



Universidade de Brasília (UnB)

Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas

(FACE)

Departamento de Ciências Contábeis e Atuariais (CCA)

Programa de Pós-Graduação em Ciências Contábeis (PPGCont)

BIANCA GABRIEL FELLET

**EVIDÊNCIAS EMPÍRICAS SOBRE MODELOS DE PRECIFICAÇÃO DE ATIVOS
APLICADOS AO MERCADO ACIONÁRIO BRASILEIRO EM PERÍODOS DE
CRISE**

Brasília/DF

2024

Professora Doutora Márcia Abrahão Moura
Reitora da Universidade de Brasília

Professor Doutor Enrique Huelva Unternbäumen
Vice-Reitor da Universidade de Brasília

Professor Doutor Lucio Remuzat Rennó Junior
Decano de Pós-Graduação

Professor Doutor José Márcio Carvalho
**Diretor da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas
Públicas**

Professor Doutor Sérgio Ricardo Miranda Nazaré
Chefe do Departamento de Ciências Contábeis e Atuariais

Professor Doutor Jomar Miranda Rodrigues
Coordenador do Programa de Pós-Graduação em Ciências Contábeis

BIANCA GABRIEL FELLET

**EVIDÊNCIAS EMPÍRICAS SOBRE MODELOS DE PRECIFICAÇÃO DE ATIVOS
APLICADOS AO MERCADO ACIONÁRIO BRASILEIRO EM PERÍODOS DE
CRISE**

Tese submetida ao Programa de Pós-Graduação em Ciências Contábeis do Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília, como requisito para a obtenção do título de Doutora em Ciências Contábeis.

Orientador: Prof. Otávio Ribeiro de Medeiros, PhD.

Linha de Pesquisa: Contabilidade e Mercado Financeiro.

Brasília/DF

2024

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

Ge GABRIEL FELLET, BIANCA
EVIDÊNCIAS EMPÍRICAS SOBRE MODELOS DE PRECIFICAÇÃO DE
ATIVOS APLICADOS AO MERCADO ACIONÁRIO BRASILEIRO EM PERÍODOS
DE CRISE / BIANCA GABRIEL FELLET; orientador OTÁVIO RIBEIRO
DE MEDEIROS. -- Brasília, 2023.
130 p.

Tese(Doutorado em Ciências Contábeis) -- Universidade de
Brasília, 2023.

1. Precificação de ativos. 2. Modelo de 5 Fatores. 3.
Arbitrage Price Theory ; 4. Dynamic Model Averaging . I.
RIBEIRO DE MEDEIROS, OTÁVIO, orient. II. Título.

BIANCA GABRIEL FELLET

**EVIDÊNCIAS EMPÍRICAS SOBRE MODELOS DE PRECIFICAÇÃO DE ATIVOS
APLICADOS AO MERCADO ACIONÁRIO BRASILEIRO EM PERÍODOS DE
CRISE**

Tese submetida ao Programa de Pós-Graduação em Ciências Contábeis do Departamento de Ciências Contábeis e Atuariais da Faculdade de Economia, Administração, Contabilidade e Gestão de Políticas Públicas da Universidade de Brasília, como requisito para a obtenção do título de Doutora em Ciências Contábeis.

BANCA EXAMINADORA

Prof. Dr. Otávio Ribeiro de Medeiros
Universidade de Brasília – UnB
Orientador

Prof. Dr. Bruno Vinicius Ramos Fernandes
Universidade de Brasília – UnB
Membro Interno

Prof. Dr. Wilson Toshiro Nakamura
Universidade Presbiteriana Mackenzie
Membro Externo

Prof. Dr. Luiz Eduardo Brandão
Pontifícia Universidade Católica do Rio de Janeiro
Membro Externo

Prof. Dr. José Alves Dantas
Universidade de Brasília-UnB
Suplente

Brasília/DF, 22 de fevereiro de 2024.

Dedico este trabalho à minha mãe (*in
memorian*).

