sobre a otimização da implementação da estratégia de investimento em desempenho contrário pelo critério da maximização do *Information Ratio* do portfólio.

## 2.2. Dos Fundos de Gestão Ativa e do *Information Ratio*

O presente trabalho utiliza o *Information Ratio* (*IR*) conforme formalizado em Sharpe (1994):

$$IR_j = \frac{\mu(R_j - R_m)}{\sigma(R_j - R_m)} \quad \text{Eq. 1}$$

em que  $R_j$  é o retorno do ativo  $j$ ,  $R_m$  é o retorno do *benchmark* (índice representativo do mercado acionário, caso o ativo analisado seja uma ação). E  $\mu$  e  $\sigma$  são os símbolos para, respectivamente, função média e função desvio padrão.

Grinold e Kahn (2019, p. 48) argumentam que o *Information Ratio* é a medida adequada de consistência da gestão ativa e que, quanto maior o *Information Ratio*, maior a probabilidade de que o retorno no próximo período seja positivo. Os autores ressaltam que obter um *Information Ratio* alto não é o mesmo que obter um retorno alto, pois qualquer gestor é capaz de assumir riscos elevados e ocasionalmente lograr retornos elevados. O *Information Ratio*, por outro lado, por ser uma medida de desempenho ajustada pelo risco, indica a consistência do gestor em entregar resultados positivos. Goodwin (1998, p. 42) argumenta que o *Information Ratio* pode ser considerada a melhor medida de média-variância de um portfólio em gestão ativa. Provavelmente o sucesso do *Information Ratio* se deve ao fato de que se trata de uma medida de aferição mais simples que o Alfa de Jensen ou Alfas baseados em modelos multifatoriais, e que consolida em um só número as dimensões de média e variância do paradigma de Markowitz (1952).

Além disso, ressalta-se que o *Information Ratio* é preferível ao Índice Sharpe (1966) porque ele próprio (o *Information Ratio*) é, segundo o próprio Sharpe (1994), a evolução do Índice Sharpe original. Enquanto que o Índice Sharpe leva em consideração o excesso de retorno do ativo em relação à taxa livre de risco, o *Índice Sharpe* permite que se adotem outros *benchmarks* mais adequados a diferentes classes de ativos. Por exemplo, ao se mensurar o desempenho de um portfólio de ações, faz mais sentido utilizar como *benchmark* o índice de mercado do que a taxa livre de risco. Por fim, considerando que, em geral, o *benchmark* da gestão ativa dos fundos de ações é o índice de mercado, o *Information Ratio* se demonstra uma medida adequada para avaliar a consistência do portfólio em superar o *benchmark* e ensejar a cobrança de taxa de performance.

### 3. REVISÃO DE LITERATURA

#### 3.1. Histórico da Estratégia de investimento em desempenho contrário

O trabalho científico seminal que investigou a capacidade da estratégia de investimento em desempenho contrário em gerar ganhos anormais (acima do mercado) e que apresentou explicações para o funcionamento da estratégia foi intitulado “*Does the Stock Market Overreact?*” e foi publicado em 1985 por Werner De Bondt e Richard Thaler. Os autores conjecturaram que, se as variações nos preços das ações são sistematicamente exageradas, então bastariam os dados de retornos passados para prever as reversões de tais movimentos. Eles propuseram duas hipóteses: (i) movimentos extremos nos preços das ações são seguidos por um subsequente movimento no sentido oposto; (ii) quanto mais extremo o movimento inicial, maior o subsequente ajuste. Ambas as hipóteses implicariam violação da forma fraca de eficiência de mercados (FAMA, 1970), e o objetivo dos autores foi o de testar empiricamente se é possível prever esse tipo de fenômeno (DE BONDT; THALER, 1985, p. 797). Os autores concluíram que portfólios compostos por ativos “perdedores” (isto é, ativos que tiveram desempenho histórico abaixo do mercado no passado) apresentaram um desempenho superior aos portfólios compostos por ativos “vencedores” (ou seja, ativos que desempenharam acima do mercado no passado). Tais achados constituiriam, segundo os autores, evidência do chamado *overreaction effect*, uma forma fraca de ineficiência de mercado que faria com que a maior parte dos agentes reagisse de forma exagerada a eventos dramáticos e inesperados.

A partir do artigo de De Bondt e Thaler (1985), houve intensa pesquisa científica sobre o tema do investimento em desempenho contrário. Chan (1988), utilizando o CAPM, observou que os betas de ações “perdedoras” aumentam após períodos de perdas anormais, o que significa um aumento do risco relativo do ativo e, conseqüentemente, um aumento do retorno esperado. Desse modo, Chan (1988), considerando essa variação nos betas, argumentou que não é adequado utilizar os betas observados no passado para estimar o retorno futuro e que os retornos supostamente anormais dos ativos perdedores se deviam ao aumento do risco. Em suma, Chan (1988) argumentou não ter encontrado fortes evidências de reações exageradas do mercado e que a estratégia de investimento em desempenho contrário geraria retornos anormais economicamente<sup>4</sup> insignificantes.

---

4 Quando a literatura fala sobre ganhos economicamente significativos, em geral isso significa ganhos substanciais suficientes para serem de interesse de investidores e gestores de carteiras de investimento.



Lo e MacKinlay (1990) argumentaram que a reação exagerada dos mercados não é a única explicação para os lucros de uma estratégia de investimento em desempenho contrário e que evidências empíricas indicam que a maior parte desses lucros se deve na realidade à existência de autocorrelações seriais cruzadas entre os ativos negociados em bolsa e que a estratégia de investimento em desempenho contrário inadvertidamente se beneficia dessas correlações. Dessa forma, ao se implementar uma estratégia de investimento em desempenho contrário que consiste em vender o ativo vencedor (A) e comprar o ativo perdedor (B), seria possível auferir lucro mesmo sem a necessidade de efeito de reação exagerada, isto é, sem a necessidade de autocorrelação negativa individual das ações.

Kryzanowski e Zhang (1992) testaram a estratégia de investimento em desempenho contrário na bolsa de valores de Toronto com dados de 1950 a 1988 e observaram que, ao contrário de De Bondt e Thaler (1985, 1987), não foram encontradas reversões estatisticamente significativas mesmo após 10 da formação da carteira.

Da Costa Jr. (1994) analisou a estratégia de investimento em desempenho contrário no Brasil com dados de 1970 a 1989 e encontrou evidências que corroboram a hipótese de reação exagerada dos mercados conforme apresentado no artigo seminal de De Bondt e Thaler (1985). Da Costa Jr. (1994) observou que o efeito no Brasil é até mais acentuado do que o observado nos Estados Unidos e que o efeito de reação exagerada se mostrou aparentemente mais pronunciado durante a extrema volatilidade de meados dos anos de 1980. Por fim, vale ressaltar que Da Costa Jr. (1994) observou que a estratégia gerou um Alfa de Jensen (1968) médio positivo, o que significa que o CAPM por si só seria incapaz de explicar o resultado da estratégia. Em outras palavras, o desempenho da estratégia de investimento em desempenho contrário no Brasil, segundo Da Costa Jr. (1994) não se explica integralmente por um maior risco sistêmico (*beta*).

Chang *et al.* (1995) constataram a existência de ganhos anormais ao se adotar a estratégia de investimento em desempenho contrário de curto prazo (de um a seis meses) na bolsa de valores de Tóquio. Os autores destacam que a estratégia continua gerando retornos anormais mesmo quando se levam em consideração o risco sistêmico e o tamanho da firma.

Ball *et al.* (1995) exploraram problemas na mensuração do desempenho de portfólios, observaram que boa parte da lucratividade da estratégia *contrarian* é causada pelos baixos preços de ações perdedoras e concluíram que os resultados dos estudos como os de De Bondt e Thaler (1985, 1987) e Chan (1988) deveriam ser vistos com ceticismo.

Galariotis (2014, p. 73) observou que grande parte do interesse acerca do tema do investimento em desempenho contrário diminuiu significativamente a partir da publicação do

artigo “*Multifactor Explanations of Asset Pricing Anomalies*” de Eugene Fama e Kenneth French em 1996. Isso ocorreu porque Fama e French (1996), por um lado, reconheceram que as reversões identificadas por De Bondt e Thaler (1985, 1987) não eram explicadas pelo CAPM (SHARPE, 1964; LINTNER, 1965), mas por outro lado, argumentaram que os padrões de retornos futuros de portfólios formados com base em retornos passados poderiam ser explicados pelo Modelo de Três Fatores de Fama e French (1993). O fundamento apresentado por Fama e French (1996, p. 66–68) foi o de que ativos perdedores de longo prazo no passado se comportam como empresas pequenas e em dificuldade (que apresentariam elevado *book-to-market*), portanto, o Modelo de Três Fatores prevê que ativos perdedores de longo prazo no passado irão apresentar maiores retornos médios no futuro.

O argumento apresentado por Fama e French (1996) foi corroborado por Clements *et al.* (2009). Utilizando dados de ações estadunidenses de 1926 a 2003, eles verificaram que, de fato, a estratégia inicialmente apresentada por De Bondt e Thaler (1985) gera retornos nominais<sup>5</sup> acima do mercado, o que poderia sugerir a existência da anomalia de reação exagerada dos agentes (CLEMENTS, 2009, p. 77). No entanto, eles concluíram que, ao se utilizar o Modelo de Três Fatores de Fama e French (1993), não é possível obter Alfa<sup>6</sup> estatisticamente significativo para a estratégia de investimento em desempenho contrário e que os resultados acima do mercado logrados pela estratégia são obtidos às custas do aumento do risco (CLEMENTS *et al.*, 2009, p. 82). Clements *et al.* (2009) também abordaram o “efeito janeiro”, que havia sido observado por De Bondt e Thaler (1985, p. 804) e que consistiria no fato de que portfólios “perdedores” (isto é, compostos por ativos que desempenharam mal do passado) apresentariam um retorno significativamente maior nos meses de janeiro. O que Clements *et al.* (2009, p. 80) argumentaram foi que, ao se utilizar o Modelo de Três Fatores de Fama e French (1993), a inclusão de uma variável *dummy* referente ao mês de janeiro aumentava somente marginalmente o poder do modelo, o que indicava que o “efeito janeiro”, se existisse, era pouco importante.

Mesmo com o arrefecimento do debate após a explicação de Fama e French (1996, p. 66–68), alguns autores continuaram explorando as causas e buscando explicações para o sucesso da estratégia de investimento em desempenho contrário ao redor do mundo. É o caso de Schiereck *et al.* (1999), que analisaram a estratégia de investimento em desempenho

---

5 Por “retornos nominais” neste contexto, entendam-se retornos sem qualquer ajuste por risco.

6 Conforme explicado anteriormente, e considerando que os autores utilizam o Modelo de Três Fatores de Fama e French (1993) para estimar os retornos dos ativos (portfólios), entende-se que, nesse caso, “Alfa” seria a diferença entre o retorno observado e o retorno esperado pelo Modelo de Três Fatores, e não o Alfa de Jensen (1968) que utiliza como referência o CAPM.

contrário na bolsa de valores de Frankfurt com dados de 1961 a 1991 e constataram que a estratégia gerou ganhos superiores à gestão passiva de carteiras e que tais ganhos eram economicamente significativos. O que mais chamou a atenção dos autores foi que, apesar das importantes diferenças institucionais (mercados organizados de maneira distinta), culturais, sociais e de ambiente econômico, os resultados observados na Alemanha foram surpreendentemente parecidos com o que havia sido observado nos Estados Unidos. Por isso, os autores conjecturam que traços inerentes à psicologia e ao comportamento humano superariam essas diferenças e imprimiriam padrões na dinâmica de preços nos mercados financeiros.

Sehgal e Balakrishnan (2002) analisaram a estratégia de investimento em desempenho contrário de longo prazo na bolsa de valores da Índia e concluíram que a estratégia era capaz de gerar ganhos positivamente moderados, mas desde que fosse mantido um intervalo de um ano entre o período de formação do portfólio e o início do período de sua manutenção/maturação. Ou seja, após avaliar o desempenho histórico dos ativos que seriam incluídos no portfólio, dever-se-ia, segundo autores, esperar um ano antes de adquiri-los. O objetivo desse intervalo seria o de controlar o efeito *momentum* que faria com que as ações que desempenharam mal no passado continuassem desempenhando mal no curto prazo antes de iniciar a reversão.

Fornier e Marhuenda (2003) atestaram a possibilidade de êxito da estratégia de investimento em desempenho contrário de longo prazo (60 meses) na bolsa de valores da Espanha.

Lee *et al.* (2003) investigaram a estratégia de investimento em desempenho contrário de curto prazo na bolsa de valores da Austrália com dados de 1994 a 2001. Eles observaram que, em média, a maior parte dos lucros da estratégia de investimento em desempenho contrário advinham de reações exageradas relacionadas a firmas. No entanto, eles observaram que, ao incluir custos de transação em suas simulações, a estratégia deixava de ser lucrativa.

Assoé e Sy (2003) analisaram a estratégia de investimento em desempenho contrário de curto prazo na bolsa de valores do Canadá com dados de 1964 a 1998 e concluíram que, mesmo utilizando o Modelo de Três Fatores de Fama e French (1993), a estratégia se mostrou lucrativa. No entanto, considerando que a estratégia de curto prazo era intensiva em compras e vendas de ações, os autores ponderam que, ao levar em consideração custos de transação, a estratégia só se mostrou lucrativa para firmas pequenas.

Antoniou *et al.* (2006) investigaram estratégias de investimento em desempenho contrário de curto prazo na bolsa de valores de Londres com dados de 1984 a 2000 e

concluíram que mesmo um modelo de três fatores similar ao utilizado por Fama e French (1996) era incapaz de explicar integralmente os significativos retornos da estratégia, mesmo levando em consideração custos de transação, problemas de negociações infrequentes, vieses de *bid-ask* e risco. Os autores observaram que a maior parte dos lucros da estratégia de investimento em desempenho contrário de curto prazo advinham de reações exageradas relacionadas às firmas e que ações “perdedoras” eram menos arriscadas que ações “vencedoras”, uma vez que os ganhos da estratégia de investimento em desempenho contrário aumentavam quando se tem em vista o retorno ajustado pelo risco. Os autores complementaram que suas descobertas quanto a estratégia no curto prazo estavam de acordo com o que já havia sido concluído em trabalhos que analisavam a estratégia no longo prazo. Por fim, Antoniou *et al.* (2006) reforçaram que suas conclusões contrariavam a hipótese de eficiência de mercados.

Ramiah *et al.* (2011) também atestaram a lucratividade da estratégia de investimento em desempenho contrário para a bolsa de valores de Hong Kong e concluíram que o Modelo de Três Fatores de Fama e French (1993) não era capaz de explicar integralmente o fenômeno.

Gottesman *et al.* (2017) investigaram se o sucesso das estratégias *contrarian* se devia na verdade à falta de liquidez das ações contidas nos portfólios que adotam essas estratégias. Os autores concluíram que existiam evidências que apontam no sentido de que os maiores retornos associados às estratégias de investimento em desempenho contrário são resultado da falta de liquidez das ações. A explicação apresentada é a de que investidores exigem retornos maiores de ações com menos liquidez e que as estratégias *contrarian* fazem com que o investidor adquira ações com baixa liquidez. Além disso, os autores recomendaram cautela dos pesquisadores ao atribuir a aspectos comportamentais dos agentes a ocorrência de aparentes anomalias do mercado ao invés de atribuírem estes fenômenos a atributos não comportamentais como a própria iliquidez dos ativos.

De qualquer modo, apesar dos trabalhos apresentando evidências (em especial as que corroboram a existência de reação exagerada nos mercados) contrárias aos argumentos de Fama e French (1996), é de fato perceptível, conforme observado por Galariotis (2014), que após esse trabalho houve uma diminuição do interesse acadêmico sobre o tema.

Apesar de ainda existir algum debate sobre as causas dos ganhos acima do mercado ao se adotar a estratégia de investimento em desempenho contrário, parece haver evidência suficiente de que esse tipo de estratégia é capaz de gerar ganhos acima do mercado em vários países ao redor do mundo. Seja porque os mercados exageram a notícias negativas (hipótese

do artigo seminal de De Bondt e Thaler (1985) e corroborada em outros trabalhos), seja porque ativos perdedores se comportam como empresas pequenas e em dificuldade (tese defendida por Fama e French (1996) e que arrefeceu o debate sobre o tema), seja por causa da existência de correlação serial cruzada conforme levantado por Lo e MacKinlay (1990), fato é que a maior parte da literatura sobre o tema indica que é sim possível obter ganhos (não ajustados por risco) acima do mercado em várias bolsas de valores ao redor do mundo ao se adotar a estratégia de investimento em desempenho contrário. Trata-se de um fenômeno bastante estudado desde 1985, e tudo que é necessário para implementá-lo é essencialmente o conhecimento dos retornos passados das ações negociadas em bolsa. Ou seja, apesar de ser uma estratégia de implementação complexa (existem vários parâmetros de implementação, conforme destrinchado na seção 4.5.1), não existem barreiras técnicas realmente impeditivas para que provavelmente a maior parte das gestoras de investimento a implementem.

É interessante notar que, apesar da literatura sobre o tema corroborar a efetividade da estratégia há anos, Lakonishok *et al.* (1994) apresentam algumas explicações de por que a estratégia não é amplamente utilizada. A primeira delas é referente aos investidores individuais que, segundo os autores, seriam susceptíveis a dar importância exagerada ao passado recente e, conseqüentemente, a pressupor que empresas repetirão esse desempenho no futuro. Essa tendência seria reforçada pela sugestão de corretores que recomendam a aquisição de “boas” empresas. Quanto aos investidores institucionais, os autores ressaltam que a princípio eles seriam menos susceptíveis aos vieses de julgamento observados nos investidores individuais, mas que ainda assim eles tenderiam a comprar ações de empresas que desempenharam bem no passado recente porque, assim, eles mostrar-se-iam mais prudentes aos olhos de seus clientes. Além disso, segundo os autores e coerente com o que a literatura chama de efeito *momentum*, empresas que desempenharam bem no passado recente provavelmente irão desempenhar bem no futuro próximo. Gestores de recursos de terceiros muitas vezes não podem desempenhar abaixo do *benchmark* ou de outros fundos no curto prazo sob pena de perderem clientes. Dessa forma, pode ser difícil convencer clientes a investirem em um fundo cuja estratégia desempenhe abaixo do *benchmark* no curto prazo e que só comece a desempenhar acima do *benchmark* a partir, por exemplo, do terceiro ou do quinto ano. Um gestor pode ser demitido antes da estratégia começar a funcionar.

Outra interessante reflexão de Lakonishok *et al.* (1994) é se os retornos anormais da estratégia de investimento em desempenho contrário iriam persistir no futuro. Os autores, em 1994, previram que, com o passar do tempo, mais investidores iriam se convencer dos retornos de longo prazo da estratégia de investimento em desempenho contrário, o que iria

fazer com que os retornos da estratégia caíssem<sup>7</sup>. Os autores também imaginavam a possibilidade de uma maior adesão a estratégias de investimento quantitativas baseadas exclusivamente na performance do portfólio, e não em escolhas individuais de ações. A existência de artigos científicos relativamente recentes (menos de dez anos) atestando a persistência dos retornos anormais da estratégia de investimento em desempenho contrário sugere que o movimento previsto pelos autores de Lakonishok *et al.* (1994) ainda não está finalizado ou, talvez, sequer tenha tido início.

### 3.2. Lacunas na Literatura

Nesta seção 3.2, será apresentado como os artigos referenciados na revisão da literatura trataram dos principais parâmetros necessários para implementar a estratégia de investimento em desempenho contrário e quais aspectos não foram suficientemente explorados.

#### 3.2.1. Critério de Formação (seleção das ações)

O primeiro passo para implementar a estratégia de investimento em desempenho contrário é definir quais ações podem ser consideradas “perdedoras” e, para tanto, é necessária uma medida de desempenho que servirá como critério de formação. A Tabela 1 apresenta quais foram os critérios de formação utilizados pelos artigos objeto da presente revisão de literatura.

Tabela 1: Critérios de Formação na Literatura

TRABALHO	CRITÉRIO DE FORMAÇÃO	COMENTÁRIO
De Bondt e Thaler (1985, 1987) <sup>8</sup>	$R_j - R_m$ em que $R_j$ é o retorno da ação analisada, e $R_m$ é o retorno do índice representativo de mercado <sup>9</sup> .	Considerando que o retorno do mercado é igual para todas as ações (já que se está comparando ações em um mesmo mercado ao longo de um mesmo período de tempo), e considerando que o objetivo é criar um <i>ranking</i> de desempenho das ações para escolher as que desempenharam pior, o

7 Isso aconteceria porque, ao observar um queda acentuada em uma ação, os investidores da estratégia de investimento em desempenho contrário iriam adquiri-la, fazendo com que, na prática, a queda não fosse tão acentuada. Isso geraria uma reversão menos intensa e, conseqüentemente, um menor desempenho da estratégia.

8 De Bondt e Thaler (1985, p. 797) informam que chegaram a testar outros critérios de desempenho baseados no CAPM, mas que problemas de má especificação no modelo poderiam confundir os resultados.

9 Isto é, o excesso de retorno em relação ao mercado, que consiste na diferença entre o retorno da ação e o retorno da carteira representativa do mercado em um mesmo período.

		critério de excesso de retorno ( $R_j - R_m$ ) equivale a utilizar o próprio retorno das ações.
Chan (1988, p. 149)	$R_j - R_m$	
Lo e MacKinlay (1990, p. 6)		
Kryzanowski e Zhang (1992)		
Da Costa (1994, p. 636) <sup>10</sup> .		
Schiereck <i>et al.</i> (1999, p. 107)		
Fornier e Marhuenda (2003, p. 71)		
Fama e French (1996, p. 66)	$R_{je}$ , isto é, o retorno composto contínuo da ação	Isso também equivale a utilizar a taxa de retorno das ações em um mesmo período considerando o objetivo de ranquear as ações por desempenho.
Antoniou <i>et al.</i> (2006, p. 7)	$R_{je}$	
Chang <i>et al.</i> (1995, p. 1037)	$R_{jm}$ , isto é, o retorno mensal da ação	
Clements <i>et al.</i> (2009, p. 77)	$R_{jm}$	
Kang <i>et al.</i> (2002, p. 248)	$R_j$	Utilizam o retorno das ações ao longo de uma semana sem qualquer ajuste de periodicidade, isto é, sem converter de “retorno semanal” para “retorno anual”, por exemplo.
Lee <i>et al.</i> (2003, p. 7)		Também utilizam o retorno das ações ao longo de uma semana sem qualquer ajuste de periodicidade.
Sehgal e Balakrishnan (2002, p. 16)	$\mu(R_j)$	Utilizam os retornos médios dos trinta e seis meses anteriores, sem qualquer ajuste de risco.
Assoé e Sy (2003, p. 312)	$R_j$	Utilizam os retornos do mês anterior, sem ajuste de risco.
Ramiah <i>et al.</i>		Utilizam o retorno da ação, sem ajuste de risco,

<sup>10</sup> Da Costa (1994, p. 636), assim como De Bondt e Thaler (1985, p. 797), informa que durante a pesquisa também foi utilizada uma medida de retorno ajustada pelo CAPM, mas que os resultados foram muito similares à utilização do excesso de retorno em relação ao mercado (diferença entre o retorno da ação e o retorno de uma carteira representativa do mercado).