AGRADECIMENTOS

Primeiramente, agradeço a Deus por me orientar em momentos de dificuldades e me permitir chegar até aqui, apesar de todas as situações delicadas durante os últimos anos.

Dedico meus principais agradecimentos as mulheres que uso como inspiração em minha vida pessoal e profissional; infelizmente ambas não se encontram mais entre nós, mas foram essenciais para o meu crescimento: minha querida mãe, Suely e minha avó, Rosa.

Agradeço também ao meu pai, Renato e a minha filha Luiza, por proporcionarem tanto amor e apoio incondicional durante minha jornada árdua em pesquisas e estudos.

Ao meu marido, Cássio que tive a sorte de encontrar durante a minha caminhada pela Universidade e que nunca mediu esforços para me apoiar em todos os projetos.

Aos mestres que me garantiram tanto conhecimento e contribuíram imensamente aos meus resultados, em especial, meu orientador, Prof. Dr. Otávio Ribeiro de Medeiros. Em reconhecimento aos professores do programa de doutorado-UNB, Prof. Dr. Rodrigo Gonçalves, Profa. Dr. Andrea Gonçalves, Prof. Dr. Jomar Miranda Rodrigues, Prof. Dr. João Bilhim, Prof. Dr. André Serrano, Prof. Dr. Paulo Brito, Prof. Dr. César Tibúrcio, Profa. Dr. Fátima Freire, Prof. Dr. Paulo Lustosa, Prof. Dr. José Matias, Prof. Dr. Jorge Katsumi Niyama, Prof. Dr. Bruno Vinícius Ramos Fernandes e Prof. Dr. Marcelo Scherer Perlin.

“O período de maior ganho em conhecimento e experiência é o período mais difícil da vida de alguém.”

(Dalai Lama)

RESUMO

Esta pesquisa teve como objetivo avaliar a capacidade explicativa e preditiva de dois modelos de precificação de ativos, já consolidados na literatura acadêmica. Sendo eles: o *Arbitrage Price Theory* de Ross (1970) e o Modelo de 5 Fatores de Fama & French (2015), através de sua aplicação no mercado acionário brasileiro em períodos de crise. A amostra da pesquisa foi composta por todas as empresas com ações negociadas na “Brasil, Bolsa, Balcão” (B3), durante o período de 2007 a 2021. Foram excluídos os ativos de empresas do setor financeiro, e a amostra foi dividida em três subperíodos, de modo a englobar :a crise de 2008, a crise política de 2016 e a crise gerada pela Covid-19. A capacidade explicativa foi testada através de regressões *Seemingly Unrelated Regressions With Identical Regressors* (SUR). Já a avaliação da capacidade preditiva dos modelos de precificação, foi conduzida empregando o método *Dynamic Model Averaging* (DMA). São apresentados os resultados da análise empírica, incluindo a capacidade explicativa e preditiva e testes de robustez. A pesquisa contribui para a compreensão da precificação de ativos em momentos de crise, assim como a identificação de fatores com capacidade explicativa sobre o retorno acionário no mercado de capitais brasileiro. O estudo se mostra útil para pesquisadores, investidores e gestores de fundos na tomada de decisões de investimento ao identificar fatores correlacionados com o retorno acionário brasileiro. Os resultados indicam que os modelos de precificação de ativos APT e Modelo de 5 Fatores apresentam boa capacidade de explicativa sobre o retorno acionário em todos os períodos definidos como subamostras. Entretanto, no que tange a capacidade preditiva, ainda há espaço para o desenvolvimento de novos modelos e a utilização de novas metodologias, já que o DMA não se mostrou eficiente na realização de previsões com a utilização dos fatores do APT e do modelo de 5 fatores.

Palavras-chave: Precificação de ativos. Modelo de 5 Fatores. APT. DMA. Crises financeiras. Retorno acionário. Mercado acionário brasileiro.

ABSTRACT

This research is aimed at evaluating the explaining and predicting power of two asset pricing models, already consolidated in academic literature. The models were the Arbitrage Pricing Theory of Ross (1970) and the Fama-French 5-Factor Model (2015), by means their application in the Brazilian stock market in periods of crisis. The research sample was composed of all companies with shares traded on “Brasil, Bolsa, Balcão” (B3), during the period from 2007 to 2021. Assets of companies in the financial sector were excluded, and the sample was divided into three sub-periods, covering the 2008 world crisis, the 2016 Brazilian political crisis, and the crisis related to the Covid-19 pandemics, respectively. The explanatory power of both aforementioned models were tested using Seemingly Unrelated Regressions with Identical Regressors (SUR). The assessment of the predictive power of such pricing models were performed using the Dynamic Model Averaging (DMA) method. The results of the empirical analysis, including explanatory and predictive power and robustness tests are performed and presented. The research contributes to the understanding of asset pricing in times of crisis, as well as the identification of factors with explanatory power of stock returns in the Brazilian stock market. It is expected that the study proves to be useful to researchers, investors and fund managers when making investment decisions by identifying factors correlated with Brazilian stock returns. The results indicate that the asset pricing models APT and 5-Factor Model have good explanatory power for stock returns in all periods defined as subsamples. However, in terms of predictive power, there is still room for the development of new models and the use of new methods, as the DMA has not been able to prove itself efficient in making predictions using either the APT or the 5-factor model.

Keywords: Asset pricing. 5-Factor Model. APT. DMA. Financial crises. stock returns. Brazilian stock market.

LISTA DE QUADROS

Quadro 1 – Estudos precursores sobre a relação entre o Retorno das Ações e Outras Variáveis	37
Quadro 2 - Pesquisas com modelos de precificação de ativos multifatoriais	37
Quadro 3 – Estudos utilizando o Modelo de 5 fatores	42
Quadro 4 – Estudos recentes com a aplicação do DMA em diversas áreas do conhecimento	45
Quadro 5 – Aplicação do DMA com a utilização de dados econômicos e financeiros	47
Quadro 6 – Variáveis a serem incluídas no modelo APT	58

LISTA DE TABELAS

Tabela 1 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2007 à 2011	72
Tabela 2 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2007 à 2011 com a variável <i>dummy</i>	72
Tabela 3 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2012 à 2016.....	73
Tabela 4 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2012 à 2016 com a variável <i>dummy</i>	74
Tabela 5 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2017 à 2021	75
Tabela 6 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2017 à 2021 com a variável <i>dummy</i>	75
Tabela 7 - Resumo dos resultados estatísticos do modelo APT durante o período de 2007 à 2011	77
Tabela 8 - Resumo dos resultados estatísticos do modelo APT durante o período de 2007 à 2011 com a variável <i>dummy</i>	78
Tabela 9 - Resumo dos resultados estatísticos do modelo APT durante o período de 20012 à 2016.....	79
Tabela 10 - Resumo dos resultados estatísticos do modelo APT durante o período de 2012 à 2016 com a variável <i>dummy</i>	80
Tabela 11 - Resumo dos resultados estatísticos do modelo APT durante o período de 2017 à 2021.....	81
Tabela 12 - Resumo dos resultados estatísticos do modelo APT durante o período de 2017 à 2021 com a variável <i>dummy</i>	82
Tabela 13 - Resultado dos testes de raiz unitária.....	83
Tabela 14 - Resultado dos testes de Durbin-Watson	84
Tabela 15 – Resultados dos testes de Breusch-Pagan.....	85
Tabela 16 - Resultados dos testes do fator de inflação da variância (VIF) do 1º período da amostra	86
Tabela 17 – Resultados dos testes do Fator de inflação da variância (VIF) DO 1º período da amostra	86
Tabela 18 – Resultados dos testes do fator de inflação da variância (VIF) do 2º período da amostra	87
Tabela 19 – Resultados dos testes do fator de inflação da variância (VIF) do 2º período da amostra	88