(2011, p. 9).		durante um período de formação variável <sup>11</sup> .
---------------	--	---

Fonte: elaboração própria.

Percebe-se, portanto, que a medida de desempenho utilizada como critério de formação em todos os estudos acima mencionados é essencialmente o retorno das ações sem ajuste pelo risco sistêmico (beta no modelo CAPM) ou pela volatilidade. Trata-se de uma lacuna na literatura.

Como a estratégia de investimento em desempenho contrário consiste em selecionar os “perdedores”, isto é, os que desempenharam pior, deveria haver uma preocupação maior em garantir que a medida de desempenho é adequada para medir a performance do ativo. Ou seja, considerando a estratégia de investimento em desempenho contrário, qual é a melhor medida de desempenho a ser utilizada para selecionar as ações “perdedoras”? É possível que a adoção de medidas ajustadas à volatilidade (como o Índice Sharpe) ou ao risco de mercado (como o CAPM) sejam mais precisas ao identificarem as ações perdedoras e, portanto, sejam melhores em uma estratégia que consiste em, justamente, adquirir ativos perdedores contando com a reversão, na média, dos seus desempenhos. Os critérios de formação adotados no presente trabalho são apresentados na seção 4.5.1.1.

### 3.2.2. *Período de Formação*

Uma vez definido o critério de formação, é necessário determinar o período de tempo sobre o qual ele será aplicado. Em outras palavras, é preciso estabelecer por quanto tempo será mensurado o desempenho histórico de uma ação. A Tabela 2 apresenta os períodos de formação dos artigos revisados no presente estudo.

Tabela 2: *Períodos de Formação na Literatura*

TRABALHO	PERÍODOS DE FORMAÇÃO	COMENTÁRIO
De Bondt e Thaler (1985, p. 799)	1, 2, e 5 anos	
Chan (1988, p. 149)	3 anos	
Fama e French (1996, p. 66)	11, 23, 35, 47, 59 e 48 meses	
Lo e MacKinlay (1990, p. 20)	1 semana	Utilizam uma abordagem de curto prazo comparando o desempenho de ações entre

11 O período de formação nos trabalhos será melhor explicado adiante.



		uma semana e outra.
Da Costa (1994, p. 636)	2 anos	
Chang <i>et al.</i> (1995, p. 1037)	Utilizam o retorno do mês anterior.	O artigo deixa isso implícito ao dizer que utiliza como critério de formação os retornos mensais.
Schiereck <i>et al.</i> (1999, p. 107)	5 anos	
Kang <i>et al.</i> (2002, p. 248)	1, 2, 4, 8, 12, 16, 20 e 26 semanas	
Sehgal e Balakrishnan (2002, p. 15)	36 meses	
Fornier e Marhuenda (2003, p. 71)		
Lee <i>et al.</i> (2003, p. 7)	1 semana	Utilizam a semana anterior como período de formação.
Antoniou <i>et al.</i> (2006, p. 12)		
Assoé e Sy (2003, p. 312)	1 mês	Utilizam o mês anterior como período de formação.
Clements <i>et al.</i> (2009, p. 78)	3, 4 e 5 anos	
Ramiah <i>et al.</i> (2011, p. 21)	1, 3 e 6 anos	
Kryzanowski e Zhang (1992, p. 385)	12, 24, 36, 60, 96 e 120 meses	

Fonte: elaboração própria.

Quanto aos períodos de formação adotados pela literatura, é possível apresentar três pontos que podem ser melhorados. Como esses três pontos guardam relação direta com três aspectos que também precisam ser melhorados quanto à definição dos períodos de maturação dos portfólios, eles serão apresentados ao final da seção 3.2.3.

### 3.2.3. Período de Maturação

A estratégia de investimento em desempenho contrário consiste em aguardar que ações que desempenharam mal no passado desempenhem bem no futuro. Para tanto, é

necessário que se aguarde por determinado período de tempo para que haja essa reversão. Trata-se do que a literatura em geral chama de “período de teste” e que, no presente trabalho, será chamado de “período de maturação”<sup>12</sup>. A Tabela 3 apresenta os períodos de maturação adotados nos artigos revisados no presente trabalho.

*Tabela 3: Períodos de Maturação na Literatura*

<b>TRABALHO</b>	<b>PERÍODOS DE MATURAÇÃO</b>	<b>COMENTÁRIO</b>
De Bondt e Thaler (1985, p. 799) .	1, 2, e 5 anos	
Chan (1988, p. 149).	3 anos	
Fama e French (1996, p. 66).	(vide comentário ao lado)	Os autores não falam explicitamente o período de maturação dos portfólios, mas tudo indica que são os mesmos dos períodos de formação.
Lo e MacKinlay (1990, p. 20).	1 semana	
Da Costa (1994, p. 637).	2 anos	
Chang <i>et al.</i> (1995, 1037).	6 meses	
Schiereck <i>et al.</i> (1999, p. 107)	5 anos	
Kang <i>et al.</i> (2002, p. 248).	1, 2, 4, 8, 12, 16, 20 e 26 semanas	
Sehgal e Balakrishnan (2002, p. 15).	12 meses.	
Fornier e Marhuenda (2003, p. 71).	36 meses	
Lee <i>et al.</i> (2003, p. 7)	1 semana	
Antoniou <i>et al.</i> (2006, p. 12)		

<sup>12</sup> Conforme será explicado na seção Metodologia, “período de teste”, no presente estudo, é a parcela dos dados que não foi utilizada para estimar dos parâmetros ótimos da estratégia (amostra) e que servirá para se avaliar como esses parâmetros ótimos desempenham fora da amostra.

Assoé e Sy (2003, p. 312).	1 mês	
Clements <i>et al.</i> (2009, p. 78).	3, 4 e 5 anos	
Ramiah <i>et al.</i> (2011, p. 21).	1, 3, 6, 9 e 12 anos	
Kryzanowski e Zhang (1992, p. 385).	12, 24, 36, 60, 96 e 120 meses	

Fonte: elaboração própria.

Quanto à definição do prazo de formação e maturação das carteiras, percebem-se três aspectos na literatura que podem ser melhor explorados. O primeiro é o de que, na maioria dos trabalhos, como em De Bondt e Thaler (1985, p. 799), Chan (1988, p. 149), Da Costa (1994, p. 637), Kryzanowski e Zhang (1992, p. 385), Schiereck *et al.* (1999, p. 107), Forner e Marhuenda (2003, p. 71), Lee *et al.* (2003, p. 7), Assoé e Sy (2003, p. 312), e Antoniou *et al.* (2006, p. 12), o período de formação e o período de maturação da carteiras em cada simulação são os mesmos. Isto é, trabalha-se nesses artigos com “ciclos” em que: analisam-se X anos do passado, compram-se os ativos perdedores, mantém-se a carteira comprada por mais X anos, e, ao final do ciclo, ele se repete analisando-se X anos do passado e assim por diante. É por isso que De Bondt e Thaler (1985, p. 799) chegam a dizer, como se fosse uma consequência natural, que o número de replicações independentes do experimento ao longo de um período de tempo varia de forma inversamente proporcional ao período de formação<sup>13</sup>. Ocorre que, a rigor, o que define o número possível de experimentos independentes ao longo de um período de tempo é, principalmente, o tamanho do período de maturação (que a literatura chama de período de testes), e não o período de formação, já que é pelo período de maturação que a carteira será acompanhada<sup>14</sup>. Os prazos de formação e maturação não guardam entre si a necessidade de coincidência já que se tratam de parâmetros de implementação da estratégia completamente diferentes. Um parâmetro é a quantidade de tempo passado necessário para avaliar adequadamente se uma ação é “perdedora”, outro parâmetro diferente é o tempo médio necessário para que a ação deixe de ser “perdedora” e se torne uma “vencedora”. Nada

13 “However, for selected experiments, the portfolio formation (and testing) periods are one, two, and five years long. Clearly, the number of independent replications varies inversely with the length of the formation period.” (DE BONDT; THALER, 1985, p. 799).

14 O tamanho do período de formação também impacta o número de replicações independentes da estratégia, mas de forma secundária. É que o primeiro período de maturação só pode começar ao final do primeiro período de formação, já que é necessário analisar o desempenho das ações durante o período de formação para se determinar o portfólio que será acompanhado ao longo do período de maturação.

impede, dessa forma, que o período de formação e de maturação sejam diferentes. Por exemplo, ao longo de um período total de dez anos de dados de ações, é possível que o período de formação seja de dois anos e o período de maturação seja de um ano. Nesse caso, seriam oito ciclos de maturação de um ano (o primeiro se iniciando ao final do segundo ano, e o último terminando ao final do décimo ano), sendo que em todos eles foram analisados os dois anos anteriores para definir as ações que seriam incluídas no portfólio. Apesar de alguns trabalhos como Chang *et al.* (1995), Kang *et al.* (2002, p. 248)<sup>15</sup>, Ramiah *et al.* (2011, p. 21), e Clements *et al.* (2009, p. 78) utilizarem períodos de formação diferentes dos períodos de maturação, ainda há espaço na literatura para trabalhos que explorem de maneira clara e categórica que esses dois parâmetros de implementação da estratégia podem ser diferentes.

O segundo aspecto que pode ser melhorado é referente aos períodos de formação e maturação. Todos os artigos mencionados na presente revisão de literatura adotam valores arbitrários de períodos de formação e maturação<sup>16</sup>. Como a estratégia consiste em manter um portfólio de “perdedores” até que ocorra uma reversão do resultado observado no passado, é muito importante que se acerte tanto o tempo necessário para avaliar de forma adequada se uma ação é “perdedora” quanto o *timing* da maturação.

Considerando a lógica de reversões dos ativos ao longo do tempo, que é o raciocínio que sustenta a estratégia de investimento em desempenho contrário, um período de formação curto demais pode significar uma quantidade de informação insuficiente para avaliar que uma ação é “perdedora”. Mas um período de formação longo demais pode acabar captando não apenas a queda da ação mas também o início de sua reversão. Da mesma forma, um período de maturação curto demais pode fazer com que as ações sejam vendidas antes do início da recuperação. Entretanto, um período de maturação longo demais pode acabar se estendendo até o início da próxima queda do desempenho da ação. Além disso, a princípio, não parece haver motivo para que o comportamento do mercado necessariamente coincida com valores “redondos” arbitrariamente definidos pelos autores, como, por exemplo, um, dois, três, ou cinco anos.

O terceiro aspecto que pode ser melhorado na literatura é quanto à separação ora existente em estratégias de investimento em desempenho contrário de curto prazo (envolvendo semanas ou meses) ou de longo prazo (a partir de um ano). Se o objetivo da estratégia de investimento em desempenho contrário é obter ganhos acima do mercado, a

15 "We consider eight different horizons (i.e., 1, 2, 4, 8, 12, 16, 20 and 26 weeks) for both formation (F) and holding (H) periods. As there are eight periods for both formation (F) and holding (H) periods, we have 64 (8 x 8) different investment strategies" (KANG *et al.* 2002, p. 248).

16 Outros artigos justificam os prazos de formação e maturação com base nos prazos que tinham sido anteriormente utilizados por outros artigos (que por sua vez escolheram esses valores arbitrariamente).

rigor, não faz diferença se a periodicidade da estratégia é de semanas ou de anos. Evidentemente que, em estratégias com maior frequência de compras e vendas, os custos de transação são mais significativos. No entanto, uma vez que esses custos estejam sendo adequadamente levados em consideração, o que importa para o investidor ou para o gestor de carteiras é a capacidade da estratégia de desempenhar acima do mercado. A percepção de que “curto prazo” e “longo prazo” são categorias que não necessariamente fazem sentido em termos dos objetivos da estratégia é especialmente relevante ao se levar em consideração a possibilidade de ser bem sucedida uma estratégia que tenha o período de formação no “curto prazo” e período de maturação no “longo prazo”. Por exemplo, se o objetivo do investidor for explorar reações exageradas do mercado a notícias negativas, uma possibilidade de implementação da estratégia pode ser a de comprar as ações que desempenharam mal nos três meses anteriores e mantê-las no portfólio por um ano e meio. Somente a análise empírica é capaz de dizer se uma estratégia com esses parâmetros desempenha bem. Mas é importante que essa combinação de “curto prazo” e “longo prazo” nos períodos de formação e maturação seja investigada.

#### 3.2.4. Número de Ações

Ao implementar a estratégia de investimento em desempenho contrário, é necessário definir quantas ações serão incluídas no portfólio. A Tabela 4 apresenta os números de ações nos portfólios dos artigos revisados.

Tabela 4: Número de Ações na Literatura

TRABALHO	NÚMERO DE AÇÕES	COMENTÁRIO
De Bondt e Thaler (1985, p. 797)	35, 50, e o decil inferior do total de ações analisadas (o que, em média, equivaleu no estudo a 82 ações)	
Chan (1988, p. 149)	Trinta e cinco ações e o decil inferior das ações analisadas.	
Lo e MacKinlay (1990)	Quartil inferior das ações analisadas	
Kryzanowski e Zhang (1992, p. 386)		
Kang <i>et al.</i> (2002, p. 248)		

Sehgal e Balakrishnan (2002, p. 15)		
Antoniou <i>et al.</i> (2006, p. 842)		
Da Costa Jr. (1994)	(vide comentário ao lado)	O autor não explica no artigo qual o critério utilizado para definir o número “n” de ações em cada portfólio, mas ele deixa claro que o tamanho varia ao longo do tempo <sup>17</sup> .
Chang <i>et al.</i> (1995, p. 1037)	Decil inferior das ações analisadas	
Fama e French (1996, p. 66)		
Assoé e Sy (2003, p. 312)		
Ramiah <i>et al.</i> (2011, p. 9)		
Schiereck <i>et al.</i> (1999, p. 110)	20 ações	
Fornier e Marhuenda (2003, p. 71)	5 ações	
Lee <i>et al.</i> (2003)	(vide comentário ao lado)	Os autores não informam a quantidade de ações nos portfólios.
Clements <i>et al.</i> (2009, p. 84)	35 ações	

Fonte: elaboração própria.

A revisão da literatura demonstra que o número de ações nos portfólios dos estudos é definido arbitrariamente sem se explicar porque se optou por esta ou aquela quantidade. Trata-se de um parâmetro importantíssimo de implementação da estratégia de investimento em desempenho contrário. Por um lado, se forem adquiridas poucas ações, corre-se o risco de estarem sendo adquiridas somente ações de empresas à beira da falência (e justamente por isso é que elas estão posicionadas por último no *ranking* de desempenho) e que podem não se recuperar. Além disso, um portfólio composto por ações de poucas empresas pode não estar diversificado o suficiente, o que pode fazer com que ele apresente uma volatilidade muito alta e/ou ainda esteja muito exposto ao risco idiossincrático das ações que o compõe. Por outro lado, se forem incluídas muitas ações no portfólio, corre-se o risco de estarem sendo

17 “In 1974 each portfolio contained about 9 stocks and about 18 stocks in 1989” (DA COSTA, 1994, p. 637).

adquiridas empresas que não são “perdedoras” o suficiente e que, conseqüentemente, não apresentarão uma reversão suficientemente grande para que o portfólio desempenhe acima do mercado. Dessa forma, é possível que haja uma quantidade média ideal de ações a serem incluídas no portfólio<sup>18</sup>.

### 3.2.5. Distribuição dos Pesos

Uma vez definida quais e quantas ações serão incluídas no portfólio, é necessário estabelecer o critério de distribuição dos pesos (participação percentual) de cada ativo no portfólio. Ou seja, é preciso determinar quantos por cento cada ação irá representar do total da carteira. A Tabela 5 apresenta quais critérios de distribuição de pesos foram adotados.

Tabela 5: Critérios de Distribuição de Pesos na Literatura

TRABALHO	DISTRIBUIÇÃO DE PESOS	COMENTÁRIO
De Bondt e Thaler (1985, p. 1987)	1/N	Em De Bondt e Thaler (1985, p. 798), como se diz que é calculada a média dos retornos de cada ativo em cada mês, é possível concluir que a distribuição dos pesos no portfólio é igualitária.
Chan (1988)		O autor não explicita o tipo de distribuição. Presume-se que seja igualitária/ingênua.
Schiereck (1999)		O autor não explicita o tipo de distribuição. Presume-se que seja igualitária/ingênua.
Lo e MacKinlay (1990, p. 7)	Utilizaram tanto uma distribuição igualitária (1/N) quanto uma distribuição inversamente proporcional ao desempenho do ativo, de modo que, quanto pior o seu desempenho, maior sua participação percentual no portfólio <sup>19</sup> .	
Kryzanowski e	Utiliza portfólios baseados em tamanho	

18 Statman (1987) conclui que um portfólio sem alavancagem precisa ter pelo menos quarenta ações para ser considerado suficientemente diversificado. No entanto, seu estudo foi feito para portfólios de ações escolhidas aleatoriamente, ao contrário do que acontece ao se implementar a estratégia de investimento em desempenho contrário em que se escolhem ações baseadas em algum critério de desempenho. Portanto, não necessariamente as conclusões alcançadas por Statman (1987) são aplicáveis ao objeto do presente estudo. Além disso, a análise de Statman (1987) se limitou a constatar a quantidade mínima de ações para se obter um portfólio diversificado. O presente estudo visa, conforme já esclarecido, criar um método que maximize o *Information Ratio* de um portfólio ao se implementar a estratégia de investimento em desempenho contrário.

19 O objetivo dessa estratégia de distribuição baseada no desempenho do ativo é o de explorar a hipótese de que, quanto maior a reação exagerada incidente sobre uma ação, maior tende a ser a correção/reversão do desempenho observado.

Zhang (1992, p. 386)	segundo o procedimento em Fama e French (1986).	
Da Costa (1994, p. 637)	1/N	
Chang <i>et al.</i> (1995, p. 1037)		
Fama e French (1996, p. 64)		
Sehgal e Balakrishnan (2002)		
Forner e Marhuenda (2003)		
Assoé e Sy (2003).		
Antoniou <i>et al.</i> (2006)		
Clements <i>et al.</i> (2009)		
Ramiah <i>et al.</i> (2011)		
Lee <i>et al.</i> (2003, p. 7)		Utilizam tanto a distribuição igualitária (1/N) quanto uma distribuição baseada no valor das companhias.
Kang <i>et al.</i> (2002, p. 248)	1/N	

Fonte: elaboração própria.

Percebe-se, portanto, que a maior parte dos artigos referenciados acima utiliza a distribuição igualitária ao testar a estratégia de investimento em desempenho contrário e uma minoria dos trabalhos utiliza outros critérios como a distribuição por valor de mercado da companhia ou, no caso de Lo e MacKinlay (1990), uma distribuição baseada no desempenho das ações. Ou seja, os trabalhos sobre a estratégia de investimento em desempenho contrário não abordam a distribuição dos pesos por uma ótica de otimização de média e variância. Conforme Markowitz (1952), um investidor racional deve distribuir os pesos dos ativos em um portfólio de modo a obter um portfólio eficiente, isto é, um portfólio que proporciona o maior retorno estimado para um dado risco estimado ou, equivalentemente, um menor risco estimado para um dado retorno estimado. Ocorre que, para fazer essa otimização de média-variância, é necessário, na maior parte dos casos, que se faça uma estimativa do retorno futuro



de cada ativo no portfólio. Uma solução ingênua poderia ser utilizar a média história de retornos do ativo como uma estimativa de retorno futuro. Mas essa solução é incoerente com a própria hipótese da estratégia de investimento em desempenho contrário que é a de que se espera que haja, em média, uma reversão do desempenho observado de uma ação. Outra possível solução, mais sofisticada, seria utilizar algum modelo de precificação de ativos financeiros como CAPM (SHARPE, 1964; LINTNER, 1965) ou o Modelo de Três Fatores de Fama e French (1993) para estimar os retornos das ações em um portfólio. Mas, além de tornar a implementação da estratégia mais complexa e demandante de mais informações e mão de obra (o que seria indesejável pela ótica de minimização dos custos ao se gerir um portfólio), estar-se-ia investigando não apenas a lucratividade da estratégia de investimento em desempenho contrário mas também a assertividade do modelo de precificação. Há, no entanto, um portfólio que se situa na fronteira eficiente<sup>20</sup> e que não demanda que se estimem os retornos futuros dos ativos que o compõem. Trata-se do portfólio de mínima variância, que, como o próprio nome diz, é o que apresenta a menor variância estimada de todos os portfólios possíveis de serem criados com determinado conjunto de ações<sup>21</sup>.

Portanto, considerando a lacuna na literatura quanto à não utilização de portfólios eficientes ao se testar a estratégia de investimento em desempenho contrário, e considerando que não se pretende lançar mão de modelos de estimativa do retorno de ações, o presente trabalho irá utilizar como critério de distribuição dos pesos dos ativos nos portfólios tanto a carteira igualitária (o padrão da literatura), quanto a carteira de mínima variância (portfólio eficiente cujo cálculo na distribuição dos pesos não demanda que se estimem os retornos esperados das ações que o compõe, isto é, basta que se saiba a matriz de covariância dos retornos dos ativos). Além de ser o padrão utilizado na literatura, sabe-se que a distribuição igualitária desempenha, fora da amostra, melhor do que várias outras abordagens que contam com dados históricos (GOETZMANN, 2014, 210). DeMiguel *et al.* (2009) recomendam que, tanto pela sua facilidade de implementação quanto pelo seu bom desempenho (medido pelo Índice Sharpe (1966)) fora da amostra em comparação à estratégias de otimização de média/variância, a distribuição igualitária sirva como *benchmark* das novas estratégias de alocação de ativos em um portfólio.

Quanto à implementação do portfólio de mínima variância, cuja formalização matemática será apresentada na seção 4.5.1.5, é necessário que se utilize uma matriz de covariâncias dos retornos dos ativos que irão compor o portfólio. No entanto, Ledoit e Wolf

---

20 Conjunto de portfólios eficientes segundo Markowitz (1952).

21 Lembrando que o presente trabalho se restringe a posições compradas.

(2004b) esclarecem que a matriz de covariância amostral (isto é, a matriz de covariâncias dos retornos históricos dos ativos que compõe um portfólio) contém erros de estimação (ou seja, erros de estimação da matriz de covariâncias real ou populacional) capazes de perturbar um otimizador de média-variância e, portanto, não adequada para fins de determinação de um portfólio eficiente (como é o caso do portfólio de mínima variância). Ledoit e Wolf (2004b), portanto, sugerem que seja utilizada a matriz de variâncias e covariâncias amostral ajustada por um procedimento desenvolvido por eles e denominado “encolhimento”. Esse procedimento consiste em trazer os coeficientes mais extremos da matriz para valores mais centrais, diminuindo, portanto, o erro de estimação. Os autores alegam que utilizar a modificação proposta aumenta substancialmente o desempenho de um portfólio em comparação ao seu *benchmark* (LEDOIT; WOLF, 2004b, p. 10). Ledoit e Wolf (2004a) apresentam as fórmulas necessárias para “encolher” uma matriz amostral de variâncias e covariâncias. O procedimento já foi implementado em bibliotecas computacionais em Python e R<sup>22</sup>.