Tabela 20 –Resultados dos testes do fator de inflação da variância (VIF) do 3º período da amostra.....	88
Tabela 21 –Resultados dos testes do fator de inflação da variância (VIF) do 3º período da amostra.....	89
Tabela 22– Resultados dos testes de normalidade dos resíduos.....	90
Tabela 23 –Resultados das projeções com o modelo de 5 fatores no 1º período da amostra..	91
Tabela 24 –Resultados das projeções com o modelo de 5 fatores no 2º período da amostra..	92
Tabela 25 –Resultados das projeções com o modelo de 5 fatores no 3º período da amostra..	93
Tabela 27 –Resultados das projeções com o modelo APT no 2º período da amostra.....	95
Tabela 28 –Resultados das projeções com o modelo APT no 3º período da amostra.....	96
Tabela 29 - Resultados do RMSE.....	97

LISTA DE ABREVIATURAS E SIGLAS

APT	- <i>Arbitrage Price Theory</i>
B3	- Brasil, Bolsa, Balcão
BCB	- Banco Central do Brasil
BCE	- Banco Central Europeu
CAPM	- <i>Capital Asset Pricing Model</i>
CDI	- Certificado de Depósito Interbancário
CMA	- <i>Conservative Minus Agressive</i>
CVM	- Comissão de Valores Mobiliários
DMA	- <i>Dynamic Model Averaging</i>
EUA	- Estados Unidos da América
FED	- <i>Federal Reserve</i> (Sistema de Reserva Federal)
HML	- <i>High Minus Low</i>
HMLO	- <i>HML Ortogonal</i>
IBOVESPA	- Índice Bovespa
NYSE	- <i>New York Stock Exchange</i>
OCDE	- Organização para a Cooperação e Desenvolvimento Econômico
OIT	- Organização Internacional do Trabalho
OMS	- Organização Mundial da Saúde
PIB	- Produto Interno Bruto
PL	- Patrimônio Líquido
RMSE	- <i>Root Mean-Square Error</i>
RMW	- <i>Robust Minus Weak</i>
SMB	- <i>Small Minus Big</i>
SUR	- <i>Seemingly Unrelated Regressions With Identical Regressors</i>
TVPs	- Parâmetros Variáveis no Tempo
VIF	- Fator de Inflação da Variância
VM	- Valor de Mercado

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 CENÁRIOS DE CRISE.....	18
1.1.1 A crise do <i>Subprime</i>.....	18
1.1.2 A crise político-econômica de 2014-2016.....	20
1.1.3 A crise causada pelo Coronavírus	21
1.2 PROBLEMA DE PESQUISA.....	23
1.3 OBJETIVOS	24
1.3.1 Objetivo geral.....	24
1.3.2 Objetivos Específicos	24
1.4 JUSTIFICATIVA.....	25
1.5 LIMITAÇÕES DO ESTUDO	26
1.6 ESTRUTURA APRESENTADA.....	26
2 REFERENCIAL TEÓRICO	28
2.1 A EVOLUÇÃO DA TEORIA DE FINANÇAS	28
2.1.1 A moderna teoria de finanças	28
2.1.2 Finanças comportamentais	30
2.1.3 Análise fundamentalista	31
2.2 O MERCADO ACIONÁRIO E A HIPÓTESE DE EFICIÊNCIA DE MERCADO.....	32
2.3 A TEORIA DO PORTIFÓLIO E OS MODELOS DE PRECIFICAÇÃO DE ATIVOS	33
2.3.1 Capital Asset Pricing Model (CAPM)	35
2.3.2 Arbitrage Price Model (APT)	38
2.3.3 Modelo de 5 fatores	39
2.4 DMA.....	43
3 METODOLOGIA	50
3.1 FONTE DE DADOS E AMOSTRA	50
3.2 FORMAÇÃO DE CARTEIRAS.....	51
3.3 TRATAMENTO ECONOMETRICO.....	52
3.4 ESPECIFICAÇÃO DOS MODELOS A SEREM UTILIZADOS.....	53
3.4.1 O Modelo de 5 fatores de Fama e French (2016)	53
3.4.2 APT.....	58
3.4.3 Quebra estrutural e teste de Quandt-Andrews.....	63
3.4.4 Estacionariedade das séries	63
3.4.5 Testes de robustez	64
3.5 DMA.....	67

3.5.1 Root Mean-Square Error (RMSE).....	69
4 RESULTADOS	71
4.1 RESULTADO DAS REGRESSÕES DO MODELO DE 5 FATORES	71
4.1.1 Desempenho do modelo de 5 fatores durante a Crise de 2008	72
4.1.2 Desempenho do modelo de 5 fatores durante a crise política (governo Dilma).....	73
4.1.3 Desempenho do modelo de 5 fatores durante a crise da Covid-19.....	74
4.2 RESULTADO DAS REGRESSÕES DO MODELO APT	76
4.2.1 Desempenho do modelo APT durante a crise de 2008.....	76
4.2.2 Desempenho do modelo APT durante a Crise política	78
4.2.3 Desempenho do modelo APT durante a pandemia da Covid-19.....	80
4.3 RESULTADOS DOS TESTES DE ROBUSTEZ.....	83
4.3.1 Testes de raiz unitária.....	83
4.3.2 Testes de autocorrelação dos resíduos e heterocedasticidade.....	84
4.3.3 Teste de Multicolinearidade	85
4.3.3 Teste de Normalidade dos resíduos	89
4.4 RESULTADOS DAS PROJEÇÕES DO DMA.....	90
4.4.1 RMSE	97
5 CONSIDERAÇÕES FINAIS.....	99
6 REFERÊNCIAS.....	103
APÊNDICE	112
APÊNDICE A – EMPRESAS QUE FAZEM PARTE DA AMOSTRA NO PERÍODO DE 2007 À 2021.....	112
APÊNDICE B – TESTES DE QUEBRA ESTRUTURAL.....	122
APÊNDICE C – TESTES DE RAÍZ UNITÁRIA.....	123
APÊNDICE D – RESULTADOS DAS REGRESSÕES	126

1 INTRODUÇÃO

A evolução no modo de fazer investimentos no Brasil pode ser observada por meio da ampliação de plataformas digitais de investimentos, do aumento na oferta de produtos financeiros e da melhoria da educação financeira. Ressalta-se que os últimos anos propiciaram um crescimento exponencial no número de brasileiros que começaram a investir em valores mobiliários (Jegadeesh & Mangipudi, 2021; Nascimento, 2019; Silva, Assis, & Oliveira, 2020; Vargas & Santos, 2020).

Uma parcela relevante de investidores já possui acesso a investimentos mais sofisticados, como operações no mercado acionário em alta frequência (*day trade*), inclusive mediante a utilização de robôs, moedas digitais, derivativos e investimentos no exterior. No entanto, esse ainda é um percentual baixo se comparado a outros mercados mais desenvolvidos pelo mundo (Comissão de Valores Mobiliários [CVM], 2021).

As informações no mercado financeiro alastram-se com rapidez e em grande quantidade. Isso é consequência das reduções dramáticas no custo computacional e de comunicações, o que permite aos participantes desse mercado acesso a grandes quantidades de informações oportunas a um custo praticamente irrisório. Diante disso, a formação do preço dos ativos torna-se assunto recorrente. Verifica-se, dessa forma, que investidores e analistas de mercado buscam constantemente informações sobre os títulos negociados, com o objetivo de formar carteiras adequadas ao retorno esperado e ao risco incorrido. Diante disso, faz-se necessário compreender como os preços dos ativos são formados e se podem ser previstos com certo grau de confiabilidade.

Observa-se que o processo de tomada de decisão com relação à compra e à venda de ações no mercado de capitais brasileiro é realizado, muitas vezes, com base em dados contábeis, informações e incertezas sobre o mercado financeiro, desempenho econômico de empresas, alterações na legislação e no cenário político-econômico (Assaf, Lima, & Araújo, 2008; Batista, Oliveira, & Macedo, 2017; Dantas, Medeiros, & Lustosa, 2006; Galdi & Lopes, 2008; Quinteiro, Medeiros, & Niyama, 2020; Machado & Medeiros, 2012; Sarlo, Lopes, & Dalmácio, 2010; Silva & Medeiros, 2019).