Dessa forma, o presente trabalho irá testar três critérios de distribuição (que serão formalizados na seção 4.5.1.5): distribuição igualitária (“1/N”), portfólio de mínima variância utilizando a matriz de variâncias e covariâncias amostral, e portfólio de mínima variância utilizando a matriz de variâncias e covariâncias “encolhida” segundo proposto por Ledoit e Wolf (2004b). Conforme explicado, não serão abordados critérios de distribuição em que seja necessário estimar o retorno futuro dos ativos que irão compor o portfólio.

### **3.2.6. Tamanho da Amostra para o Cálculo da Distribuição de Pesos**

Ainda sobre a questão da distribuição dos pesos tratada na seção 3.2.5, caso se opte por um dos portfólios de mínima variância (seja o que utiliza a matriz de variâncias amostral seja o que utiliza a matriz de variâncias amostral encolhida), é necessário que se defina qual é o tamanho da amostra dos dados históricos que será utilizada para calcular a matriz de covariâncias. Os artigos estudados na revisão de literatura não tratam desse tema, inclusive porque a maioria dos artigos utiliza a distribuição igualitária em que essa questão sequer precisa ser enfrentada. No entanto, no caso de uma implementação prática da estratégia de investimento em desempenho contrário em que não se utilize a distribuição igualitária, precisará ser definido qual o tamanho da amostra ao se fazer os cálculos da distribuição de pesos. Por um lado, pode-se argumentar que a amostra deve ser a maior possível para que a

---

<sup>22</sup> Em Python, o procedimento foi implementado na biblioteca “*sklearn.covariance.LedoitWolf*”; em R, na biblioteca “*nlshrink*”.

matriz de covariâncias amostral calculada seja a mais próxima possível da matriz de covariâncias populacional. Por outro lado, pode-se alegar que o objetivo da matriz de covariâncias é apresentar as correlações lineares entre os retornos das ações, que essas relações dependem das atividades econômicas exercidas pelas respectivas empresas e que, com o tempo, as empresas alteram suas atividades econômicas de modo que uma matriz calculada com dados de vários anos atrás pode não ser adequada para estimar as correlações lineares entre as ações no futuro. Assim como em outros parâmetros da estratégia de investimento em desempenho contrário, é provável que esse parâmetro também possua um “meio-termo” ótimo.

### **3.2.7. Período para Rebalanceamento**

Depois de definido o critério de distribuição da participação percentual de cada ação no portfólio, é necessário definir de quanto em quanto tempo o portfólio será rebalanceado, isto é, depois de quanto tempo desde a sua formação (ou desde o último rebalanceamento) serão reestabelecidos os percentuais inicialmente definidos. Isso é necessário porque, como os retornos individuais de cada ação no portfólio são diferentes entre si, com o passar do tempo os percentuais de participação de cada ativo na carteira irão mudar. E se foi escolhido um determinado critério de distribuição dos pesos, é desejável que, pelo menos periodicamente, os pesos sejam reestabelecidos segundo esse critério sob pena de torná-lo inútil. Isso é especialmente importante quando se adota um portfólio de mínima variância, pois, se o investidor/gestor deseja a distribuição com a menor volatilidade esperada possível, desvios dessa distribuição farão a variância esperada aumentar.

De Bondt e Thaler (1985, p. 798) não chegam a dizer expressamente de quanto em quanto tempo é feito o rebalanceamento, assim como não dizem de forma explícita qual é a distribuição dos pesos das ações no portfólio. No entanto, como a metodologia do artigo consiste em calcular mensalmente a média dos retornos das ações no portfólio, isso equivale a ter uma distribuição de pesos igualitária que é rebalanceada diariamente de modo que, todas as vezes que a média dos retornos das ações for calculada, os pesos estariam sempre de acordo com a distribuição original. Da Costa (1994, p. 637) alega que a metodologia utilizada (média dos retornos mensais de cada ativo no portfólio) implica implicitamente um rebalanceamento mensal de maneira que o peso de cada ativo no portfólio permanece igual aos demais. No entanto, essa constatação está, *data venia*, equivocada. As negociações em bolsa de valores não possuem periodicidade mensal, de forma que, ao final de um único dia de negociações, a diferença dos retornos das ações faz com que a distribuição dos pesos se

altere e impeça que se possa simplesmente presumir que, ao final do mês, os pesos dos ativos continuam os mesmos e que basta tomar a média mensal dos ativos para obter o retorno do portfólio como um todo. Portanto, um procedimento de cálculo mensal das médias das ações demanda que haja um rebalanceamento diário da participação percentual de cada ativo no portfólio.

Esse mesmo raciocínio se aplica a Chan (1988), Kryzanowski e Zhang (1992), Kang *et al.* (2002, p. 248), Sehgal e Balakrishnan (2002, p. 15), Forner e Marhuenda (2003, p. 72)<sup>23</sup>, Assoé e Sy (2003, p. 312), Clements *et al.* (2009, p. 84), Ramiah *et al.* (2011, p. 9) que também não explicitaram o período de rebalanceamento, mas que tomam a média dos retornos das ações mensalmente. Lo e MacKinlay (1990), e Antoniou *et al.* (2006, p. 846)<sup>24</sup> utilizam uma estratégia de investimento de curto prazo e não tratam de rebalanceamento no sentido que está sendo tratado no presente trabalho. Chang *et al.* (1995), Schiereck *et al.* (1999), e Lee *et al.* (2003) não informam o período de rebalanceamento na estratégia de investimento em desempenho contrário. Fama e French (1996, p. 66) utilizam um rebalanceamento mensal.

Percebe-se que, na literatura sobre a estratégia de investimento em desempenho contrário, o período para rebalanceamento é tratado de forma errática e pouco clara. Em geral, sequer menciona-se explicitamente de quanto em quanto tempo os pesos originalmente atribuídos a cada ativo no portfólio serão reestabelecidos. Mais grave que isso, a forma como em geral se calculam os retornos dos portfólios (pela média dos retornos de cada ativo que o compõe) implicitamente demanda que haja um rebalanceamento contínuo (diário) conforme já explicado. Essa presunção de rebalanceamento contínuo gera um problema de mensuração do retorno do portfólio. Isto porque ou se está calculando o retorno de uma carteira sem levar em consideração a sua real distribuição de pesos (que provavelmente se alterou desde de sua formação inicial) ou se está de fato rebalanceando o portfólio diariamente (nesse caso tomar a média dos retornos dos ativos é correto), mas sem contabilizar os custos de transação de um rebalanceamento tão frequente.

Um período para rebalanceamento curto demais faz aumentar os custos de transação, enquanto um período de rebalanceamento longo demais descaracteriza a distribuição dos

---

23 Apesar de Forner e Marhuenda (2003) calcularem o retorno mensal do portfólio tomando a média dos retornos mensais das ações (o que, conforme explicado, a rigor demandaria um rebalanceamento diário), os autores estimam os custos de transação com base no *turnover* anual de reajuste dos portfólios, o que pode dar a entender que ocorre um rebalanceamento anual dos mesmos.

24 Antoniou *et al.* (2006, p. 846), ao falar de “*weekly-rebalanced contrarian strategy*”, referem-se a um novo ciclo de seleção, compra, e maturação de ações.

pesos originalmente pretendida. É possível que também haja um “meio-termo” ótimo de período para rebalanceamento em cada mercado.

### 3.2.8. Custos de Transação

De Bondt e Thaler (1985, p. 802) dizem expressamente que os resultados de seu estudo sobre o desempenho da estratégia de investimento em desempenho contrário não levam em consideração os custos de transação, o que também acontece em De Bondt e Thaler (1987). Chan (1988, p. 153) também não incorpora custos de transação em suas simulações, mas diz que, como os resultados anormais gerados pela estratégia de investimento em desempenho contrário são muito pequenos, eles seriam provavelmente economicamente insignificantes caso fossem considerados os custos de transação. Lo (1990, p. 20) é explícito ao dizer que seu estudo não leva em consideração os custos de transação ao calcular a lucratividade da estratégia de investimento em desempenho contrário, apesar de reconhecer que se trata de uma questão importante. Kryzanowski e Zhang (1992), Fama e French (1996), Kang et al. (2002), Sehgal, Balakrishnan (2002), Clements et al. (2009), e Ramiah et al. (2011) não tratam da questão dos custos de transação. Da Costa Jr. (1994), apesar de mencionar quais seriam os custos de transação incidentes em negociações na Bovespa, parece não incorporar esses custos nos cálculos de retorno da estratégia de investimento em desempenho contrário. Chang et al. (1995, p. 1041) também não levam em conta os custos de transação nas simulações para as estimativas de retorno da estratégia de investimento em desempenho contrário, se limitando a dizer que os retornos estimados superam os custos de transação calculados por outros estudos. Da mesma forma, Schiereck et al. (1999) também não levam em consideração os custos de transação nas simulações de mensuração do desempenho da estratégia, restringindo-se a argumentar que os custos de implementação de estratégias de baixa frequência de negociação são modestos.

Fornier e Marhuenda (2003, p. 83), ao contrário dos artigos mencionados no parágrafo anterior, enfrentam a questão dos custos de transação de maneira mais realista. Eles levam em consideração o *bid-ask spread*<sup>25</sup> médio das ações que compõe a amostra do estudo, uma taxa de corretagem estimada de 0,25%, e o *turnover*<sup>26</sup> anual do portfólio. Mesmo assim, os autores concluem que a estratégia de investimento em desempenho contrário continuou lucrativa no estudo.

---

25 Diferença entre o maior preço que um comprador está disposto a pagar pela ação e o menor preço que um vendedor está disposto a receber por ela.

26 Definido no estudo dos autores como o percentual do valor do portfólio que é reajustado todo ano.

Lee et al. (2003, p. 6) partem de uma abordagem diferente das adotadas pelos demais artigos: ao invés de estimarem os custos de transação em suas simulações e obterem o desempenho da estratégia, eles resolvem o modelo de modo que o lucro da estratégia seja uma premissa e o custo de transação seja o resultado. Dessa forma, ao pressupor no modelo que a estratégia irá gerar lucro zero, eles obtêm a resposta de qual é o custo de transação máximo para a estratégia seja lucrativa. Os autores concluem que um custo de transação de 0,30% é suficiente para eliminar qualquer lucro significativo da estratégia de investimento em desempenho contrário de curto prazo.

Assoé e Sy (2003, p. 315) estimam custos de transação através do *bid-ask spread* e do percentual de mudança entre um portfólio e outro, mês a mês.<sup>27</sup> Antoniou et al. (2006, p. 865) levam em consideração o custo de transação referente ao *bid-ask spread* estimado para grupos de ações em função de seus tamanhos (quanto maior o tamanho, menor *bid-ask spread*).

Percebe-se, portanto, que, apesar da literatura sobre o tema reconhecer a importância sobre os custos de transação, na maior parte dos casos eles são simplesmente ignorados. Mesmo os trabalhos que consideram os custos de transação o fazem de maneira pouco aprofundada, como, por exemplo, estimando os custos em grupos de ações em função de seus tamanhos ao invés de estimar o custo de transação específico para cada ação adquirida. Além disso, esses artigos presumem que os custos de transação são constantes ao longo do tempo o que não necessariamente condiz com a realidade. Conforme apresentado na seção 4.5.2, o presente estudo irá suprir essa lacuna ao adotar um método robusto de estimativa do custo de transação para cada ação que for negociada e que leva em consideração o fato de que esses custos podem variar ao longo do tempo.

---

<sup>27</sup> No estudo, os autores trabalham com uma implementação da estratégia de curto prazo (um mês) e chamam de “rebalanceamento” o que o presente trabalho chamaria de um novo período de maturação.

## 4. METODOLOGIA

### 4.1. Países Estudados

A estratégia de investimento em desempenho contrário poder ser aplicada, pelo menos em posições compradas, em qualquer mercado acionário do mundo. Todavia, durante a realização do presente trabalho, só se teve acesso (pela plataforma Economática) aos dados dos mercados estadunidense e brasileiro. De qualquer modo, o algoritmo de otimização desenvolvido no presente trabalho foi elaborado para ser passível de aplicação a qualquer mercado acionário do mundo.

### 4.2. Panorama da Metodologia empregada no presente trabalho.

O Algoritmo para Otimização da Estratégia de Investimento em Desempenho Contrário utiliza duas bases de dados. A primeira é a Base de Dados dos Preços Históricos (vide seção 4.4), e a segunda é a Base de Dados dos Resultados das Simulações (vide seção 4.6). Os primeiros 70% de observações, em ordem cronológica, da Base de Dados dos Preços Históricos constituem o chamado Período de Treino, e os 30%<sup>28</sup> restantes constituem o Período de Testes. Com base no Período de Treino, o Algoritmo de Simulações (explicado em detalhes na seção 4.5) gera a Base de Dados dos Resultados das Simulações. Posteriormente, utilizando a Base de Dados dos Resultados das Simulações, será aplicado um modelo econométrico (seção seção 4.6) cujo resultado irá apresentar a melhor forma de implementar a estratégia de investimento em desempenho contrário considerando o objetivo de maximizar o *Information Ratio* (conforme justificado na seção 2.2, página 19), isto é, irá apresentar a melhor regra de negociação da estratégia de investimento em valor contrário. Essa regra de negociação será posta à prova ao aplicar o Algoritmo de Simulações ao Período de Testes da Base de Dados dos Preços Históricos, isto é, será analisada como a regra desempenha fora da amostra utilizada para gerá-la. Este procedimento será feito tanto para Brasil quanto para Estados Unidos.

### 4.3. Hipótese Geral

A hipótese geral do presente trabalho é a de que a regra de negociação resultante do Algoritmo de Otimização da Estratégia de Investimento em Desempenho Contrário é capaz de gerar *Information Ratio* positivo. Para suportar ou refutar essa hipótese geral, existem as duas Hipóteses Específicas (seções 4.3.1 e 4.3.2). Caso ambas sejam verdadeiras, entender-se-á que

---

<sup>28</sup> Essa divisão de 70% para período de treino e 30% para período de teste é o que parece ser mais comum na praxe de estudos que testam a eficácia de modelos (tanto econométricos quanto de aprendizado de máquina) fora da amostra, que é justamente o que se faz no presente trabalho.

a hipótese geral encontra suporte no presente estudo. Caso ambas sejam falsas, a Hipótese Geral será tida como refutada no presente estudo. Caso uma seja verdadeira e a outra falsa, os resultados do presente estudo serão considerados inconclusivos.

#### 4.3.1. Sucesso do Algoritmo no Brasil

A primeira hipótese específica é a de que a regra de negociação resultante do algoritmo de otimização da estratégia de investimento em desempenho contrário é capaz de gerar *Information Ratio* positivo (vide explicação na seção 1.3) no Brasil.

#### 4.3.2. Sucesso do Algoritmo nos Estados Unidos da América

A segunda hipótese específica é a de que a regra de negociação resultante do Algoritmo de otimização da estratégia de investimento em desempenho contrário é capaz de gerar *Information Ratio* positivo nos Estados Unidos da América.

### 4.4. **A Base de Dados dos Preços Históricos**

O presente estudo chama de Base de Dados dos Preços Históricos<sup>29</sup> o conjunto dos seguintes dados:

1. Preços diários históricos das ações<sup>30</sup> de todas<sup>31</sup> as empresas nacionais<sup>32</sup> negociadas nos mercados acionários<sup>33</sup> de cada país. No caso do Brasil, a base utilizada no presente estudo tem início em 04/01/1988, fim em 13/03/2021 (8665 linhas), e conta com 1765 ativos. No caso dos Estados Unidos, a base tem início em 03/01/1995, fim em 19/03/2021 (6839 linhas), e conta com 5737 ativos. Os preços das ações são as cotações de fechamento diário ajustados por inflação<sup>34</sup>, dividendos, bonificações,

29 Todos eles obtidos na plataforma Economática.

30 Incluindo todas as diferentes classes de ações (ordinárias, preferenciais, units, etc) de uma mesma empresa.

31 Incluindo as ações que não estavam mais disponíveis para negociação no dia em que a base de dados foi baixada.

32 Por ações de empresas nacionais entendem-se ações de empresas com sede nos países onde são negociadas. Não foram incluídas, portanto, as *American depositary receipts (ADRs)* e as *Brazilian Depositary Receipts (BDRs)*. Essa delimitação do estudo se justifica na medida em que é provável que ativos de empresas sediadas em outros países sigam uma dinâmica diferente das ações domésticas. Interessante mencionar que Parhizgari e Nguyen (2008) estudaram a estratégia de investimento em desempenho contrário aplicada às *ADRs* e concluíram pela sua efetividade. Mas, de qualquer forma, os autores argumentaram pela realização de um estudo exclusivo para as *ADRs* justamente porque se tratava de um grupo de ações distintas e que mereceria um estudo próprio quanto à efetividade da estratégia.

33 No caso do Brasil, foram obtidos os dados das ações negociadas na Bovespa/B3. No caso dos Estados Unidos, foram obtidos os dados das ações negociadas na *New York Stock Exchange* (anteriormente denominada *American Stock Exchange*) e da *Nasdaq Stock Market*.

34 O presente estudo trabalha exclusivamente com dados reais porque o que importa para o agente é o retorno real. Ao ver o gráfico das simulações, o que interessa é que se compare a evolução dos retornos ao longo do



desdobramentos, reduções de capital, grupamentos, subscrições e cisões. Eventuais ausências de negociações (os seja, lacunas na base de dados) foram preenchidas durante a realização de cada simulação, conforme explicado na seção 4.5.3, página 58;

2. O valor diário do principal índice representativo do mercado acionário em determinado país. No caso do Brasil, foi utilizado o Ibovespa. No caso dos Estados Unidos, foi utilizado o S&P 500. Como o preço das ações estava ajustado por inflação, o índice também precisou ser. As taxas de inflação utilizadas para ajustar o índice representativo do mercado acionário foram o Índice de Preços ao Consumidor Amplo (IPCA) para o caso brasileiro, e o Consumer Price Index (CPI) para o caso estadunidense. A frequência dos índices de inflação foi convertida de mensal para diária utilizando a fórmula

$$i_d = ((i_m + 1)^{1/21}) - 1 \quad \text{Eq. 2}$$

em que  $i_d$  é a inflação diária,  $i_m$  é a inflação mensal, e 21 é o número médio de dias úteis em um mês (ou seja, número médio de pregões em bolsa de valores). Uma vez estando o índice e a inflação na frequência diária, subtrai-se a inflação do retorno nominal do índice para obter o retorno real do índice;

3. O retorno diário da “taxa livre de risco” adequada ao mercado em análise. As taxas livre de risco de Brasil e Estados Unidos adotadas neste estudo são, respectivamente, a taxa do Certificado de Depósito Interbancário (CDI) e a taxa do Treasury Bond (T-Bond) de 10 anos. Essas taxas também foram ajustadas pela inflação (de modo a se obter a taxa de juros real) seguindo o mesmo procedimento de correção monetária explicado para a correção dos índices representativos dos mercados acionários de Brasil e Estados Unidos.

#### 4.5. O Algoritmo de Simulações

O Algoritmo de Simulações utilizou a Base de Dados dos Preços Históricos para gerar a Base de Dados dos Resultados das Simulações, que é o resultado de cada uma das

---

tempo, e, para que essa comparação seja adequada em termos econômicos, os valores dos retornos e do patrimônio investido devem ser reais. O mesmo vale para visualizar a evolução do patrimônio real investido.

simulações (10.000 para o caso brasileiro e 1.200<sup>35</sup> para o caso estadunidense) de implementação da estratégia de investimento em desempenho contrário ao longo do Período de Treino. Cada simulação foi conduzida com uma diferente combinação aleatória de parâmetros de implementação da estratégia de investimento em desempenho contrário (seguindo as distribuições de frequência apresentadas na seção 4.5.1).

Esta seção apresenta o funcionamento do Algoritmo de Simulações. Importante ressaltar que todos os parâmetros apresentados nesta seção que façam referência a períodos de tempo são medidos em dias.

#### 4.5.1. *Formalização dos Parâmetros*

##### 4.5.1.1. Critério de Formação (seleção das ações)

Critério de Formação (*CF*). É a medida de desempenho utilizada para determinar as ações “perdedoras”. O presente estudo irá adotar três critérios de formação de modo que

$$CF \sim U\{1,3\} \quad \text{Eq. 3}$$

ou seja, *CF* pode assumir com igual probabilidade os valores 1, 2, ou 3. Cada um desses três valores representa um determinado critério de formação.

O critério número 1 é denominado no presente estudo como Retorno Simples<sup>36</sup> (*Ret*) e é definido por

$$R_{jPF} = \frac{P_0 - P_{-PF}}{P_{-PF}} \quad \text{Eq. 4}$$

em que o subscrito *j* indica que a variável é referente ao ativo *j*;  $P_0$  é o preço<sup>37</sup> da ação no instante zero, isto é, momento em que as ações são avaliadas como “perdedoras” e que coincide com o momento de aquisição das ações que forem compradas; *PF* é o período de formação, ou seja, o tempo em dias em que o desempenho de uma ação é avaliada;  $P_{-PF}$  é o preço da ação *PF* dias antes da data em que está sendo feita a avaliação das ações (o sinal negativo na frente de *PF* deixa explícito que se trata do preço da ação no passado); e,

35 A diferença no número de simulações para cada país se deve ao fato de que existem muito mais ativos na base de dados estadunidense do que na base de dados brasileira, o que torna o processamento das simulações estadunidenses, em média, significativamente mais lento do que o processamento no caso brasileiro.

36 Por não sofrer qualquer ajuste.

37 Com os já mencionados ajustes de inflação, dividendos, juros sobre capital próprio, etc.

consequentemente,  $R_{jPF}$  é o retorno do ativo  $j$  durante o período de formação  $PF$ . É importante ressaltar que o Retorno Simples também pode ser calculado através do histórico diário dos retornos do ativo, ou seja, sem utilizar os preços como na Eq. 4. Nesse caso, o Retorno Simples é definido por

$$R_{jPF} = \left( \prod_{k=-(PF-1)}^{k=0} (r_k + 1) \right) - 1 \quad \text{Eq. 5}$$

em que

$$r_k = \frac{P_k - P_{k-1}}{P_{k-1}}. \quad \text{Eq. 6}$$

O critério número 2 é o Alfa de Jensen ( *Alfa* ) definido por

$$\alpha_{jPF} = R_{jPF} - \left( R_{fPF} + \beta_{jPF} (R_{mPF} - R_{fPF}) \right) \quad \text{Eq. 7}$$

em que  $R_{jPF}$  tem a mesma definição apresentada na Eq. 5;  $R_{fPF}$  é o retorno da taxa livre de risco (deflacionada) observada ao longo do período de formação;  $R_{mPF}$  é o retorno (deflacionado) do índice representativo do mercado durante o período de formação; e  $\beta_{jPF}$  (*beta*, podendo também ser chamado de risco relativo ou de risco sistêmico ao longo do trabalho) é definido por

$$\beta_{jPF} = \frac{COV(R_{jPF}, R_{mPF})}{\sigma^2 R_{mPF}} \quad \text{Eq. 8}$$

(em que, por sua vez, *cov* significa covariância e  $\sigma^2$  variância) e que é a medida de risco relativo do ativo  $j$  em comparação ao índice representativo do mercado observada durante o período de formação. Portanto,  $\alpha_{jPF}$  mede o desempenho do ativo  $j$ , ao longo do período de formação  $PF$ , que excede o retorno esperado do ativo segundo o CAPM (SHARPE, 1964; LINTNER, 1965). Trata-se, portanto, de uma medida ajustada tanto pelo risco relativo

observado  $\beta_{jPF}$  quanto pelo próprio desempenho do mercado  $R_{mPF}$ . Importante ressaltar que, ao rearranjar a Eq. 7, chega-se a

$$(R_{jPF} - R_{PF}) = \alpha_{jPF} + \beta_{jPF}(R_{mPF} - R_{PF}) \quad \text{Eq. 9}$$

ou seja, ao utilizar a Eq. 9 como modelo em uma regressão linear,  $\alpha_{jPF}$  será o intercepto da regressão.