Com isso, identificar um método que estabeleça uma relação adequada entre risco e retorno consiste em um dos maiores problemas que a teoria de finanças enfrenta. Observa-se que diferentes modelos foram concebidos para examinar essa relação, mas não há, ainda, consenso sobre determinado modelo ou metodologia que os valide. É importante mencionar que o mais popular desses modelos é o *Capital Asset Pricing Model* (CAPM), que foi

apresentado por Sharpe (1964) e Lintner (1965), e desenvolvido com base na teoria das carteiras, de Markowitz (1952).

Segundo Sharpe (1964), existem dois tipos de riscos. O primeiro, denominado de risco sistemático, diz respeito àquele que afeta todo o sistema econômico, sendo responsivo aos riscos totais da combinação de investimentos, não podendo ser mitigado mediante a diversificação dos investimentos. Esse tipo de risco é provocado por fatores externos e fora de controle das empresas, embora estas sejam afetadas em diferentes níveis.

O segundo é chamado de risco idiossincrático (assistemático) e refere-se à parcela de risco incorrido, que faz referência apenas à determinada ação decorrente, por exemplo, de decisões tomadas pela própria administração, tais como: política financeira, estratégias de investimento, atuação e operacionais, estrutura de capital, dentre outras. O risco assistemático pode ser reduzido significativamente por meio de uma estratégia de diversificação. Contudo, nunca poderá ser totalmente eliminado, independentemente de quantos tipos de ativos sejam agregados em um portfólio, pois os retornos sobre diferentes ativos estão correlacionados em pelo menos algum grau.

O CAPM trata o risco idiossincrático como irrelevante, uma vez que este pode ser eliminado mediante um portfólio bem diversificado. No entanto, desde a década de 1970, foram formulados vários modelos de precificação de ativos na literatura que o levam em conta. Esses modelos partem da premissa de que os agentes do mercado, por algum motivo, não possuem carteiras perfeitamente diversificadas. Em função disso, são introduzidos novos fatores, como variáveis adicionais, dos mais diversos tipos no intuito de explicar o retorno acionário (Levy, 1978; Malkiel & Xu, 2002; Merton, 1987; Roll, 1977).

Muitos estudos foram elaborados, e outros continuam sendo feitos, para testar a capacidade do CAPM em explicar completamente a relação entre o retorno esperado e o risco. Especialmente os estudos mais antigos apoiaram as implicações do modelo CAPM e corroboraram a existência de uma relação linear entre o retorno esperado de uma carteira e o risco sistemático medido pelo beta (Fama & Macbeth, 1973; Jensen, Black, & Scholes, 1972; Sharpe & Cooper, 1972; Strong & Xu, 1997).

Desde os anos 1970, o uso de modelos multidimensionais tem sido ampliado, visto que problemas encontrados nos testes empíricos do CAPM não são explicados de forma contundente; tratam-se de possíveis ineficiências do mercado. Diante disso, discute-se a validade do modelo (Roll, 1977).

Em face às evidências documentadas ao longo dos anos sobre anomalias, uma abordagem é comumente usada em estudos de finanças para estudar tais variações nos retornos. Tanto em estudos norte-americanos, quanto em países emergentes, utilizam-se de modelos de precificação de ativos como método de testar a existência de padrões existentes nos retornos médios. Nesses modelos as anomalias são atribuídas a um prêmio que os investidores exigem pelo risco, relacionados a fatores (Ribeiro, Silva, Pires, & Souza, 2023, p.4).

Diversos estudos criticam, no teste empírico do modelo CAPM, o uso do beta como única medida de risco. Outros estudos, em contrapartida, adicionam outras variáveis explicativas dos mais diversos tipos. Além disso, podem ser encontrados, na literatura, estudos que rejeitam a existência de uma relação linear entre risco e retorno (Beaver, 1968; Bhandari, 1988; Carhart, 1997; Chan, Hamao, & Lakonishok, 1991; Chan & Marsh, 2021a; Fama & French, 1992, 1993, 2015; Jegadeesh, Noh, Pukthuanthong, Roll, & Junbo, 2019; Liu, 2006; Ross, 1976; Singh, Mehta, & Varsha, 2011; Stambaugh, Yu, & Yuan, 2012).