O critério número 3 é o Índice Sharpe ( *Sharpe* ), nesse trabalho definido por:

$$S_{jPF} = \frac{\mu(R_{jPF} - R_{PF})}{\sigma(R_{jPF})} \quad \text{Eq. 10}$$

em que  $\mu(R_{jPF} - R_{PF})$  é a média diária do excesso de retorno do ativo  $j$  em relação à taxa livre de risco durante o período de formação, e  $\sigma(R_{jPF})$  é o desvio padrão populacional<sup>38</sup> dos retornos diários do ativo  $j$ . Vale ressaltar que o Índice Sharpe (1966) foi concebido para ser uma medida anual de retorno ajustado por risco e que, a princípio, seria necessário anualizar  $S_{jPF}$  que tem periodicidade diária. No entanto, conforme apontado por Lo (2002), o procedimento para mudança de periodicidade do Índice Sharpe é um procedimento relativamente complexo, não podendo ser utilizada, na maioria dos casos, a “regra de bolso” de multiplicar o valor do índice por  $\sqrt{252}$  para convertê-lo de diário para anual. Além disso, importante lembrar que o critério de formação (*CF*) tem por objetivo comparar o desempenho de diferentes ações para classificá-las como “perdedoras” ou não e, se for o caso, incluí-las no portfólio. Dessa maneira, a rigor não importa qual é a periodicidade de qualquer uma das medidas de desempenho utilizadas, desde de que todas estejam com a mesma periodicidade e se refiram ao mesmo período de formação *PF*. Importante observar que, quando o Índice Sharpe é negativo, um menor desvio padrão gera um índice menor, o que é uma limitação do indicador uma vez que, a princípio, menos volatilidade é preferível a mais volatilidade. Por outro lado, pode-se argumentar que, quando se tem Sharpe negativo, é preferível ter uma volatilidade alta (e eventualmente alguns retornos positivos ao longo da série) a ter uma constância de resultados negativos.

---

<sup>38</sup> É utilizada a fórmula do desvio padrão populacional porque pretende-se obter uma estatística descritiva do desempenho do ativo ao longo de um período de formação. A população, portanto, são todas as observações de retornos dentro do período de formação.

Acima foram apresentadas três medidas de desempenho, sendo a primeira ( $R_{jPF}$ ) não ajustada por risco ou desempenho do mercado, a segunda ( $\alpha_{jPF}$ ) sendo ajustada por risco sistêmico ( $\beta_{jPF}$ ) e desempenho do mercado ( $R_{mPF}$ ), e a terceira ajustada por risco ( $\sigma(R_{jPF})$ ). Presume-se que essas três diferentes abordagens para mensurar o desempenho já sejam suficientes para que o trabalho cumpra os objetivos propostos, não sendo necessário, portanto, incluir outras medidas de desempenho dos ativos.

#### 4.5.1.2. Período de Formação

Conforme já apresentado na seção 3.2.2,  $PF$  é o período de tempo em que as ações são analisadas para serem consideradas “perdedoras” ou não. Com o objetivo de ser o mais abrangente possível, mas sem descolar demasiadamente da literatura sobre o tema, o presente estudo trabalhará com o prazo máximo de seis anos de período de formação (que é o prazo máximo utilizado pelos artigos referenciados nesse estudo). Como a base de dados é diária e apresenta somente os dias em que houve negociação, e como em regra cada ano possui 252 dias de negociação (tanto no Brasil quanto nos Estados Unidos), no presente trabalho

$$PF \sim U\{2, (252 \times 6)\} \quad \text{Eq. 11}$$

ou seja,  $PF$  pode assumir, com igual probabilidade, qualquer valor inteiro entre 2 e 1512. O limite inferior precisa ser 2 pois é impossível calcular o Índice Sharpe (1966) ou o Alfa de Jensen (1968) em um período de tempo de apenas uma observação.

#### 4.5.1.3. Período de Maturação

O Período de Maturação  $PM$  é o período de tempo que um portfólio de ações “perdedoras” será mantido até se inicie um novo ciclo de seleção e aquisição de novas ações, isto é, até que se inicie um novo período de maturação. Com o objetivo de ser o mais abrangente o possível dentro do que já foi trabalhado pela literatura acima referenciada (período máximo de 12 anos), os valores de períodos de maturação no presente trabalho serão tais que

$$PM \sim U\{1, (252 \times 12)\}. \quad \text{Eq. 12}$$

Importante destacar que, no presente estudo, o período de maturação inicia-se no começo do pregão do primeiro dia útil imediatamente seguinte ao término do período de

formação. Isto é, não é dado um intervalo de tempo entre a análise das ações e a sua aquisição conforme feito por Fama e French (1996, 64), e Sehgal e Balakrishnan (2002). Esse intervalo foi proposto pelos autores porque foi observado que ações “perdedoras” continuam desempenhando mal no curto prazo antes que houvesse uma reversão. No entanto, o algoritmo de otimização da estratégia de investimento em desempenho contrário objeto do presente trabalho, a princípio, tornará desnecessário que se dê esse intervalo de tempo entre a avaliação do desempenho de uma ação e a sua aquisição. Isso porque, a rigor, esse intervalo de tempo só é necessário porque não está sendo adotado um período de formação ótimo. Se, na média, é necessário aguardar determinado período de tempo entre a avaliação da ação e a sua aquisição por conta do efeito *momentum*, bastaria que simplesmente fosse aumentado o período de formação para que ele abarque esse tempo médio. Não parece fazer sentido que uma regra de negociação possa se beneficiar ao desprezar deliberadamente dados que podem conter informações relevantes sobre o mercado e sobre as ações. Em outras palavras, o problema real que o intervalo proposto por Fama e French (1996, p. 64) e Sehgal e Balakrishnan (2002) tenta resolver não é o de que as ações estejam sendo compradas “cedo demais”, mas sim o de que o período de formação não terminou “tarde o suficiente”.

#### 4.5.1.4. Número de Ações (Fração do Total Disponível)

Outro parâmetro necessário para implementar a estratégia de investimento em desempenho contrário é o número de ações a serem incluídas no portfólio de ações “perdedoras”. No presente trabalho, esse número é definido por

$$N = \lceil Q \times T \rceil \quad \text{Eq. 13}$$

(isto é, caso a multiplicação  $Q \times T$  seja um número não inteiro,  $N$  será arredondado para cima), em que

$$Q \sim U\left(0, \frac{1}{2}\right). \quad \text{Eq. 14}$$

$Q$  representa a fração do total de ações que será incluída no portfólio, e  $T$  é o total de ações disponíveis para compra no momento de aquisição das ações “perdedoras”. Como  $N$  depende dos valores de  $Q$  e  $T$ , e como  $T$  é uma variável que não é possível de ser controlada, a rigor o parâmetro de implementação da estratégia é  $Q$ , que é o valor que pode ser escolhido pelo

gestor ao implementar um portfólio. Considerando a definição da Eq. 14, no presente estudo a quantidade de ações a ser incluída no portfólio equivale a uma fração entre 0 e 0,5 (metade) do total de ações disponíveis para compra no mercado daquele país no momento de aquisição do portfólio (conforme explicado seção 4.4). Os limites da distribuição foram escolhidos para proporcionar a maior abrangência o possível considerando o pressuposto de que para ser “perdedora” (e não “vencedora”) uma ação tem que estar abaixo da mediana (já que a ideia é dividir as ações em duas metades) no desempenho das ações analisadas. Caso o resultado de  $N$  seja igual a 1, o Algoritmo de Simulações irá reatribuir a  $N$  o valor 2, visto que o presente estudo adota o conceito de que um portfólio é composto de, pelo menos, duas ações com pesos diferentes de zero.

#### 4.5.1.5. Distribuição dos Pesos

Primeiramente, é necessário apresentar a notação que será utilizada. As operações matriciais apresentadas abaixo foram baseadas em Alexander (2008).

Seja  $W$  a matriz  $1 \times N$  em que cada elemento  $w_{1,n}$  representa a participação relativa (peso) do  $n$ -ésimo ativo do portfólio. Seja  $W'$  a transposta de  $W$ . Seja  $V$  a matriz amostral  $N \times N$  de covariâncias dos retornos dos  $N$  ativos do portfólio. E seja  $V_S$  a matriz  $V$  que passou pelo “encolhimento” proposto em Ledoit e Wolf (2004b).

O presente trabalho irá adotar três Critérios de Distribuição dos Pesos ( $DP$ ), de forma que

$$DP \sim U[1,3] \quad \text{Eq. 15}$$

ou seja,  $DP$  pode assumir com, igual probabilidade, os valores 1, 2, ou 3.

O valor 1 refere-se à distribuição de pesos igualitária:

$$Ig \Rightarrow w_{1,n} = (1/N), \forall n \quad \text{Eq. 16}$$

(leia-se, distribuição igualitária que implica que, para todo  $n$ -ésimo ativo no portfólio, seu peso seja igual a 1 dividido por  $N$ ).

O valor 2 de  $DP$  refere-se à distribuição dos pesos que gere um portfólio de mínima variância calculado com base na matriz de variâncias amostral e definida por

$$M \Rightarrow \min_W W V W' \wedge \sum_{i=1}^N w_{1,n} = 1 \wedge w_{1,n} \geq 0,0001 \forall n \quad \text{Eq. 17}$$

(leia-se, portfólio de mínima variância amostral que implica que a matriz  $W$  minimize o resultado da multiplicação das três matrizes  $W$ ,  $V$  e  $W'$ , e que os pesos dos ativos sejam maiores ou iguais a 0,0001 e suas somas sejam iguais a 1).

O valor 3 de DP refere-se à distribuição dos pesos que gere um portfólio de mínima variância calculado com base na matriz de variâncias “encolhida” e definida por

$$M_s \Rightarrow \min_W W V_s W' \wedge \sum_{i=1}^N w_{1,n} = 1 \wedge w_{1,n} \geq 0,0001, \forall n \quad \text{Eq. 18}$$

(leia-se, portfólio de mínima variância encolhida que implica que a matriz  $W$  minimize o resultado da multiplicação das três matrizes  $W$ ,  $V_s$  e  $W'$ , e que os pesos dos ativos sejam maiores ou iguais a 0,0001 e suas somas sejam iguais a 1).

Com relação às Eq. 17 e Eq. 18, é muito importante destacar dois aspectos. O primeiro é o de que em nenhum momento se utiliza a inversa da matriz de covariâncias para calcular os portfólios de mínima variância (seja com matriz amostral encolhida ou não). O Algoritmo de Simulações adota um método de otimização computacional conhecido como *Sequential Least Squares Programming*<sup>39</sup> que utiliza as expressões, conforme apresentadas em Eq. 17 e Eq. 18, para encontrar os portfólios de mínima variância.

O segundo aspecto a ser destacado é com relação ao peso mínimo de 0,0001 (ou 0,01%) para cada ativo no portfólio. Foi necessário estabelecer esse limite inferior arbitrário para evitar que o otimizador atribuísse pesos muito pequenos (por exemplo  $1,0 \times 10^{-15}$ ) a um ou mais ativos no portfólio. O estabelecimento de pesos tão pequenos enviesariam a análise do presente estudo porque, em uma implementação prática, esses percentuais seriam muito difíceis de serem adquiridos (mesmo no mercado fracionário e com altas quantias investidas no fundo). Além disso, para qualquer finalidade prática, esses percentuais equivaleriam a zero, isto é, equivaleriam como se aquele ativo não estivesse na carteira, mas o algoritmo iria contabilizá-lo como um ativo no portfólio mesmo assim.

#### 4.5.1.6. Tamanho da Amostra para o Cálculo da Distribuição de Pesos

<sup>39</sup> Implementado na biblioteca Python “scipy.optimize.minimize”.



O Tamanho da Amostra para o Cálculo da Distribuição de Pesos ( $TA$ ) indica o tamanho do período de tempo (dados históricos) que será utilizado para calcular a matriz de covariâncias  $V$  das ações que irão compor o portfólio. Esse parâmetro só é aplicável quando se adota como critério de Distribuição de Pesos  $M$  ou  $M_s$ , conforme definido na seção 4.5.1.5. Apesar de, a rigor, ser possível que na prática  $TA$  seja maior que  $PF$  (isto é, que se utilize um período de tempo maior para calcular a matriz de variâncias e covariâncias do que para calcular o desempenho das ações), essa possibilidade tornaria o modelo excessivamente complexo. Isso ocorreria porque, para calcular a matriz  $V$ , todas as ações precisam ter dados disponíveis ao longo de todo  $TA$ , não sendo possível calcular a matriz de covariâncias se a quantidade de dados disponíveis para uma ação for menor que para as demais. Caso  $TA$  seja sempre menor ou igual a  $PF$ , é garantido que todas as ações terão dados disponíveis ao longo de todo  $TA$ . Isso acontece porque, conforme será explicado na seção 4.5.3, página 58, os ativos que obedecem às regras de liquidez têm eventuais lacunas preenchidas, e, portanto, as ações incluídas no portfólio necessariamente possuem dados disponíveis ao longo de todo  $TA$ . Caso  $TA$  pudesse ser maior que  $PF$ , não haveria qualquer garantia de que todas as ações teriam dados disponíveis ao longo de todo  $TA$  e, portanto, não haveria garantia de que a matriz  $V$  pudesse ser calculada. A forma mais simples e elegante para resolver esse problema é justamente impedir que  $TA$  seja maior que  $PF$ . Demais soluções demandariam que se fizessem, por exemplo, controles que abortassem toda uma simulação caso, em algum momento ao longo de toda a simulação (que compreende vários ciclos de maturação de carteiras), não fosse possível calcular a matriz  $V$ . Além de tornar o algoritmo mais complexo e lento (pois várias simulações seriam abortadas após já terem sido iniciadas), essa possibilidade (de  $TA$  ser maior que  $PF$ ) não traria significativa vantagem ao estudo uma vez que já serão realizadas muitas simulações (e conseqüentemente haverá variabilidade grande o suficiente em todos os parâmetros).

Diante do exposto,

$$DP = (M \vee M_s) \Rightarrow TA \sim U\{2, (PF)\} \quad \text{Eq. 19}$$

ou seja, quando o critério para distribuição dos pesos for  $M$  ou  $M_s$ , isso implica que o Tamanho da Amostra para cálculo da Distribuição de Pesos seguirá uma distribuição uniforme discreta de limite inferior 2 (número mínimo de observações para se calcular uma matriz de covariâncias) e limite superior igual ao valor  $PF$  da simulação. Além disso,

$$DP = I_g \Rightarrow TA = 0 \quad \text{Eq. 20}$$

ou seja, quando o critério para a distribuição de pesos for a carteira igualitária, o tamanho da amostra para o cálculo da distribuição dos pesos é igual a zero.

#### 4.5.1.7. Período para Rebalanceamento

O Período para Rebalanceamento ( $PR$ ) indica de quanto em quanto tempo o portfólio será rebalanceado para que a distribuição de pesos  $W$  volte a ser a originalmente estabelecida. Com o objetivo de tornar a análise o mais abrangente possível, os valores de  $PR$  terão como limite inferior 1 (o que implica um rebalanceamento diário) e como limite superior o Período de Maturação  $PM$  de modo que

$$PR \sim U [1, PM] \quad \text{Eq. 21}$$

Isso significa que nenhuma simulação apresentará Período de Rebalanceamento maior que o seu respectivo Período de Maturação. Isso faz sentido considerando que o término do Período de Maturação faz iniciar um novo ciclo de formação de portfólio.

Um Rebalanceamento Dinâmico que consistiria em recalculando os pesos dos ativos no portfólio periodicamente dentro dos próprios períodos de maturação, ao invés de simplesmente reestabelecer periodicamente os pesos originalmente atribuídos no início de cada período de maturação se mostrou muito difícil de ser compatibilizado com o Sistema de Manutenção da Liquidez, apresentado na seção 4.5.3. No entanto, já foi possível perceber que o rebalanceamento dinâmico impunha custos de transação muito maiores já que, mesmo dentro de um período de maturação, os pesos variavam muito de rebalanceamento para rebalanceamento, o que exigia um percentual maior de compras e vendas a cada rebalanceamento. Já no rebalanceamento não dinâmico (descrito na presente seção), os custos de transação são bem menos significativos pois basta reestabelecer pesos que já haviam sido implementados anteriormente. Além disso, considerando a dificuldade técnica de conciliar o Rebalanceamento Dinâmico com o Sistema de Manutenção da Liquidez, optou-se por privilegiar a permanência do Sistema de Manutenção da Liquidez já que, em uma implementação prática da estratégia por um fundo de investimentos, a manutenção da liquidez é um ponto crucial. Por fim, a manutenção de ações sem liquidez tende a distorcer os resultados do desempenho do portfólio conforme estudado por Gottesman *et al.* (2017).

#### 4.5.2. Estimativa dos Custos de Transação

Lesmond (1999) desenvolveu uma inteligente maneira de estimar todos os custos de transação para qualquer ação, de qualquer mercado, e em qualquer período de tempo utilizando como insumo somente as séries temporais dos retornos diários do ativo e do índice representativo do mercado. Os custos de transação estimados pelo modelo englobam não apenas o *bid-ask spread* e a corretagem, mas quaisquer outros custos de transação incorridos pelo agente como o impacto esperado da negociação no preço e os custos de oportunidade (LESMOND, 1999, p. 1117).

O raciocínio por trás do método proposto é o de que um investidor marginal (informado) só irá negociar com base em nova (ou acumulada) informação se a negociação gerar um retorno superior aos custos de transação. Ou seja, os custos de transação constituem uma barreira que precisa ser transposta pelos retornos da negociação para que a compra e venda ocorra. Quanto maiores forem os custos de transação, menos frequentes serão as negociações e, conseqüentemente, maior será a ocorrência de retornos iguais a zero ao longo da série temporal dos retornos da ação.<sup>40</sup> Se não houvesse custos de transação, os investidores poderiam negociar continuamente com todas as ações em função das informações obtidas. No entanto, o autor pondera que, se por um lado não é possível saber se os investidores são ou não informados nem mensurar diretamente qual é o retorno real de uma ação (isto é, o retorno ajustado pelos custos de transação), por outro é possível observar tanto os retornos do mercado quanto a ocorrência de retornos zero da ação de interesse.

Segundo o método proposto por Lesmond (1999)<sup>41</sup>, as estimativas de custos de transação são feitas ao se resolver o modelo:

$$R_{jt}^* = \beta_j R_{mt} + u_{jt} \quad \text{Eq. 22}$$

em que

$$R_{jt} = R_{jt}^* - \alpha_{1j} \quad \text{se} \quad R_{jt}^* < \alpha_{1j} \quad \text{Eq. 23}$$

$$R_{jt} = 0 \quad \text{se} \quad \alpha_{1j} < R_{jt}^* < \alpha_{2j} \quad \text{Eq. 24}$$

$$R_{jt} = R_{jt}^* - \alpha_{2j} \quad \text{se} \quad R_{jt}^* > \alpha_{2j} \quad \text{Eq. 25}$$

40 "We treat zero returns as evidence that the transaction cost threshold has not been exceeded by the marginal trader" (LESMOND, 1999, p.1117)

41 Foram mantidas nas fórmulas as mesmas notações do artigo.

sendo que:

$R_{jt}$  é o retorno observado da ação  $j$  no tempo  $t$  ;

$R_{jt}^*$  é o retorno verdadeiro da ação  $j$  no tempo  $t$  ;

$R_{mt}$  é o retorno observado do mercado  $m$  no tempo  $t$  ;

$u_{jt}$  é o termo de erro no modelo que explica  $R_{jt}^*$  com base em  $R_{mt}$  ;

$\beta_j$  é o coeficiente de  $R_{mt}$  no modelo que explica  $R_{jt}^*$  ;

$\alpha_{1j}$  é o custo de transação proporcional estimado para venda do ativo  $j$  no tempo  $t$  ;

$\alpha_{2j}$  é o custo de transação proporcional estimado para compra do ativo  $j$  no tempo  $t$  .

Ao aplicar seu método em ações do mercado estadunidense, Lesmond (1999, p. 1128) concluiu que, conforme esperado, quanto maiores as firmas, menores os custos de transação (tanto de venda quanto de compra), uma vez que ações de empresas maiores tendem a ser mais negociadas e, conseqüentemente, mais líquidas. Segundo Lesmond (1999, p. 1128), os valores médios de compra mais venda (*round trip*) das firmas do decil superior (em um *ranking* de tamanho) foram de 1,23%. Já para as firmas do decil inferior, o valor médio de custo de transação *round trip* foi de 10,35%. Essa constatação é especialmente importante para a estratégia de investimento em desempenho contrário porque, conforme pontuado por Fama e French (1996, p. 66–68), ativos perdedores de longo prazo se comportam como empresas pequenas. Ou seja, pelo que indica a literatura, adquirir ações perdedoras, além de ser uma estratégia de maior risco (FAMA e FRENCH, 1996, p. 66–68), é também uma estratégia mais cara.

Em Lesmond (1999, p. 1122) a estrutura econométrica da Eq. 22 resulta em uma função de verossimilhança cuja maximização resolve (gera os resultados) dos parâmetros  $\alpha_{1j}$  ,  $\alpha_{2j}$  e  $\beta_j$  . Já no presente trabalho, a solução do modelo apresentado na Eq. 22 foi feita da seguinte forma. Primeiro criou-se uma função (algoritmo em Python) denominada “erros\_quadrados\_lesmond” que agrega as equações Eq. 22 a Eq. 25 e que retorna (*output*) a soma dos quadrados dos resíduos do modelo Eq. 22. Essa função em Python possui cinco parâmetros:  $\alpha_{1j}$  ,  $\alpha_{2j}$  e  $\beta_j$  , uma série temporal dos retornos do ativo cujos custos de transação se deseja calcular, e uma série temporal dos retornos do índice representativo do mercado acionário. O parâmetro  $\beta_j$  é calculado utilizando-se o CAPM através da Eq. 9 (o

mesmo resultado poderia ser obtido adotando a Eq. 8). Já as séries temporais dos retornos (do ativo e do índice de mercado) são as séries dos 252<sup>42</sup> dias que antecedem a transação. Isto é, dos cinco parâmetros necessários para executar a função, três são fornecidos conforme apresentado, e dois ( $\alpha_{1j}$  e  $\alpha_{2j}$ ), que são justamente os custos de transação de venda e de compra, precisam ser estimados. Essa estimativa é feita ao se minimizar<sup>43</sup> a função “erros\_quadrados\_lesmond”. Isto é, aplica-se o Método dos Mínimos Quadrados Ordinários para se chegar aos custos de transação de determinado ativo em determinado dia.

No presente trabalho, sempre que o Algoritmo de Simulações, descrito na seção 4.5.5, identificar a ocorrência de alguma transação, ele irá obter as estimativas específicas para os ativos transacionados, no dia da transação, e para o tipo de transação, isto é, compra ou venda. Após cada transação, seus custos (seja de venda ou de compra) serão contabilizados no retorno do portfólio naquele dia de modo que, ao final, a série de retornos de cada simulação realizada incorpore todos os custos de transação.

#### 4.5.3. Do Sistema de Manutenção da Liquidez

Considerando, conforme explicado na seção 1.3, que o foco do presente trabalho são as gestoras de fundos de investimento, e que a manutenção da liquidez dos portfólios é, em geral, importante para as gestoras e seus clientes; e considerando que, conforme estudado por Gottesman *et al.* (2017), a falta de liquidez tende a distorcer a mensuração de desempenho de um ativo/portfólio, optou-se por incluir no Algoritmo de Simulações duas regras de liquidez, a saber, uma para a inclusão dos ativos no portfólio e outra para a manutenção dos ativos no portfólio.

A regra de liquidez para inclusão dos ativos no portfólio estabelece que, uma vez definido um Período de Formação (conforme explicado na seção 4.5.1.2, página 50), qualquer ativo que apresentar ausência de negociações por mais de 10<sup>44</sup> pregões seguidos é considerado ilíquido e sequer tem seu desempenho avaliado para eventual inclusão no portfólio. As lacunas menores ou iguais a 10 dias são preenchidas com o último preço disponível na base

---

42 A escolha deste período de tempo (um ano calendário) para gerar as estimativas de custos de transação segue a periodicidade do próprio artigo de Lesmond (1999, p. 1123). Caso não existam tantos dados disponíveis assim (o que deve ocorrer no início do Período de Treinamento), a estimativa será feita com base no maior número possível de dados.

43 Essa minimização é feita por meio do algoritmo de otimização Broyden–Fletcher–Goldfarb–Shanno, implementado na biblioteca Python “scipy.optimize.minimize”.

44 Esse limite foi escolhido arbitrariamente e equivale, em média, a duas semanas. Não foram encontradas referências bibliográficas que estabelecem quantos dias seguidos uma ação deve ficar sem negociações para ser considerada ilíquida.

de dados. Consequentemente, nos dias em que houve esse preenchimento, o retorno do ativo é igual a zero, o que é de fato essencial para a estimativa dos custos de transação.

Já a regra de liquidez para manutenção dos ativos no portfólio determina que, durante um Período de Maturação, qualquer ativo que apresentar ausência de negociações por mais de 10 pregões seguidos é considerado ilíquido. Isso implica que, tão logo se verifique essa condição, as posições do ativo na carteira sejam zeradas (venda esta que também tem seus custos de transação). O preço de venda da ação é feito pelo último preço disponível na base de dados. Se por um lado é um paradoxo liquidar um ativo justamente na data que se conclui que ele é ilíquido (11º pregão seguido sem negociação), por outro o método de estimativa de custos de transação de Lesmond (1999) implica que ativos com menos liquidez apresentem custos de transação maiores. Ou seja, os custos necessários para liquidar as posições de um ativo ilíquido também já estão sendo automaticamente levados em consideração no presente estudo. Uma vez retirada uma ação durante um período de maturação, ela é mantida fora do portfólio até que se encerre aquele período de maturação. A ação pode até voltar a ser incluída no portfólio do próximo período de maturação, mas ela precisa passar pelo crivo da regra de liquidez referente à inclusão de ativos no portfólio. Casos em que uma ou mais ações deixam de estar disponíveis para negociação ao longo do período de maturação são tratados da mesma forma que ações que ficaram mais de 10 pregões seguidos sem negociações.

Quando um ativo é retirado do portfólio em um período de maturação, não ocorre a redistribuição do seu peso para os demais ativos que permaneceram na carteira. Para todos os efeitos, o algoritmo irá interpretar que as ações que foram retiradas do portfólio por falta de liquidez foram substituídas por um ativo de retorno zero até o final do *PM*<sup>45</sup>. É necessário que assim seja porque o objetivo é gerar uma simulação que mostre como um determinado conjunto de parâmetros contribuiu para o *Information Ratio* daquela implementação específica da estratégia. Se algum desses parâmetros for alterado ao longo da implementação da estratégia por causa da exclusão de uma ação, haverá, posteriormente, um problema de viés de estimação. Isto porque a variável explicada (*Information Ratio*) daquela simulação não foi gerada exclusivamente pelos parâmetros que compõem as variáveis explicativas daquela simulação (conforme explicado na seção 4.5.5). Por um lado, pode-se argumentar que não é realista pressupor que um gestor não irá incluir outra (ou outras) ações no lugar das que foram

---

45 Na verdade, o que o algoritmo faz é atribuir um peso zero ao ativo que está sendo retirado do portfólio, mas sem aumentar o peso dos demais ativos. Como a soma dos pesos de todos os ativos no portfólio continua tendo que ser 1, o efeito prático é o surgimento de um ativo “fantasma”, que não aparece no portfólio e, portanto, tem retorno igual a zero.

retiradas. Por outro lado, pode-se alegar que, na prática, todo fundo de investimento mantém alguma quantidade de caixa em seu patrimônio, e que o retorno do caixa é igual a zero.

É importante ressaltar que, ao longo de uma simulação, toda e qualquer análise de liquidez dos ativos é feita retrospectivamente, como de fato aconteceria em uma implementação prática, na vida real, da estratégia. Uma análise prospectiva da liquidez de um ativo, e a sua inclusão ou não em um portfólio por conta disso, contaminaria a análise com um viés de sobrevivência.

#### **4.5.4. Drawdown máximo**

Uma medida importante para avaliar o risco de um investimento é o *drawdown* máximo observado. *Drawdown* é a queda do valor do portfólio entre um pico (maior valor patrimonial do portfólio até aquele momento) e um vale (menor valor patrimonial do portfólio após o último pico). O *drawdown* é medido como o percentual da queda em relação ao pico. Então, se, por exemplo, um portfólio atingiu o valor de R\$ 1.000,00 (mil reais) em um pico e, posteriormente a este pico, o menor valor atingido pelo portfólio foi de R\$ 400,00 (quatrocentos reais), observou-se um *drawdown* de 60%. Ao longo do tempo, um portfólio observa vários *drawdowns*. O maior *drawdown*, isto é, a maior queda entre um pico e um vale, é chamado de *drawdown* máximo.

#### **4.5.5. Descrição do Algoritmo de Simulações**

O Algoritmo segue as etapas descritas abaixo para a realização de cada simulação *i*:

1. É apresentado ao Algoritmo a Base de Dados sobre a qual ele será executado. Para gerar a Base de Dados dos Resultados das Simulações, é utilizado o Período de Treino da Base de Dados dos Preços Históricos. Para testar o desempenho, fora da amostra, de uma regra de negociação, é utilizado o Período de Testes da Base de Dados dos Preços Históricos;
2. O Algoritmo parte do início da Base de Dados para criar o primeiro<sup>46</sup> Período de Formação (explicado na seção 4.5.1.2). Ações sem negociações (lacunas na base de dados) são tratadas conforme explicado na seção 4.5.3;

---

46 O segundo período de formação termina imediatamente antes do início do segundo período de maturação, e assim sucessivamente.

3. Aplica-se uma função sobre o Período de Formação, que até então apresenta os preços das ações em cada dia, para que ele passe a apresentar os retornos das ações em cada dia, segundo a Eq. 6;
4. É calculado o desempenho, segundo definido pelo Critério de Formação  $CF_i$  (vide explicação na seção 4.5.1.1), de todas as ações com dados disponíveis ao longo de todo o primeiro período de formação  $PF_i$ ;
5. Seleção das  $N_i$  (calculadas através do parâmetro  $Q_i$  explicado na seção 4.5.1.4) ações que desempenharam pior<sup>47</sup> segundo o Critério de Formação  $CF_i$  na avaliação feita na etapa anterior;
6. Distribuição dos pesos (participação percentual das ações na carteira) das ações no portfólio  $W_i$  segundo o Critério de Distribuição de Pesos  $DP_i$  (explicado na seção 4.5.1.5, página 52), com base nos dados históricos de tamanho  $TA$  (explicado na seção 4.5.1.6);
7. Manutenção do portfólio pelo Período de Maturação  $PM_i$ <sup>48</sup> (explicado na seção 4.5.1.3). Ao longo do Período de Maturação, rebalancear o portfólio segundo o Período para Rebalanceamento  $PR_i$  (explicado na seção 4.5.1.7, página 55) para reestabelecer os pesos previstos em  $W_i$ ;
8. Ao final do Período de Maturação  $PM_i$ , iniciar um novo ciclo de cálculo de desempenho, cálculo de distribuições de pesos, manutenção e rebalanceamento do portfólio, por repetidas vezes até que se encerre a base de dados sobre a qual está sendo executado o Algoritmo;
9. Sempre que ocorrer qualquer compra ou venda de ação (seja ao iniciar ou terminar um período de maturação, seja nos próprios rebalanceamentos ao longo do período de maturação), serão levados em consideração os custos de transação conforme explicado na seção 4.5.2. O Algoritmo simula negociações que tentam minimizar os custos de transação (como de fato aconteceria na prática da gestão de um portfólio). Por exemplo: caso determinada ação em um portfólio tenha que deixar de representar 10% do patrimônio do portfólio para passar a representar 8%, os custos de transação

---

47 Quanto menor o valor obtido pela medida de desempenho prescrita no Critério de Formação, pior será considerado o desempenho da ação (mesmo no caso do Índice Sharpe (1966) com sua aparente limitação com valores negativos conforme ponderado na seção 4.5.1.1).

48 O primeiro período de maturação inicia-se logo após o término do primeiro período de formação. O segundo período de maturação inicia-se logo após o término do primeiro período de maturação, e assim sucessivamente. O último período de maturação se encerra com o término dos dados sobre os quais está sendo executado o Algoritmo.



incidirão sobre uma venda de 2% das ações, e não sobre uma venda de 10% e uma posterior compra de 8%.

#### **4.5.6. Gráficos e Dados gerados pelo Algoritmo de Simulações**

Ao término de cada simulação, o Algoritmo de Simulações gera as seguintes informações (sempre que se faz referência à “*benchmark*” nesta seção, entenda-se o Ibovespa ou o S&P 500, dependendo de qual país está sendo analisado):

##### 1. Uma imagem com os seguintes gráficos:

- 1.1. Transações (compras e vendas em proporção do total da carteira). Este gráfico mostra quantos por cento do portfólio foi transacionado (compras e vendas) em cada dia. O valor mínimo deste gráfico é zero (quando não ocorreram transações), e o valor máximo é 2 (200%), que significa que toda a carteira original foi vendida, e depois uma nova carteira inteira foi comprada.
- 1.2. Custos das Transações. Este gráfico mostra qual foi o custo das transações em cada dia. Esse custo é medido em valores percentuais que são subtraídos do retorno do portfólio no dia da transação.
- 1.3. Média Aritmética dos Custos de Transação dos Ativos na Carteira. O objetivo desse gráfico é mostrar a evolução dos custos de transação médios dos ativos que compõem a carteira. São apresentados valores para todos os dias ao longo da simulação (independentemente se houve ou não transação naquele dia), além disso, a média não é ponderada pelo percentual de cada ativo na carteira, de modo que se tem uma noção geral dos custos de transação dos ativos na carteira independentemente da distribuição dos pesos.
- 1.4. Retornos da Simulação. Série temporal dos retornos, dia a dia, da simulação após os custos de transação.
- 1.5. Evolução Patrimonial da Simulação e do índice de mercado. Gráfico com a comparação das evoluções patrimoniais (partindo de 1, isto é, 100%) da simulação e do índice de mercado (Ibovespa no caso brasileiro e S&P 500 no caso estadunidense).

2. “numero\_simulacao”: um texto com o número identificador da simulação e com a indicação se a simulação é com ou sem custos de simulação (conforme será explicado na seção 5.1.2, foram feitas simulações com e sem custos de transação para comparar os resultados).

3. “data\_inicio\_simulacao”: a data do primeiro dia do primeiro período de maturação da simulação.
4. “data\_fim\_simulacao”: a data do último dia do último período de maturação da simulação.
5. “PF”: tamanho do Período de Formação  $PF$  conforme formalizado na seção 4.5.1.2.
6. “CF”: a medida de desempenho  $CF$  utilizada para selecionar os ativos “perdedores” conforme formalizado na seção 4.5.1.1.
7. “Q”: o valor de  $Q$  conforme formalizado na seção 4.5.1.4.
8. “TA”: o valor de  $TA$  conforme formalizado na seção 4.5.1.6.
9. “DP”: o critério  $DP$  conforme formalizado na seção 4.5.1.5.
10. “PM”: o tamanho de  $PM$  conforme formalizado na seção 4.5.1.3.
11. “PR”: o valor de  $PR$  conforme formalizado na seção 4.5.1.7.
12. “numero\_medio\_ativos\_simulacao”: o valor médio de ativos que são adquiridos no início de cada período de maturação ao longo da simulação. A retirada de ações ao longo de um período de maturação não afeta este número.
13. “custo\_transacao\_medio\_anualizado\_simulacao”: apresenta o custo, isto é, o que foi subtraído do retorno, em média, por ano, em cada simulação por conta das compras e vendas de ativos no portfólio. O custo médio é calculado inicialmente em função do número de dias em cada simulação, isto é, parte-se do total que foi gasto ao longo de toda a simulação (lembrando que diferentes simulações possuem diferentes durações), toma-se a média diária desses custos, e depois é feita a mudança de frequência para anual.
14. “information\_ratio\_anualizado\_simulacao”<sup>49</sup>: o valor anualizado do *Information Ratio* da simulação.
15. “retorno\_medio\_anualizado\_simulacao”: o valor anualizado do retorno (sem ajuste por risco) da simulação.
16. “retorno\_medio\_anualizado\_benchmark”: o valor anualizado do retorno (sem ajuste por risco) do *benchmark*.
17. “sharpe\_anualizado\_simulacao”<sup>50</sup>: o valor anualizado do Índice Sharpe da simulação.

---

49 A transformação de frequência diária para para anual do *Information Ratio* foi feita ao se multiplicar o *Information Ratio* diário por  $\sqrt{252}$ .

50 A transformação de frequência diária para anual do Índice Sharpe foi feita ao se multiplicar o Índice Sharpe diário por  $\sqrt{252}$ .

18. “sharpe\_anualizado\_benchmark”<sup>51</sup>: o valor anualizado do Índice Sharpe do *benchmark*.
19. “alfa\_jensen\_anualizado\_simulacao”: o valor anualizado do Alfa de Jensen da simulação.
20. “pvalor\_alfa\_simulacao”: o *p-valor* do Alfa de Jensen da simulação.
21. “beta\_simulacao”: o *beta* da simulação.
22. “pvalor\_beta\_simulacao”: o *p-valor* do *beta* da simulação.
23. “desvio\_padrao\_anualizado\_simulacao”<sup>52</sup>: o desvio padrão anualizado da simulação.
24. “desvio\_padrao\_anualizado\_benchmark”<sup>53</sup>: o desvio padrão anualizado do *benchmark*.
25. “valor\_drawdown\_maximo\_simulacao”: o valor do maior *drawdown* (isto é, a diferença entre um pico e um vale na evolução do patrimônio investido) da simulação.
26. “valor\_drawdown\_maximo\_benchmark”: o valor do maior *drawdown* do *benchmark*.
27. “data\_pico\_drawdown\_maximo\_simulacao”: a data do pico do maior *drawdown* da simulação.
28. “data\_vale\_drawdown\_maximo\_simulacao”: a data do vale do maior *drawdown* da simulação.
29. “data\_pico\_drawdown\_maximo\_benchmark”: a data do pico do maior *drawdown* do *benchmark*.
30. “data\_vale\_drawdown\_maximo\_benchmark”: a data do vale do maior *drawdown* do *benchmark*.

#### **4.6. Otimização dos parâmetros de implementação da Estratégia de Investimento em Desempenho Contrário**

Uma vez gerada a Base de Dados dos Resultados das Simulações, ela é utilizada para estimar como cada parâmetro de implementação da estratégia impacta o valor médio do *Information Ratio* das implementações da estratégia de investimento em desempenho contrário. Em outras palavras, a Base de Dados dos Resultados das Simulações é utilizada para estimar os coeficientes dos parâmetros de implementação da estratégia em termos da variação da *Information Ratio*.

É importante lembrar que cada simulação foi gerada com determinada combinação de parâmetros e foi executada sobre um determinado período de tempo. Até as datas iniciais e

---

51 Vide nota de rodapé número 50.

52 A transformação de frequência diária para anual do desvio padrão foi feita ao se multiplicar o desvio padrão diário por  $\sqrt{252}$ .

53 Vide nota de rodapé número 52.

finais de cada simulação variam, já que também varia o tamanho do período de formação, que determina a data do primeiro dia do primeiro período de maturação<sup>54</sup>. Mas além disso, questões contingenciais e idiossincráticas não relacionadas aos seus parâmetros também interferem no *Information Ratio* de uma simulação. É o caso, por exemplo, de uma simulação com poucas ações (pequeno valor de  $Q$ ) e que, em determinado período de maturação, tenha se beneficiado de uma valorização extraordinária e imprevisível de determinada ação. Da mesma forma, uma determinada simulação pode ter sido especialmente prejudicada porque, por uma coincidência, foram adquiridas muitas ações de um setor que enfrentou escândalos de corrupção ou acidentes naturais. É justamente por isso que não basta olhar quais foram os parâmetros da simulação mais bem-sucedida na Base de Dados dos Resultados das Simulações. O fato de aquele conjunto de parâmetros ter sido vitorioso dentro da amostra não oferece qualquer garantia de que ele também seria vitorioso fora da amostra. Por outro lado, adotar técnicas de estimação populacional (real) dos coeficientes dos parâmetros de implementação da estratégia é uma forma de anular (ou pelo menos atenuar) os efeitos das contingências e idiossincrasias de cada simulação.

A técnica de estimação adotada no presente trabalho é a dos Mínimos Quadrados Ordinários (MQO). Essa opção foi feita pois, segundo o Teorema de Gauss-Markov, esse é o melhor estimador linear não viesado caso sejam atendidos os seguintes pressupostos (GUJARATI, 2011, p. 84):

- Hipótese 1: linearidade dos parâmetros.
- Hipótese 2: independência dos regressores com relação ao termo de erro.
- Hipótese 3: valor médio do termo de erro igual a zero.
- Hipótese 4: homocedasticidade do termo de erro.
- Hipótese 5: inexistência de autocorrelação entre os termos de erro.
- Hipótese 6: número de observações maior que o número de parâmetros a serem estimados.
- Hipótese 7: variabilidade dos valores dos regressores.

---

<sup>54</sup> Na verdade, o tamanho do período de formação só determina o início do período de maturação no Período de Treino da Base de Dados dos Preços Históricos, já que não existem dados anteriores ao início do Período de Treino. Mas, quando o algoritmo é aplicado sobre o Período de Testes, como existem dados anteriores, o primeiro dia do primeiro período de maturação é o mesmo para todas as simulações independentemente do tamanho do período de formação adotado (considerando que o valor máximo de período de formação adotado no presente trabalho é de 6 anos).

Antes de apresentar o modelo de regressão linear utilizado para estimar, através do MQO, os coeficientes dos parâmetros de implementação da estratégia (variáveis independentes) e seus impactos no *Information Ratio* (variável dependente), é importante fazer duas considerações. A primeira é a de que, dos sete parâmetros de implementação da estratégia de investimento em desempenho contrário (todos eles formalizados na seção 4.5.1), dois serão incorporados ao modelo por meio de variáveis *dummy*: Critério de Formação *CF* e Critério de Distribuição de Pesos *DP*. O objetivo nesse caso é avaliar quais desses critérios são os melhores ao se implementar a estratégia de investimento em desempenho contrário. A segunda consideração é a de que, com base no que foi ponderado na seção 3.2, pressupõe-se que existam valores ótimos dos seguintes parâmetros de implementação da estratégia: Período de Formação (*PF*), Período de Maturação (*PM*), Fração do Total das Ações Disponíveis (*Q*), Tamanho da Amostra para o Cálculo da Distribuição de Pesos (*TA*) e Período para Rebalanceamento (*PR*). Presume-se também que esses valores ótimos se encontram em algum ponto entre os valores máximos e mínimos das distribuições de frequência apresentadas na seção 4.5.1. Portanto, para que o estimador consiga captar essa relação não linear e estime o ponto em que o parâmetro maximiza o *Information Ratio*, serão adotadas formas quadráticas no modelo linear abaixo:

$$IR_i = \beta_0 + \beta_1 Alfa_i + \beta_2 Sharpe_i + \beta_3 PF_i + \beta_4 PF_i^2 + \beta_5 PM_i + \beta_6 PM_i^2 + \beta_7 Q_i + \beta_8 Q_i^2 + \beta_9 M_i + \beta_{10} M_{Si} + \beta_{11} TA_i + \beta_{12} TA_i^2 + \beta_{13} PR_i + \beta_{14} PR_i^2 + u_i \quad \text{Eq. 26}$$

Uma vez estimados os coeficientes dos parâmetros de implementação da estratégia, é possível calcular a combinação ótima desses parâmetros (e, conseqüentemente, responder todas as perguntas apresentadas na seção 1.5). Ao aplicar esses parâmetros no Período de Testes (explicado na seção 4.2), será verificado, no final de todo processo, se valeu a pena implementar e utilizar o Algoritmo de Otimização da Estratégia de Investimento em Desempenho Contrário.

## 5. RESULTADOS

Optou-se por gerar resultados com e sem custos de transação para investigar o impacto que os custos de transação geram sobre as carteiras e sobre a otimização dos parâmetros de implementação da estratégia. Para o caso brasileiro, foram geradas 10.000 simulações com custos de transação e 10.000 simulações sem custos de transação. Para o caso estadunidense, foram geradas 1.200 simulações com custos de transação e 1.200 simulações sem custos de transação. O resultado de todas as simulações, isto é, gráficos<sup>55</sup> e Bases de Dados dos Resultados das Simulações podem ser acessados pelo link:

[https://www.dropbox.com/sh/bkyutaqamx11smb/AAB\\_sHyhvUTojhwvCedZFYU3a?dl=0](https://www.dropbox.com/sh/bkyutaqamx11smb/AAB_sHyhvUTojhwvCedZFYU3a?dl=0)

### 5.1. Brasil

#### 5.1.1. Com custos de transação

A implementação do MQO no modelo apresentado na Eq. 26 sobre os dados das simulações brasileiras com custos de transação gerou o seguinte resultado (foi utilizado o software Gretl para executar os modelos e seus respectivos testes):

*Tabela 6: MQO, Brasil (com custos de transação). Variável dependente: information\_ratio\_anualizado*

	<i>Coefficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig</i> <small><sup>56</sup></small>
const	-0,0765557	0,0142551	-5,370	<0,0001	***
Alfa	0,0117337	0,00614394	1,910	0,0562	*
Sharpe	0,0162773	0,00614234	2,650	0,0081	***
PF	-0,000192287	2,63759e-05	-7,290	<0,0001	***
PF2	1,66975e-07	1,64107e-08	10,17	<0,0001	***

55 Os gráficos que possuem nos nomes de seus arquivos a expressão “ALERTA” são referentes às simulações em que, em algum dia, o retorno do portfólio foi superior a 100%. Esse tipo de ocorrência de fato merece atenção, e, para facilitar sua identificação, foi incluída essa expressão no nome dos arquivos dos gráficos. No entanto, não foram identificados problemas no Algoritmo de Simulações que indiquem tais retornos extraordinários sejam gerados por falhas no código. Também foi investigado se tais retornos tão intensos não seriam erros na base de dados da Economática, e da mesma forma não foram encontrados problemas já que no próprio histórico da B3 (no caso brasileiro) foi possível verificar que algumas ações apresentaram intensa variação de preços de um dia para o outro. De qualquer forma, de um total de 20 mil simulações para o caso brasileiro, apenas 251 (1,25%) geraram esse alerta. No caso estadunidense, somente 2 em 2400 (0,08%) incorreram neste fenômeno.

56 Um asterisco significa que o p-valor é menor que 10%. Dois asteriscos significam que o p-valor é menor que 5%. Três asteriscos significam que o p-valor é menor que 1%.

PM	-6,12756e-05	1,34215e-05	-4,565	<0,0001	***
PM2	6,96870e-09	4,17076e-09	1,671	0,0948	*
Q	-1,27409	0,0686706	-18,55	<0,0001	***
Q2	1,68864	0,133480	12,65	<0,0001	***
M	0,0447876	0,00887971	5,044	<0,0001	***
Ms	0,0256564	0,00883598	2,904	0,0037	***
TA	0,000132586	3,24805e-05	4,082	<0,0001	***
TA2	-9,93037e-08	2,73601e-08	-3,630	0,0003	***
PR	8,46995e-06	1,43549e-05	0,5900	0,5552	
PR2	-2,91154e-09	5,98518e-09	-0,4865	0,6267	

Média var. dependente	-0,289856	D.P. var. dependente	0,266744
Soma resíd. quadrados	626,1449	E.P. da regressão	0,250417
R-quadrado	0,119904	R-quadrado ajustado	0,118670
F(14, 9985)	97,16827	P-valor(F)	7,5e-264

Fonte: resultado gerado pelo software Gretl, com adaptações.

Foi aplicado o Teste de White para a heteroscedasticidade (cuja hipótese nula é a de homocedasticidade) e foi obtido um p-valor = 1,16567e-51. Ou seja, foi necessário implementar um modelo de heteroscedasticidade corrigida<sup>57</sup>.

*Tabela 7: MQO Heterocedasticidade Corrigida, Brasil (com custos de transação). Variável dependente: information\_ratio\_anualizado*

	<i>Coefficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig.</i>
const	-0,0854369	0,0105578	-8,092	<0,0001	***
Alfa	0,000471288	0,00376432	0,1252	0,9004	
Sharpe	0,00473946	0,00381692	1,242	0,2144	

<sup>57</sup> Na referência de comandos do Gret (<http://gretl.sourceforge.net/gretl-help/cmdref.html>) está a explicação do procedimento para a correção da heterocedasticidade: “This command is applicable where heteroskedasticity is present in the form of an unknown function of the regressors which can be approximated by a quadratic relationship. In that context it offers the possibility of consistent standard errors and more efficient parameter estimates as compared with OLS. The procedure involves (a) OLS estimation of the model of interest, followed by (b) an auxiliary regression to generate an estimate of the error variance, then finally (c) weighted least squares, using as weight the reciprocal of the estimated variance. In the auxiliary regression (b) we regress the log of the squared residuals from the first OLS on the original regressors and their squares (by default), or just on the original regressors (if the --no-squares option is given). The log transformation is performed to ensure that the estimated variances are all non-negative. Call the fitted values from this regression  $u^*$ . The weight series for the final WLS is then formed as  $1/\exp(u^*)$ .”

PF	-0,000206406	1,51762e-05	-13,60	<0,0001	***
PF2	1,71455e-07	9,60731e-09	17,85	<0,0001	***
PM	-9,01994e-05	9,31240e-06	-9,686	<0,0001	***
PM2	1,66399e-08	2,79759e-09	5,948	<0,0001	***
Q	-1,00368	0,0528309	-19,00	<0,0001	***
Q2	1,29335	0,0923530	14,00	<0,0001	***
M	0,0603592	0,00541085	11,16	<0,0001	***
Ms	0,0500512	0,00534193	9,369	<0,0001	***
TA	7,24925e-05	2,04631e-05	3,543	0,0004	***
TA2	-7,20518e-08	1,70395e-08	-4,229	<0,0001	***
PR	6,52496e-06	8,32929e-06	0,7834	0,4334	
PR2	-2,43805e-09	3,52237e-09	-0,6922	0,4889	

Estatísticas baseadas nos dados ponderados:

R-quadrado	0,170865	R-quadrado ajustado	0,169702
F(14, 9985)	146,9763	P-valor(F)	0,000000

Estatísticas baseadas nos dados originais:

Média var. dependente	-0,289856	D.P. var. dependente	0,266744
Soma resíd. quadrados	629,8647	E.P. da regressão	0,251159

Fonte: resultado gerado pelo *software* Gretl, com adaptações.

Foram aplicados testes de normalidade dos resíduos, cujos resultados foram categóricos ao afastar a hipótese nula de normalidade:

1. Teste de Doornik-Hansen = 1,38658e+06, com p-valor = 0
2. Shapiro-Wilk W = 0,308414, com p-valor 1,0955e-105
3. Teste de Lilliefors = 0,222081, com p-valor  $\approx$  0
4. Teste de Jarque-Bera = 2,60342e+08, com p-valor = 0

Vale a pena ressaltar, no entanto, que apesar de desejável<sup>58</sup>, a normalidade dos resíduos não é um dos pressupostos do modelo clássico de regressão linear. Ou seja, segundo o teorema de Gauss-Markov, caso estejam presentes as hipóteses já apresentadas na seção 4.6, os estimadores de mínimos quadrados ordinários são os melhores estimadores lineares não viesados (GUJARATI, 2011, p. 122), mesmo que os resíduos sejam não normais.

<sup>58</sup> A normalidade dos resíduos é um dos pressupostos do modelo de regressão linear normal.



A Hipótese 1 (linearidade dos parâmetros) está satisfeita uma vez que o modelo executado é linear nos parâmetros (vide Eq. 26).

A Hipótese 2 (independência dos regressores com relação ao termo de erro) pode ser testada ao salvar os resíduos do modelo apresentado na Tabela 7 e depois utilizá-lo como variável dependente em um modelo com os mesmos regressores (variáveis independentes) do modelo original (apresentado na Tabela 7). Segue o resultado deste modelo:

*Tabela 8: MQO Heterocedasticidade Corrigida, Brasil (com custos de transação). Variável dependente: uhat1*

	<i>Coefficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig.</i>
const	-1,25977e-12	0,0105578	-1,193e-10	1,0000	
Alfa	0,00000	0,00376432	-2,094e-11	1,0000	
Sharpe	0,00000	0,00381692	-1,200e-11	1,0000	
PF	0,00000	1,51762e-05	4,251e-11	1,0000	
PF2	0,00000	9,60731e-09	-3,632e-11	1,0000	
PM	0,00000	9,31240e-06	1,413e-12	1,0000	
PM2	0,00000	2,79759e-09	1,834e-12	1,0000	
Q	4,84342e-12	0,0528309	9,168e-11	1,0000	
Q2	-4,31793e-12	0,0923530	-4,675e-11	1,0000	
M	3,05673e-13	0,00541085	5,649e-11	1,0000	
Ms	2,99256e-13	0,00534193	5,602e-11	1,0000	
TA	0,00000	2,04631e-05	-6,229e-11	1,0000	
TA2	0,00000	1,70395e-08	4,550e-11	1,0000	
PR	0,00000	8,32929e-06	2,947e-12	1,0000	
PR2	0,00000	3,52237e-09	1,126e-12	1,0000	

Estadísticas baseadas nos dados ponderados:

Soma resíd. quadrados	94236,77	E.P. da regressão	3,072106
R-quadrado	0,000000	R-quadrado ajustado	-0,001402
F(14, 9985)	5,84e-12	P-valor(F)	1,000000
Log da verossimilhança	-25405,51	Critério de Akaike	50841,02
Critério de Schwarz	50949,18	Critério Hannan-Quinn	50877,63

Estadísticas baseadas nos dados originais:

Média var. dependente	0,001820	D.P. var. dependente	0,250977
-----------------------	----------	----------------------	----------

Soma resíd. quadrados	629,8647	E.P. da regressão	0,251159
-----------------------	----------	-------------------	----------

Fonte: resultado gerado pelo *software* Gretl, com adaptações.

O fato do p-valor de todas as variáveis independentes ser igual a 1 demonstra que não há qualquer correlação entre estes regressores e os resíduos do modelo apresentado na Tabela 7.

A Hipótese 3 (valor médio do termo de erro igual a zero) pode ser considerada satisfeita uma vez que a média do resíduo do modelo apresentado na Tabela 7 é apenas 0,0018204.

A Hipótese 4 (homocedasticidade do termo de erro) também está satisfeita uma vez que o próprio modelo utilizado é um MQO de heterocedasticidade corrigida.

A Hipótese 5 (inexistência de autocorrelação entre os termos de erro) está satisfeita porque os dados são de corte transversal e foram obtidos como uma amostra aleatória da população (a população é o conjunto de todas as combinações possíveis de diferentes implementações da estratégia, e a amostra de 10 mil simulações foi gerada aleatoriamente pois seus parâmetros foram gerados aleatoriamente).

A Hipótese 6 (número de observações maior que o número de parâmetros estimados) também está satisfeita já que a base de dados utilizada possui 10 mil observações, enquanto o número de regressores é 14 (mais uma constante/intercepto).

Como todos os pressupostos do modelo clássico de regressão linear estão presentes, tem-se certeza de que se está utilizando o melhor estimador linear não viesado. Somente a título de análise, foi feito ainda o teste de Fatores de Inflacionamento da Variância (VIF) para detecção de colinearidade, no qual o menor valor possível é 1 e valores acima de 10 indicam a presença de colinearidade (GUJARATI, 2011):

*Tabela 9: VIF, MQO Heterocedasticidade Corrigida, Brasil (com custos de transação)*

Alfa	1,340
Sharpe	1,339
PF	20,569
PF2	19,692
PM	21,916
PM2	20,377
Q	15,555
Q2	15,557
M	2,801

Ms	2,807
TA	18,005
TA2	13,424
PR	14,473
PR2	12,936

Fonte: resultado gerado pelo *software* Gretl.

Conforme esperado, a maioria das variáveis apresentou indícios de colinearidade. Isto era esperado tanto por conta do intensivo uso de termos polinomiais (GUJARATI, 2011, p. 332) quanto pela forma como algumas variáveis foram construídas ( *PR* é definido em função do valor de *PM* conforme apresentado na seção 4.5.1.7 e *TA* tem como valor máximo *PF* e assume valor zero quando *DP* é igual a *Ig* conforme explicado na seção 4.5.1.5). Mas, se por um lado a presença de colinearidade aumenta os erros padrões dos coeficientes estimados, o que compromete a análise de suas significâncias estatísticas e dificulta a definição precisa de seus valores, por outro lado, mesmo na presença de colinearidade alta (mas não perfeita), o MQO continua sendo o melhor estimador linear não viesado caso sejam satisfeitas as hipóteses do modelo clássico de regressão linear (o que se constatou verdadeiro nesta própria seção). Além disso, a especificação do modelo foi feita fundamentando-se na teoria extraída da revisão de literatura (em especial nas considerações feitas na seção 3.2), de modo que não seria adequado mudar uma especificação teoricamente fundamentada por conta de um fenômeno (colinearidade) que não torna as estimativas viesadas. Por fim, cabe ressaltar que, conforme ponderado por Gujarati (2011, p. 353), “se o único propósito da regressão for a previsão ou prognóstico, a multicolinearidade não é um problema grave”. E é exatamente isso que se pretende fazer no presente estudo. Muito mais importante do que avaliar a significância estatística dos coeficientes individualmente, o objetivo é descobrir qual combinação linear dos parâmetros em conjunto maximiza o *Information Ratio*.

Uma possível solução para a colinearidade seria aumentar o número de observações, ou seja, de simulações (GUJARATI, 2011, p. 357). No caso brasileiro, isto é bastante viável (por conta do relativamente pequeno número de ações líquidas disponíveis ao longo de cada simulação, que faz com que não sejam incluídas tantas ações nos portfólios). Mas, no caso estadunidense, aumentar em algumas vezes o número de simulações demandaria muito tempo de processamento computacional.

Outro elemento interessante do modelo apresentado na Tabela 7 é o  $R^2$  ajustado, que apresentou valor de 16,97%, o que significa que 16,97% de toda variação do *Information*

*Ratio* pode ser explicada por fatores totalmente controláveis pelo investidor/gestor. No entanto, se a estratégia de investimento em desempenho contrário for inerentemente ruim a ponto de sequer a sua otimização gerar *Information Ratio* positiva, então ela deve de fato ser abandonada.

Também vale notar que o fato dos coeficientes da Tabela 7 serem números muito pequenos já era esperado. Isso se dá porque o *Information Ratio* é, em regra, um número pequeno (o resultado de uma divisão entre a média e o desvio padrão de uma série), enquanto que a maioria das variáveis explicativas são números grandes (intervalos de tempo que podem se estender por anos, medidos em dias).

Diante de todo o exposto nesta seção, podem-se utilizar, então, os coeficientes do modelo apresentado na Tabela 7 para definir os parâmetros ótimos de implementação da estratégia de investimento em valor contrário no Brasil em um contexto de existência de custos de transação. E isso é feito ao analisar como cada parâmetro impacta o *Information Ratio* segundo o modelo da Tabela 7. Vale a pena lembrar que o resultado do modelo econométrico da Tabela 7 pode ser apresentado como uma equação matemática:

$$\begin{aligned}
 IR_i = & -0,0854369 + 0,000471288 \times Alfa_i + 0,00473946 \times Sharpe_i \\
 & - 0,000206406 PF_i + 0,000000171455 \times PF_i^2 - 0,0000901994 PM_i \\
 & + 0,0000000166399 PM_i^2 - 1,00368 Q_i + 1,29335 Q_i^2 + 0,0603592 M_i \\
 & + 0,0500512 M_{S_i} + 0,0000724925 TA_i - 0,0000000720518 TA_i^2 \\
 & + 0,00000652496 PR_i - 0,00000000243805 PR_i^2 + u_i
 \end{aligned}
 \tag{Eq. 27}$$

Se por um lado apresentar o resultado do modelo econométrico da Tabela 7 na Eq. 27 gera uma equação muito grande e de difícil leitura, por outro lado ajuda a explicar que o resultado de um modelo econométrico é nada mais que uma função matemática que pode ser maximizada. Isto é, uma vez estimados os coeficientes dos parâmetros da função, basta agora calcular quais devem ser os valores a serem assumidos pelos parâmetros (ou seja, os valores das variáveis explicativas) que maximizem a função objetivo apresentada na Eq. 27. No presente caso, essa otimização não poderia ser feita pelo método dos Multiplicadores de Lagrange uma vez que as restrições não são restrições de igualdade (*equality constraints*), mas sim restrições de desigualdade (*inequality constraints*) cujos próprios limites das restrições variam em função do resultado dos valores de outros parâmetros (variáveis explicativas). Por exemplo, o período de rebalanceamento não pode ser superior ao período de maturação, e o tamanho da amostra para calcular a matriz de covariâncias não pode ser maior

que o período de formação. É também por esse motivo (o fato de que os limites das restrições do problema de otimização variarem em função dos próprios resultados da otimização) que implementar esse problema no Python ou no R pode ser bastante desafiador. No entanto, considerando a forma polinomial da função objetivo, ela pode ser maximizada pela simples análise de como cada um dos seus parâmetros contribui para o maior *Information Ratio* possível.

O primeiro parâmetro, critério de seleção, maximiza o *Information Ratio* quando se adota o *Sharpe* como medida de desempenho, pois é esse critério que apresentou o maior coeficiente (lembrando que não se poderia incluir a variável referente ao critério *Ret* , Retorno Simples, para não se incorrer em colinearidade perfeita entre os regressores e que, portanto, o seu coeficiente deve ser interpretado como sendo zero).

O segundo parâmetro, período de formação, foi incluído no modelo em forma quadrática e apresentou o seguinte resultado:

$$f(PF) = -0,000206406 PF + 0,000000171455 \times PF^2 \quad \text{Eq. 28}$$

A primeira derivada da Eq. 28 é:

$$f'(PF) = -0,000206406 + 0,00000034291 PF \quad \text{Eq. 29}$$

E a segunda derivada da Eq. 28 é:

$$f''(PF) = 0,00000034291 \quad \text{Eq. 30}$$

A função é convexa (segunda derivada positiva) e, portanto, não tem máximo global. O que isso significa é que, quanto maior o período de formação, maior, em média, tende a ser o *Information Ratio*. É um resultado interessante e que vai contra o que havia sido conjecturado na seção 3.2.1, isto é, de que haveria um meio-termo ideal no tamanho do período de formação. Uma explicação para este resultado pode ser o fato de que, quanto maior o período de formação, menor a proporção de empresas com negociação recente e/ou baixa liquidez (pois elas são submetidas ao crivo da primeira regra de liquidez, apresentada na seção 4.5.3, por um período maior de tempo), o que faz com que aumente a proporção de empresas maiores (mais líquidas) e consolidadas. Será adotado, portanto, como parâmetro ótimo, o *PF* de 6 anos (1512 dias) que é o máximo adotado neste estudo conforme explicado na seção 4.5.1.2.

O terceiro parâmetro, período de maturação, também foi incluído em forma quadrática e apresentou o seguinte resultado:

$$f(PM) = -0,0000901994 PM + 0,0000000166399 \times PM^2 \quad \text{Eq. 31}$$

A primeira derivada da Eq. 31 é:

$$f'(PM) = -0,0000901994 + 0,00000003327980 PM \quad \text{Eq. 32}$$

A segunda derivada da Eq. 31 é:

$$f''(PM) = 0,00000003327980 \quad \text{Eq. 33}$$

Seguindo o mesmo raciocínio da definição do período de formação ótimo, conclui-se que, quanto maior o período de maturação, maior, em média, o *Information Ratio*. Apesar de não ter se confirmado a hipótese do “meio-termo ideal” conforme apresentado na seção 3.2.3, a explicação para o resultado do modelo é a de que, quanto maior o período de maturação, menos frequentes são as intensas compras e vendas (e os significativos custos de transação) que acontecem ao se terminar um período de maturação e iniciar o próximo. É fácil visualizar essa constatação nos gráficos das simulações. Rebalanceamentos geram custos de transação muito menores que mudanças de períodos de maturação, já que no primeiro existe somente o ajuste dos pesos entre ações que permanecem em um portfólio, enquanto que, ao iniciar um novo período de maturação, ativos são retirados e incluídos na carteira. Será adotado o  $PM$  de 12 anos (3024 dias), máximo do presente trabalho conforme explicado na seção 4.5.1.3.

O quarto parâmetro, percentual das ações disponíveis a serem incluídas no portfólio, a exemplo do que aconteceu com os parâmetros  $PF$  e  $PM$ , também apresentou no termo elevado a 2 de sua forma quadrática um coeficiente positivo, indicando que, quanto maior o  $Q$ , maior tende a ser, em média, o *Information Ratio*. Apesar de também não ter sido a hipótese do “meio-termo ideal” conjecturada na seção 3.2.6, o resultado faz sentido uma vez que, quanto maior o número de ações em um portfólio, menor tende a ser a sua variância e, portanto, maior o *Information Ratio* (vide Eq. 1). No entanto, mantendo a essência da estratégia de investimento em desempenho contrário que consiste em comprar ações “perdedoras”, será adotado como valor ótimo do parâmetro  $Q$  a fração 0,5 (ou seja, metade das ações disponíveis ao iniciar um novo período de maturação).

O quinto parâmetro, referente ao critério de distribuição de pesos, segundo o modelo da Tabela 7, maximiza o *Information Ratio* quando se adota o portfólio de mínima variância sem encolhimento da matriz de covariâncias conforme proposto por Ledoit e Wolf (2004b). É um resultado de certa forma surpreendente pois, se por um lado, uma menor variância de fato gera um *Information Ratio* maior, por outro lado, conforme explicado na seção 3.2.5, o encolhimento de Ledoit e Wolf (2004b) deveria melhorar a estimativa do portfólio de mínima variância. Além disso, o portfólio de distribuição igualitária (distribuição ingênua) apresentou, no modelo da Tabela 7, o pior resultado entre os critérios adotados neste trabalho, o que também é um resultado importante considerando a dificuldade de superar essa forma de distribuição de pesos (vide seção 3.2.5).

O sexto parâmetro, referente ao tamanho da amostra para cálculo do portfólio de mínima variância, apresentou o seguinte resultado:

$$f(TA) = 0,0000724925 TA - 0,0000000720518 \times TA^2 \quad \text{Eq. 34}$$

A primeira derivada da Eq. 34 é:

$$f'(TA) = 0,0000724925 - 0,00000014410360 TA \quad \text{Eq. 35}$$

A segunda derivada da Eq. 34 é:

$$f''(TA) = -0,00000014410360 \quad \text{Eq. 36}$$

O fato da função da Eq. 34 ser côncava (segunda derivada negativa) indica a existência de um máximo global, confirmando a hipótese de existência de um “meio-termo ideal” apresentada na seção 3.2.6, página 39. Igualando a Eq. 35 a zero, conclui-se que o valor do parâmetro *TA* que maximiza o *Information Ratio* é 503.

O sétimo parâmetro, referente ao período de rebalanceamento, apresentou o seguinte resultado:

$$f(PR) = 0,00000652496 PR_i - 0,00000000243805 \times PR^2_i \quad \text{Eq. 37}$$

A primeira derivada da Eq. 37 é:

$$f'(PR) = 0,00000652496 - 0,00000000487610 PR \quad \text{Eq. 38}$$

A segunda derivada da Eq. 37 é:

$$f''(PR) = -0,00000000487610 \quad \text{Eq. 39}$$

O fato da segunda derivada da Eq. 37 ser negativa conforma a hipótese do “meio-termo ideal” apresentada em 3.2.7. Ao igualar a Eq. 38 a zero tem-se que o valor de  $PR$  que maximiza o *Information Ratio* é 1338.

Os parâmetros ótimos explicados acima estão resumidos na Tabela 10.

*Tabela 10: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, Brasil (com custos de transação)*

$CF$	$Sharpe$
$PF$	1512 dias
$PM$	3024 dias
$Q$	0,5
$DP$	$M$
$TA$	503 dias
$PR$	1338 dias

Fonte: elaboração própria.

Ao executar o Algoritmo de Simulações (descrito na seção 4.5.5) sobre o Período de Testes da Base de Dados dos Preços Históricos do Brasil utilizando os parâmetros da Tabela 10, chega-se aos resultados apresentados na Tabela 11:

*Tabela 11: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (com custos de transação)*

data_inicio_simulacao	2011-04-04
data_fim_simulacao	2021-03-19
numero_medio_ativos_simulacao	74
custo_transacao_medio_anualizado_simulacao	2,54%
information_ratio_anualizado_simulacao	-7,78%
retorno_medio_anualizado_simulacao	0,96%
retorno_medio_anualizado_benchmark	2,57%
sharpe_anualizado_simulacao	-0,23
sharpe_anualizado_benchmark	-0,01



alfa_jensen_anualizado_simulacao	-1,76%
pvalor_alfa_simulacao	0,33
beta_simulacao	0,22
pvalor_beta_simulacao	0,00
desvio_padrao_anualizado_simulacao	8,09%
desvio_padrao_anualizado_benchmark	25,11%
valor_drawdown_maximo_simulacao	28,00%
valor_drawdown_maximo_benchmark	62,00%
data_pico_drawdown_maximo_simulacao	2011-04-25
data_vale_drawdown_maximo_simulacao	2016-01-21
data_pico_drawdown_maximo_benchmark	2011-04-05
data_vale_drawdown_maximo_benchmark	2016-01-26

Fonte: elaboração própria.

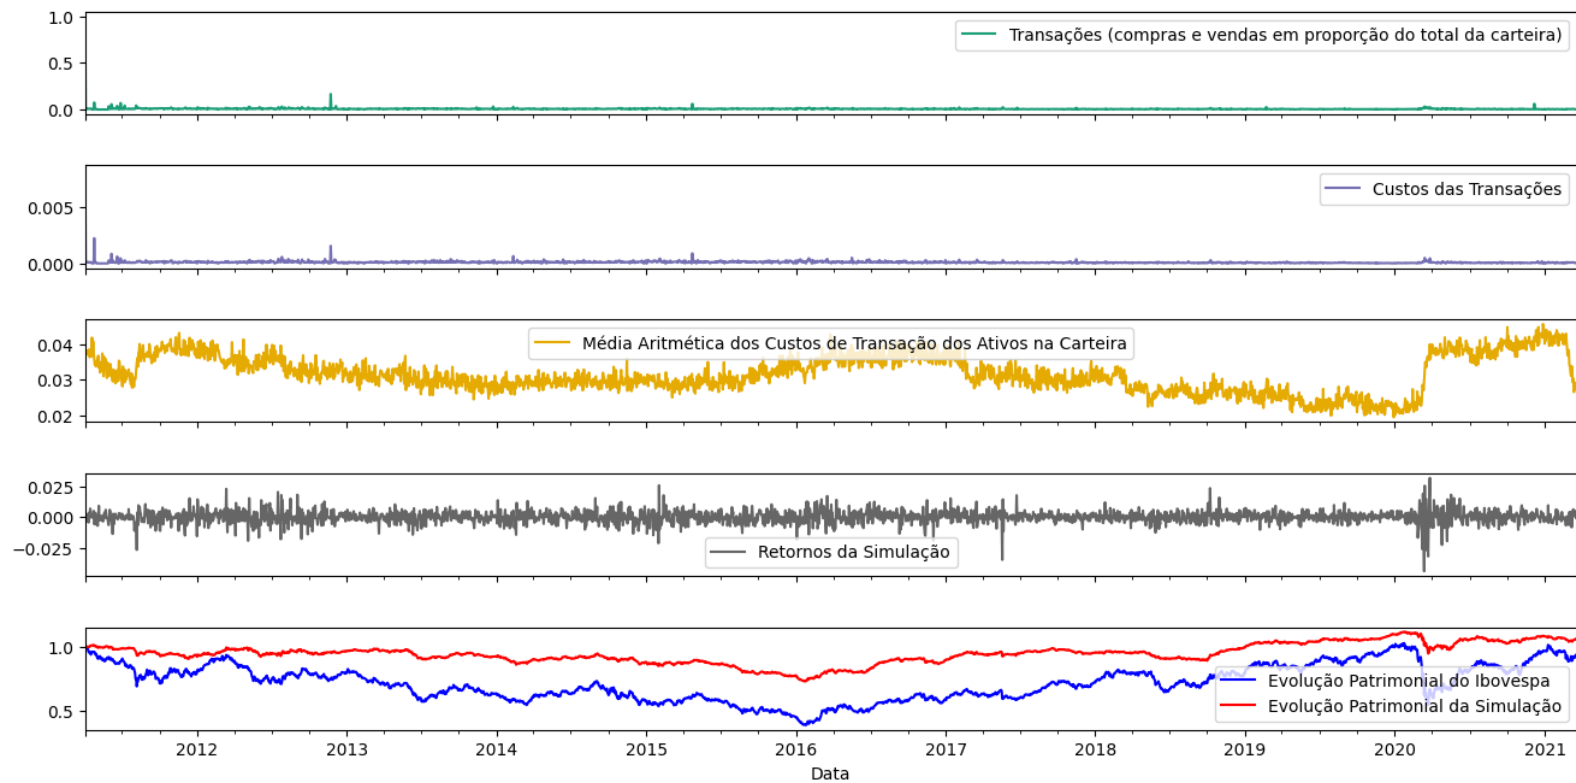


Figura 1: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (com custos de transação)

Fonte: elaboração própria.

Os resultados apresentados na Tabela 11 e na Figura 1 demonstram que o Algoritmo de Otimização da Estratégia de Investimento em Desempenho Contrário não foi bem sucedido

no objetivo de produzir uma regra de negociação que gerasse *Information Ratio* positivo. A aplicação dos parâmetros ótimos fora da amostra gerou, na realidade, um *Information Ratio* de -7,78% e um Alfa de Jensen de -1,76% (estatisticamente não significativo considerando um nível de significância de 5%). No entanto, é muito importante observar que, segundo informado na Tabela 7, o *Information Ratio* anualizado médio da amostra de 10.000 observações com custos de transação é de -28,98%. Ou seja, o Algoritmo de Otimização objeto deste trabalho conseguiu gerar um *Information Ratio* muito melhor (apesar de ainda ser muito ruim) que a média do *Information Ratio* de implementações aleatórias da estratégia. Além disso, os méritos da regra de negociação foram também o desvio padrão anualizado de 8,09% (contra 25,11% do Ibovespa), o *drawdown* máximo de 28,00% (contra 62,00% do Ibovespa) e o fato de que o patrimônio investido na simulação nunca esteve abaixo do patrimônio investido no Ibovespa.

Para além do resultado da simulação, é interessante observar a evolução da média aritmética dos custos de transação dos ativos na carteira. Esta simulação é especialmente útil para se observar essa série temporal porque a simulação inicia-se com um número de ativos no portfólio relativamente alto para o caso brasileiro (74 ativos) e não existem mudanças significativas no portfólio já que o período de maturação (12 anos) é superior à duração do Período de Treino. As únicas mudanças que existem na carteira são a título de retirada de ativos ilíquidos, o que não interfere na série dos custos médios de transação que se baseia exclusivamente nos ativos que compõem o portfólio no início do período de maturação. A primeira coisa a ser observada é que parece existir uma tendência de queda, ao longo dos anos, nos custos de transação dos ativos. Isso pode ser explicado, em parte, pelo fato de que ações que deixaram de ser negociadas ao longo do período de negociação continuam sendo computadas no cálculo da média dos custos dos ativos na carteira como se tivessem custos zero de compra e venda (sendo que sequer elas estão sendo negociadas). Esse problema, que só é significativo em simulações com período de maturação muito longo, deve ser corrigido nas próximas versões do Algoritmo de Simulações. No entanto, é provável que esse efeito (da contabilização das ações que já saíram de negociação) seja pequeno e que existam outras causas para a redução dos custos de transação ao longo do tempo. Isto porque, mesmo em simulações com período de maturação curto, percebe-se que há uma tendência de queda dos custos de transação ao longo do tempo. Além disso, é muito claro que, em momentos de grande crise sistêmica (notadamente em 2008 e em 2020), os custos de transação sobem de forma significativa. Uma possível explicação é um provável aumento do *bid-ask spread* por conta do aumento da aversão a risco por parte dos agentes ou, ainda, o aumento do custo de

oportunidade dos investidores em um cenário de incertezas. De qualquer forma, a investigação da variação dos custos de transação ao longo do tempo e em função de crises, tema que foge do objeto da presente pesquisa, merece um trabalho próprio em futuras oportunidades.

### 5.1.2. Sem custos de transação

Com o objetivo de verificar o impacto que os custos de transação geram sobre a estratégia de investimento em desempenho contrário, optou-se por repetir todo o processo descrito na seção 5.1.1 mas, dessa vez, em um contexto de total inexistência de custos de transação. O objetivo é investigar se os parâmetros ótimos da estratégia se alteram caso inexistam custos de transação e como seria o desempenho fora da amostra desses parâmetros, também sem custos de transação.

*Tabela 12: MQO Heterocedasticidade Corrigida, Brasil (sem custos de transação). Variável dependente: information\_ratio\_anualizado*

	<i>Coefficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig.</i>
const	0,603242	0,00698498	86,36	<0,0001	***
Alfa	-0,0440268	0,00259621	-16,96	<0,0001	***
Sharpe	-0,0527339	0,00262035	-20,12	<0,0001	***
PF	-0,000197348	1,05512e-05	-18,70	<0,0001	***
PF2	1,55288e-07	6,57058e-09	23,63	<0,0001	***
PM	-0,000416615	6,17303e-06	-67,49	<0,0001	***
PM2	8,71427e-08	1,87527e-09	46,47	<0,0001	***
Q	-0,445982	0,0342569	-13,02	<0,0001	***
Q2	0,458492	0,0614071	7,466	<0,0001	***
M	-0,135140	0,00364041	-37,12	<0,0001	***
Ms	-0,104303	0,00363847	-28,67	<0,0001	***
TA	-0,000128213	1,39124e-05	-9,216	<0,0001	***
TA2	8,78802e-08	1,20165e-08	7,313	<0,0001	***
PR	-1,94066e-06	5,71696e-06	-0,3395	0,7343	
PR2	1,11663e-09	2,40873e-09	0,4636	0,6430	

Estatísticas baseadas nos dados ponderados:

R-quadrado	0,674243	R-quadrado ajustado	0,673786
F(14, 9985)	1476,190	P-valor(F)	0,000000

Fonte: resultado gerado pelo *software* Gretl, com adaptações.

Inicialmente, destaca-se um dado que salta aos olhos no modelo da Tabela 12: o  $R^2$  ajustado de 67,37%. Este resultado é 50,4 pontos percentuais maior do que o  $R^2$  ajustado do modelo da Tabela 7 (16,97%). Ressalta-se que a única diferença entre os dados que alimentaram os dois modelos foi a inexistência de custos de transação (todos os demais parâmetros que geraram as simulações foram exatamente iguais). Isso significa que os custos de transação, em média, explicam aproximadamente metade do *Information Ratio* de um portfólio. Isto é, os custos de transação são muito mais importantes para o sucesso ou fracasso da estratégia de investimento em desempenho contrário do que qualquer parâmetro de implementação diretamente controlado pelo investidor.

Quanto à definição dos parâmetros ótimos, observa-se que, de todas as variáveis explicativas que foram incluídas no modelo de forma quadrática, nenhuma apresentou coeficiente negativo no termo quadrático. Isso significa que em nenhuma delas confirmou-se a hipótese do “meio-termo ideal” e que, a princípio, quanto maiores os valores destes parâmetros, maior, em média, o *Information Ratio*. Não foi possível vislumbrar uma explicação de por que  $TA$  e  $PR$ , que no caso do modelo com custos de transação tinham um “meio-termo ótimo”, passaram a apresentar um resultado que indica que, quanto maior, melhor (e, neste caso, eles assumirão seus respectivos valores máximos que são, respectivamente, os valores dos períodos de formação período de maturação). Especificamente no caso do  $PR$ , a inexistência de custos de transação deveria ensejar um valor ótimo pequeno, o que permitiria que se reestabelecesse, por exemplo, o portfólio de mínima variância com maior frequência sem que houvesse custos para tanto.

Com relação ao critério de formação e à distribuição de pesos, os valores ótimos foram, respectivamente,  $Ret$  (não incluído no modelo e, portanto, com coeficiente zero) e  $Ig$ . Não foi possível identificar porque a retirada dos custos de transação alterou os valores ótimos destes parâmetros.

*Tabela 13: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, Brasil (sem custos de transação)*

$CF$	$Ret$
$PF$	1512 dias
$PM$	3024 dias
$Q$	0,5

<i>DP</i>	<i>Ig</i>
<i>TA</i>	1512 dias
<i>PR</i>	3024 dias

Fonte: elaboração própria.

*Tabela 14: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (sem custos de transação)*

data_inicio_simulacao	2011-04-04
data_fim_simulacao	2021-03-19
numero_medio_ativos_simulacao	74
custo_transacao_medio_anualizado_simulacao	0,00%
information_ratio_anualizado_simulacao	47,86%
retorno_medio_anualizado_simulacao	11,62%
retorno_medio_anualizado_benchmark	2,57%
sharpe_anualizado_simulacao	0,70
sharpe_anualizado_benchmark	-0,01
alfa_jensen_anualizado_simulacao	8,65%
pvalor_alfa_simulacao	0,00
beta_simulacao	0,36
pvalor_beta_simulacao	0,00
desvio_padrao_anualizado_simulacao	11,77%
desvio_padrao_anualizado_benchmark	25,11%
valor_drawdown_maximo_simulacao	26,00%
valor_drawdown_maximo_benchmark	62,00%
data_pico_drawdown_maximo_simulacao	2020-01-23
data_vale_drawdown_maximo_simulacao	2020-03-23
data_pico_drawdown_maximo_benchmark	2011-04-05
data_vale_drawdown_maximo_benchmark	2016-01-26

Fonte: elaboração própria.




Figura 2: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, Brasil (sem custos de transação)

Fonte: elaboração própria.

A análise da Tabela 14 e da Figura 2 demonstra o sucesso da estratégia de investimento em desempenho contrário em um contexto sem custos de transação. Esse resultado era esperado considerando tanto o grande aumento do  $R^2$  ajustado da regressão ao se retirar os custos de transação, quanto o que é apresentado pelos artigos apresentados na seção 3.1, que concluíram pela lucratividade da estratégia em um contexto sem custos de transação. É interessante notar ainda que, conforme informado pela Tabela 12, o *Information Ratio* anualizado médio da amostra de 10.000 observações aleatórias da implementação da estratégia sem custos de transação é de apenas 0,58%. Já o *Information Ratio* anualizado da simulação com os parâmetros ótimos foi de 47,86%. O Alfa de Jensen da simulação com parâmetros ótimos foi de 8,65% (com p-valor de 0,00).

### 5.1.3. Conclusão Brasil

Os resultados apresentados nas seções 5.1.1 e 5.1.2 fazem concluir que a estratégia de investimento em desempenho contrário, na média, não gera *Information Ratio* positiva em um contexto de existência de custos de transação (que é o contexto real do mercado). O Algoritmo de Otimização da Estratégia, objeto do presente estudo, até foi bem sucedido em aumentar o valor da *Information Ratio* gerada em uma implementação fora da amostra, mas não o suficiente para gerar *Information Ratio* positivo. Já em um contexto fictício de inexistência de custos de transação, a estratégia de investimento em desempenho contrário se mostrou, na média, capaz de gerar *Information Ratio* positivo. Novamente, o Algoritmo de Otimização da Estratégia foi bem sucedido em aumentar o *Information Ratio* da estratégia.

## 5.2. *Estados Unidos*

### 5.2.1. Com Custos de Transação

Ao aplicar o mesmo método apresentado na seção 5.1.1, obtemos o modelo de regressão apresentado na Tabela 15.

*Tabela 15: MQO Heterocedasticidade Corrigida, EUA (com custos de transação). Variável dependente: information\_ratio\_anualizado*

	<i>Coefficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig.</i>
const	0,424615	0,0420163	10,11	<0,0001	***
Alfa	-0,0166869	0,0115088	-1,450	0,1473	
Sharpe	-0,0200450	0,0117152	-1,711	0,0873	*
PF	-0,000366971	4,90234e-05	-7,486	<0,0001	***
PF2	2,94142e-07	3,07288e-08	9,572	<0,0001	***
PM	-8,01173e-05	2,23018e-05	-3,592	0,0003	***
PM2	-3,23283e-09	7,11686e-09	-0,4542	0,6497	
Q	0,381379	0,147678	2,583	0,0099	***
Q2	-0,646537	0,266569	-2,425	0,0154	**
M	0,0347041	0,0177906	1,951	0,0513	*
Ms	0,0415215	0,0176860	2,348	0,0191	**
TA	4,51257e-05	5,97457e-05	0,7553	0,4502	
TA2	-1,68333e-08	4,76836e-08	-0,3530	0,7241	
PR	-3,15819e-05	3,29826e-05	-0,9575	0,3385	
PR2	9,19452e-09	8,73774e-09	1,052	0,2929	

Estatísticas baseadas nos dados ponderados:

R-quadrado	0,279143	R-quadrado ajustado	0,270626
F(14, 1185)	32,77689	P-valor(F)	1,80e-74

Estatísticas baseadas nos dados originais:

Média var. dependente	0,280646	D.P. var. dependente	0,210628
Soma resíd. quadrados	40,59284	E.P. da regressão	0,185083

Fonte: resultado gerado pelo *software* Gretl, com adaptações.

Segundo o modelo apresentado na Tabela 15, o critério de formação que apresentou melhor coeficiente foi *Ret* (não incluído no modelo e, portanto, com coeficiente zero). O período de formação, incluído no modelo em sua forma quadrática, apresentou coeficiente positivo no termo quadrático, de modo que será utilizado o maior *PF* adotado no presente trabalho, que é de 6 anos (1512 dias). O período de maturação, também incluído em sua forma quadrática, apresentou no termo elevado a 2 coeficiente negativo, o que tornaria possível o cálculo do valor ótimo deste parâmetro. Ocorre que o ponto máximo da função apresentada na Eq. 40 ocorre quando *PM* é igual a -12391, o que não é possível de ser implementado.

$$f(PM) = -8,01E-05 PM - 3,23E-09 PM^2 \quad \text{Eq. 40}$$

Portanto, considerando a hipótese do “meio-termo ideal” apresentada na seção 3.2.3, optou-se por utilizar o valor médio de período de maturação adotado neste trabalho segundo a Eq. 12, isto é, 1512 dias.

O parâmetro *Q*, incluído em sua forma quadrática, apresentou o seguinte resultado:

$$f(Q) = 0,381379 Q_i - 0,646537 x Q_i^2 \quad \text{Eq. 41}$$

A primeira derivada da Eq. 41 é:

$$f'(Q) = 0,381379 - 1,293074 Q \quad \text{Eq. 42}$$

A segunda derivada da Eq. 41 é:

$$f''(Q) = -1,293074 \quad \text{Eq. 43}$$



Considerando que a segunda derivada é negativa, igualar a Eq. 42 a zero, gera o resultado de que o valor ótimo de  $Q$  é 0,30.

A distribuição de pesos ótima é o portfólio de mínima variância com matriz de covariâncias encolhida.

Com relação à  $TA$ , temos o seguinte resultado:

$$f(TA) = 0,0000451257 TA - 0,00000001683338 \times TA^2 \quad \text{Eq. 44}$$

A primeira derivada da Eq. 44 é:

$$f'(TA) = 0,0000451257 - 0,0000000336666 TA \quad \text{Eq. 45}$$

A segunda derivada da Eq. 44 é:

$$f''(TA) = -0,0000000336666 \quad \text{Eq. 46}$$

Ao igualar a equação Eq. 45 a zero, e considerando que a Eq. 46 é negativa, tem-se que o valor ótimo de  $TA$  é 1340.

Quanto ao parâmetro  $PR$ , como seu termo quadrático é positivo (o que implica em segunda derivada positiva e inexistência de máximo global determinado), foi adotado o seu valor máximo possível, que é o valor de  $PM$ .

*Tabela 16: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, EUA (com custos de transação)*

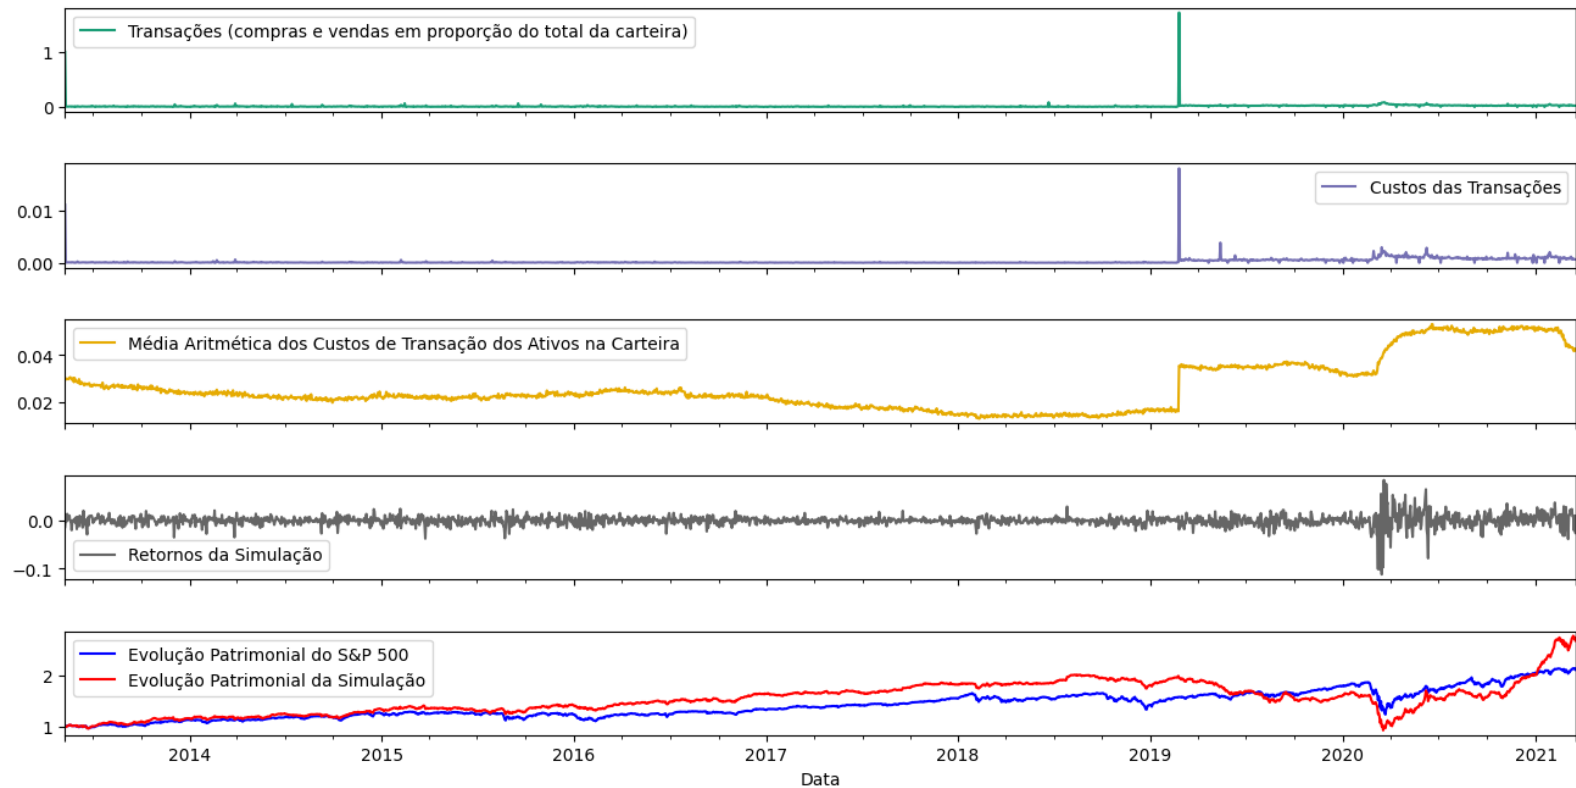
<i>CF</i>	<i>Ret</i>
<i>PF</i>	1512 dias
<i>PM</i>	1512 dias
<i>Q</i>	0,3
<i>DP</i>	<i>MVs</i>
<i>TA</i>	1340 dias
<i>PR</i>	1512 dias

Fonte: elaboração própria.

*Tabela 17: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (com custos de transação)*

data_inicio_simulacao	2013-05-09
data_fim_simulacao	2021-03-19
numero_medio_ativos_simulacao	571
custo_transacao_medio_anualizado_simulacao	6,54%
information_ratio_anualizado_simulacao	26,84%
retorno_medio_anualizado_simulacao	14,80%
retorno_medio_anualizado_benchmark	11,16%
sharpe_anualizado_simulacao	0,75
sharpe_anualizado_benchmark	0,60
alfa_jensen_anualizado_simulacao	5,36%
pvalor_alfa_simulacao	0,20
beta_simulacao	0,80
pvalor_beta_simulacao	0,00
desvio_padrao_anualizado_simulacao	17,86%
desvio_padrao_anualizado_benchmark	16,99%
valor_drawdown_maximo_simulacao	54,00%
valor_drawdown_maximo_benchmark	34,00%
data_pico_drawdown_maximo_simulacao	2018-08-14
data_vale_drawdown_maximo_simulacao	2020-03-18
data_pico_drawdown_maximo_benchmark	2020-02-19
data_vale_drawdown_maximo_benchmark	2020-03-23

Fonte: elaboração própria.



*Figura 3: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (com custos de transação)*

Fonte: elaboração própria.

Destaca-se na figura que após o término do primeiro período de maturação e início do segundo (no início de 2019) houve, como esperado, uma elevada proporção de compras e vendas na carteira, o que se observa pelos picos tanto no gráfico de transações quanto no gráfico de custos das transações. No entanto, o que não é evidente à primeira vista é a explicação de por que a média aritmética dos custos de transação dos ativos na carteira assumiu um novo patamar (mais elevado) logo após o início do segundo período de maturação. Esse fenômeno é observável nos gráficos das milhares de simulações realizadas no presente trabalho: quase sempre que se inicia um novo período de maturação, a média aritmética dos custos de transação dos ativos na carteira sobem de patamar mas, gradualmente, voltam a seguir a trajetória de queda ao longo do tempo. Uma explicação para esse fenômeno do aumento da média aritmética dos custos de transação ao iniciar um novo período de maturação está ao combinar duas constatações. A primeira é a de que, segundo Lesmond (1999), empresas menores apresentam maiores custos de transação. A segunda é a

de que, de acordo com Fama e French (1996, p. 66-68), ativos perdedores de longo prazo no passado se comportam como empresas pequenas. Ou seja, ao adquirir um portfólio de ações perdedoras, naturalmente a média aritmética dos custos de transação dos ativos será maior. Com o passar do tempo, as empresas que se recuperam passam a se comportar como empresas maiores, e os seus custos de transação caem.

Os resultados do caso estadunidense não poderiam ser mais diferentes do que se observou no caso brasileiro. Enquanto no Brasil a média do *Information Ratio* das simulações foi negativa (vide Tabela 7), no caso estadunidense as 1.200<sup>59</sup> implementações aleatórias da estratégia de investimento em desempenho contrário apresentaram média de 28,06% (vide Tabela 15). Esse resultado por si só não parece fazer sentido, considerando que o mercado acionário estadunidense é notoriamente mais maduro, líquido e, conseqüentemente, eficiente que o mercado acionário brasileiro. Isso deveria tornar o seu índice representativo (S&P 500) mais difícil de ser superado de forma consistente (que é exatamente o que o *Information Ratio* mede). Uma possível explicação talvez seja que a amostra (de 1.200 observações) ainda esteja muito pequena para refletir a média do *Information Ratio* real/populacional da estratégia. Outra hipótese é uma eventual falha no Algoritmo de Simulações, mas a princípio essa mesma falha deveria se manifestar também no caso brasileiro. Por fim, existe ainda a hipótese de que, ao contrário do que foi observado no Brasil, a estratégia de investimento em desempenho contrário, ainda que implementada de forma aleatória, é uma estratégia de sucesso no mercado americano em termos de geração de *Information Ratio* positivo.

Além disso, o Algoritmo de Otimização da Estratégia, que melhorou o valor da *Information Ratio* no Brasil (comparando a simulação fora da amostra com a média amostral), não foi capaz de gerar uma regra de negociação cujo *Information Ratio* tivesse sido maior que o da implementação aleatória da estratégia. Uma possível explicação é a de que a amostra de 1.200 observações foi pequena demais a fim de que se conseguisse estimar os coeficientes com precisão suficiente para que se pudesse extrair uma regra de negociação otimizada (ainda mais considerando a presença de colinearidade em função da própria forma como as variáveis são construídas e pelo uso intensivo de formas quadráticas no modelo econométrico). A falta de significância estatística de vários regressores corrobora essa hipótese. Outra explicação possível é a de que como a estratégia já funciona muito bem mesmo com implementações

---

59 Só foram feitas 1.200 simulações para o caso estadunidense (em comparação às 10.000 simulações do caso brasileiro) porque o tempo médio de processamento das simulações no mercado estadunidense é muito superior ao do caso brasileiro de modo que, considerando o prazo para finalizar o trabalho, não foi possível gerar um número maior de simulações para o caso americano.

aleatórias, haveria pouco espaço para que um Algoritmo de Otimização da Estratégia pudesse surtir efeito.

### 5.2.2. Sem Custos de Transação

A Tabela 18 apresenta os coeficientes estimados dos parâmetros de implementação da estratégia de investimento em desempenho contrário em um contexto de inexistência de custos de transação. Inicialmente percebe-se que, assim como ocorreu no caso brasileiro, a retirada dos custos de transação fez o  $R^2$  ajustado aumentar. No caso americano, o aumento foi de 33,75 pontos percentuais. Essa variação foi menor do que o impacto observado no caso brasileiro, o que indica que os custos de transação no mercado americano são menos relevantes na determinação do *Information Ratio* do que no Brasil (provavelmente porque os custos no Brasil são maiores).

*Tabela 18: MQO Heterocedasticidade Corrigida, EUA (sem custos de transação). Variável dependente: information\_ratio\_anualizado*

	<i>Coeficiente</i>	<i>Erro Padrão</i>	<i>estatística t</i>	<i>p-valor</i>	<i>sig.</i>
const	1,25906	0,0316241	39,81	<0,0001	***
Alfa	-0,0453189	0,0127572	-3,552	0,0004	***
Sharpe	-0,0756914	0,0127939	-5,916	<0,0001	***
PF	-0,000504382	5,28995e-05	-9,535	<0,0001	***
PF2	3,34847e-07	3,24977e-08	10,30	<0,0001	***
PM	-0,000246540	2,68777e-05	-9,173	<0,0001	***
PM2	3,31200e-08	8,46283e-09	3,914	<0,0001	***
Q	0,522457	0,162649	3,212	0,0014	***
Q2	-0,915300	0,295469	-3,098	0,0020	***
M	-0,253401	0,0201773	-12,56	<0,0001	***
Ms	-0,197212	0,0194027	-10,16	<0,0001	***
TA	-0,000282709	6,65998e-05	-4,245	<0,0001	***
TA2	2,01367e-07	5,23584e-08	3,846	0,0001	***
PR	-2,03275e-05	2,75425e-05	-0,7380	0,4606	
PR2	2,72895e-09	1,07252e-08	0,2544	0,7992	

Estadísticas baseadas nos dados ponderados:

Soma resíd. quadrados	4135,900	E.P. da regressão	1,868211
R-quadrado	0,612664	R-quadrado ajustado	0,608087
F(14, 1185)	133,8826	P-valor(F)	2,9e-232
Log da verossimilhança	-2445,156	Crítério de Akaike	4920,312
Crítério de Schwarz	4996,664	Crítério Hannan-Quinn	4949,073

Estatísticas baseadas nos dados originais:

Média var. dependente	0,673379	D.P. var. dependente	0,286560
Soma resíd. quadrados	46,53301	E.P. da regressão	0,198162

Fonte: resultado gerado pelo *software* Gretl, com adaptações.

Os parâmetros ótimos, definidos seguindo a mesma metodologia já apresentada nas seções 5.1.1, 5.1.2 e 5.2.1, encontra-se na Tabela 19.

*Tabela 19: Parâmetros Ótimos, MQO Heterocedasticidade Corrigida, EUA (sem custos de transação)*

<i>CF</i>	<i>Ret</i>
<i>PF</i>	1512 dias
<i>PM</i>	3024 dias
<i>Q</i>	0,28
<i>DP</i>	<i>Ig</i>
<i>TA</i>	1512 dias
<i>PR</i>	3024 dias

Fonte: elaboração própria.

Os resultados da aplicação dos parâmetros da Tabela 19 estão demonstrados na Tabela 20 e na Figura 4.

*Tabela 20: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (com custos de transação)*

data_inicio_simulacao	2013-05-09
data_fim_simulacao	2021-03-19
numero_medio_ativos_simulacao	31100,00%
custo_transacao_medio_anualizado_simulacao	0,00
information_ratio_anualizado_simulacao	-23,37%
retorno_medio_anualizado_simulacao	8,71%
retorno_medio_anualizado_benchmark	11,16%

sharpe_anualizado_simulacao	0,46
sharpe_anualizado_benchmark	0,60
alfa_jensen_anualizado_simulacao	-0,70%
pvalor_alfa_simulacao	82,75%
beta_simulacao	0,85
pvalor_beta_simulacao	0,00
desvio_padrao_anualizado_simulacao	17,11%
desvio_padrao_anualizado_benchmark	16,99%
valor_drawdown_maximo_simulacao	36,00%
valor_drawdown_maximo_benchmark	34,00%
data_pico_drawdown_maximo_simulacao	2018-01-23
data_vale_drawdown_maximo_simulacao	2020-03-18
data_pico_drawdown_maximo_benchmark	2020-02-19
data_vale_drawdown_maximo_benchmark	2020-03-23

Fonte: elaboração própria.




Figura 4: Resultado de Simulação Fora da Amostra, Parâmetros Otimizados, EUA (sem custos de transação)

Fonte: elaboração própria.

Mais uma vez os resultados contradizem o que foi observado no caso brasileiro. O Algoritmo de Simulações gerou uma regra de negociação que não apenas desempenhou pior que a média das implementações aleatórias, mas gerou uma simulação com *Information Ratio* negativo.

### 5.2.3. Conclusão Estados Unidos

Os resultados para o caso estadunidense não parecem ser consistentes. O fato de o *Information Ratio* médio em implementações aleatórias ser um número positivo e elevado (28%) é um indício de que talvez a amostra gerada tenha sido muito pequena. Essa constatação é corroborada pela análise dos fracos desempenhos fora da amostra dos parâmetros ótimos estimados (tanto em um cenário com quanto sem custos de transação), efeito contrário do que aconteceu no caso brasileiro. Trata-se, então, de resultados inconclusivos. A solução é aumentar o número de observações na amostra para o caso americano para que ele chegue (ou ao menos se aproxime) das 10.000 observações feitas para o caso brasileiro. Esse aumento do número de observações, no entanto, demanda um tempo de processamento computacional de semanas.

### 5.3. **Conclusão Geral do Trabalho**

A pergunta que o presente trabalho se propôs a responder foi: é possível, e vale a pena, desenvolver e implementar um Algoritmo de Otimização da Estratégia de Investimento em Desempenho Contrário com o objetivo de maximizar o *Information Ratio* de um portfólio? E a resposta é: não vale a pena fazer essa otimização caso a estimação dos coeficientes dos parâmetros de implementação da estratégia seja realizada por um modelo linear. No caso brasileiro, o Algoritmo de Otimização objeto do presente estudo até se mostrou capaz de melhorar significativamente o desempenho da estratégia (considerando o aumento do *Information Ratio* da simulação fora da amostra em comparação ao *Information Ratio* médio das 10.000 simulações dentro da amostra), o que é um indício de que o método de otimização em si é de certo modo eficaz. Isso faz sentido considerando que foi empregado o método dos Mínimos Quadrados Ordinários e que todos os pressupostos para que ele seja o melhor estimador linear não viesado estavam presentes. No entanto, o Algoritmo de Otimização não se mostrou eficaz o suficiente para compensar a inerente inadequação da estratégia de investimento em desempenho contrário em gerar *Information Ratio* positivo. Por outro lado, é possível que modelos não lineares ou modelos mais sofisticados de *Machine Learning* tenham mais sucesso nessa otimização. Pode ser interessante também verificar como o Algoritmo de



Otimização apresentado nesta dissertação desempenha ao tentar otimizar outras estratégias de investimento, como, por exemplo, a estratégia *momentum*.

Com relação ao caso estadunidense, os resultados alcançados pelo presente estudo parecem ser inconsistentes, e, portanto, o mais prudente é entendê-los como sendo inconclusivos até que se refaça a análise com um número maior de observações na amostra. Por fim, a técnica de estimação dos custos de transação empregada no presente trabalho talvez mereça uma agenda de pesquisa específica para que se possa investigar, por exemplo, quais mudanças institucionais e tecnológicas estão correlacionadas com a queda nos custos de transação, por que os custos de transação aumentam em períodos de crise sistêmica, as diferenças de custos de transação entre diferentes países e se o modelo proposto por Lesmond (1999) pode ser aperfeiçoado à luz de modelos de precificação multifatoriais.

## 6. BIBLIOGRAFIA

ANTONIOU, Antonios; GALARIOTIS, Emilios C.; SPYROU, Spyros I. Are contrarian investment strategies profitable in the London Stock Exchange? Where do these profits come from?. Available at SSRN 391570, 2003.

ANTONIOU, Antonios; GALARIOTIS, Emilios C.; SPYROU, Spyros I. Short-term Contrarian Strategies in the London Stock Exchange: Are They Profitable? Which Factors Affect Them?. *Journal of Business Finance & Accounting*, v. 33, n. 5-6, p. 839-867, 2006.

ASSOE, Kodjovi; SY, Oumar. Profitability of the short-run contrarian strategy in canadian stock markets. *Canadian Journal of Administrative Sciences/Revue Canadienne des Sciences de l'Administration*, v. 20, n. 4, p. 311-319, 2003.

BALL, Ray; KOTHARI, S. P.; SHANKEN, Jay. Problems in measuring portfolio performance An application to contrarian investment strategies. *Journal of Financial economics*, v. 38, n. 1, p. 79-107, 1995.

CHAN, K. C. On the contrarian investment strategy. *Journal of business*, p. 147-163, 1988.

CHANG, Rosita P.; MCLEAVEY, D. W.; RHEE, S. Ghon. Short-term abnormal returns of the contrarian strategy in the Japanese stock market. *Journal of Business Finance & Accounting*, v. 22, n. 7, p. 1035-1048, 1995.

CLEMENTS, Adam et al. The death of the overreaction anomaly? A multifactor explanation of contrarian returns. *Investment Management and Financial Innovations*, v. 6, n. 1, p. 76-85, 2009.

DA COSTA JR, Newton CA. Overreaction in the Brazilian stock market. *Journal of banking & finance*, v. 18, n. 4, p. 633-642, 1994.

DAMODARAN, Aswath. Value investing: investing for grown ups?. Available at SSRN 2042657, 2012.

DE BONDT, Werner FM; THALER, Richard H. Further evidence on investor overreaction and stock market seasonality. *The Journal of finance*, v. 42, n. 3, p. 557-581, 1987.

DE BONDT, Werner FM; THALER, Richard. Does the stock market overreact?. *The Journal of finance*, v. 40, n. 3, p. 793-805, 1985.

DE OLIVEIRA FILHO, Bolivar Godinho; DE SOUSA, Almir Ferreira. Fundos de investimento em ações no Brasil: métricas para avaliação de desempenho. *REGE-Revista de Gestão*, v. 22, n. 1, p. 61-76, 2015.

DEMIGUEL, Victor; GARLAPPI, Lorenzo; UPPAL, Raman. Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy?. *The review of Financial studies*, v. 22, n. 5, p. 1915-1953, 2009.

FAMA, Eugene F. et al. Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, v. 25, n. 2, p. 383-417, 1970.

FAMA, Eugene F.; FRENCH, Kenneth R. A five-factor asset pricing model. *Journal of financial economics*, v. 116, n. 1, p. 1-22, 2015.

FAMA, Eugene F.; FRENCH, Kenneth R. Common factors in the serial correlation of stock returns. 1986.

FAMA, Eugene F.; FRENCH, Kenneth R. Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, v. 33, p. 3-56, 1993.

FAMA, Eugene F.; FRENCH, Kenneth R. Multifactor Explanations of Asset Pricing Anomalies. *Journal of Finance*, p. 55-84, 1996.

FORNER, Carlos; MARHUENDA, Joaquín. Contrarian and momentum strategies in the Spanish stock market. *European Financial Management*, v. 9, n. 1, p. 67-88, 2003.

GOODWIN, Thomas H. The information ratio. *Financial Analysts Journal*, v. 54, n. 4, p. 34-43, 1998.

GOTTESMAN, Aron A.; JACOBY, Gady; LI, Huijing. Value investing or investing in illiquidity? The profitability of contrarian investment strategies, revisited. *Financial Innovation*, v. 3, n. 1, p. 1-12, 2017.

GRINOLD, Richard C.; KAHN, Ronald N. *Advances in Active Portfolio Management: New Developments in Quantitative Investing*. McGraw Hill Professional, 2019.

GUJARATI, Damodar N.; PORTER, Dawn C. *Econometria básica-5*. Amgh Editora, 2011.

HANSEN, Kristian Bondo. Contrarian investment philosophy in the American stock market: on investment advice and the crowd conundrum. *Economy and Society*, v. 44, n. 4, p. 616-638, 2015.

HANSEN, Kristian Bondo. Contrarian investment philosophy in the American stock market: on investment advice and the crowd conundrum. *Economy and Society*, v. 44, n. 4, p. 616-638, 2015.

JENSEN, Michael C. The performance of mutual funds in the period 1945-1964. *The Journal of finance*, v. 23, n. 2, p. 389-416, 1968.

KANG, Joseph; LIU, Ming-Hua; NI, Sophie Xiaoyan. Contrarian and momentum strategies in the China stock market: 1993–2000. *Pacific-Basin Finance Journal*, v. 10, n. 3, p. 243-265, 2002.

KRYZANOWSKI, Lawrence; ZHANG, Hao. The contrarian investment strategy does not work in Canadian markets. *Journal of Financial and Quantitative Analysis*, p. 383-395, 1992.

LAKONISHOK, Josef; SHLEIFER, Andrei; VISHNY, Robert W. Contrarian investment, extrapolation, and risk. *The journal of finance*, v. 49, n. 5, p. 1541-1578, 1994.

LEDOIT, Olivier; WOLF, Michael. A well-conditioned estimator for large-dimensional covariance matrices. *Journal of multivariate analysis*, v. 88, n. 2, p. 365-411, 2004a.

LEDOIT, Olivier; WOLF, Michael. Honey, I shrunk the sample covariance matrix. *The Journal of Portfolio Management*, v. 30, n. 4, p. 110-119, 2004b.

LEE, Darren D. et al. Short-term contrarian investing—is it profitable?... Yes and No. *Journal of Multinational Financial Management*, v. 13, n. 4-5, p. 385-404, 2003.

LEMOS, Marcelo de Oliveira; DA COSTA JÚNIOR, Newton CA. O efeito de sobre-reação a curto prazo no mercado de capitais brasileiro. *Relatórios COPPEAD*, 1996.

LESMOND, David A.; OGDEN, Joseph P.; TRZCINKA, Charles A. A new estimate of transaction costs. *The review of financial studies*, v. 12, n. 5, p. 1113-1141, 1999.

LINTNER, John. THE VALUATION OF RISK ASSETS AND THE SELECTION OF RISKY INVESTMENTS IN STOCK PORTFOLIOS AND CAPITAL BUDGETS. *The Review of Economics and Statistics*, v. 47, n. 1, p. 13-37, 1965.

LO, Andrew W. The statistics of Sharpe ratios. *Financial analysts journal*, v. 58, n. 4, p. 36-52, 2002.

LO, Andrew W.; MACKINLAY, A. Craig. When are contrarian profits due to stock market overreaction?. *The review of financial studies*, v. 3, n. 2, p. 175-205, 1990.

MARKOWITZ, Harry. Portfolio Selection, *Journal of Finance*. Markowitz HM—1952.—№, p. 77-91, 1952.

PARHIZGARI, Ai M.; NGUYEN, D. ADRs under momentum and contrarian strategies. *Global Finance Journal*, v. 19, n. 2, p. 102-122, 2008.

RAMIAH, Vikash et al. Contrarian investment strategies work better for dually-traded stocks: Evidence from Hong Kong. *Pacific-Basin Finance Journal*, v. 19, n. 1, p. 140-156, 2011.

SATURNINO, Odilon et al. investimento em desempenho contrário no Brasil: Overreaction ou efeito tamanho?. 2011.

SCHIERECK, Dirk; DE BONDT, Werner; WEBER, Martin. Contrarian and momentum strategies in Germany. *Financial Analysts Journal*, v. 55, n. 6, p. 104-116, 1999.

SEHGAL, Sanjay; BALAKRISHNAN, I. Contrarian and momentum strategies in the Indian capital market. *Vikalpa*, v. 27, n. 1, p. 13-20, 2002.

SHARPE, William F. Capital asset prices: A theory of market equilibrium under conditions of risk. *The journal of finance*, v. 19, n. 3, p. 425-442, 1964.

SHARPE, William F. Mutual fund performance. *The Journal of business*, v. 39, n. 1, p. 119-138, 1966.

SHARPE, William F. The Sharpe Ratio. *Journal of Portfolio Management*. Stanford University, Fall, 1994.

STATMAN, Meir. How many stocks make a diversified portfolio?. *Journal of financial and quantitative analysis*, p. 353-363, 1987.