O custo do capital próprio em mercados desenvolvidos é frequentemente estimado por meio dos modelos de precificação, principalmente em função da taxa livre de risco, do valor beta e de uma estimativa do prêmio de risco médio, associado ao investimento em ações em relação aos ativos livres de risco, de acordo com a teoria amparada pelo CAPM.

Com relação a essa questão, verifica-se que mercados desenvolvidos são razoavelmente líquidos e eficientes. Em contraposição, a precificação em mercados emergentes, como o brasileiro, apresenta ainda mais desafios. Esses são frequentemente marcados por potenciais riscos adicionais, como riscos políticos e riscos associados à operação em mercados menos líquidos e transparentes que aqueles maduros.

Em períodos de incerteza econômica, a estimação do custo de capital é um componente-chave na tomada de decisões financeiras, pois é observado um aumento no risco sistemático. Por conseguinte, espera-se um aumento na volatilidade do preço dos ativos e mudanças estruturais, principalmente em mercados emergentes.

Isso deixa lacunas na literatura, como problemas na identificação de medidas apropriadas e confiáveis da taxa livre de risco e a possibilidade de adição de novas variáveis explicativas aos modelos, de modo a adaptá-los à realidade desses mercados.

Mais recentemente, artigos que abordam a estimativa de risco sistemático de forma dinâmica ganharam espaço na literatura, haja vista que a estrutura de correlação entre os fatores envolvidos nos modelos pode sofrer alterações ao longo do tempo, especialmente quando existem quebras estruturais na série temporal, decorrentes, por exemplo, de um período de crise

(Abdennadher & Hallara, 2018; Costa, Mazzeu, & Costa, 2016; Costa, Porto, & Menezes, 2018; Garcia & Bonomo, 2001; Nguyen & Bellalah, 2008; Silva, Pinto, Melo, & Camargos, 2009).

1.1 CENÁRIOS DE CRISE

O cenário econômico brasileiro apresentou sucessivas crises das mais diversas origens, como cambial, fiscal, de crédito, de oferta e demanda, além dos reflexos de crises políticas internas e de origem internacional.

De tempos em tempos, há eventos de crises financeiras relevantes, como o período de hiperinflação dos anos 1980 e início dos anos 1990, a desvalorização do Real, em 1999, a crise do *Subprime*, em 2008 (de origem externa), a crise político-econômica, em 2014, e a crise provocada pelo Coronavírus, em 2020. O presente estudo busca abordar as três últimas elencadas.

1.1.1 A crise do *Subprime*

A chamada crise do *Subprime*, em 2008, é considerada, por muitos, como a pior crise econômica desde a Grande Depressão – Crise de 1929. Foi desencadeada devido à uma bolha imobiliária nos Estados Unidos, gerando aumentos significativos nos valores imobiliários em detrimento da renda da população, que não conseguiu quitar seus compromissos financeiros.

Na década de 1990, houve uma grande expansão de crédito nos Estados Unidos, o que proporcionou uma prática comum no país, a da hipoteca. Esta é uma modalidade de crédito em que pessoas obtêm empréstimo bancário e colocam o imóvel como garantia, para o caso de não honrarem o pagamento. Dessa forma, a hipoteca oportunizou a valorização, alimentando ainda mais o mercado imobiliário.

Os bancos começaram a se preocupar menos em assegurar uma adequada qualificação financeira dos mutuários e mais em promover formas de gerar novos empréstimos. Os mutuantes hipotecários deram início a um número cada vez maior de novos empréstimos à habitação, muitos dos quais foram concedidos a pessoas com uma má classificação de crédito. Em 2005, as taxas básicas de juros nos Estados Unidos começam a subir, aumentando para 8,25%, em 2007, contra 4%, em 2004 (Kothari & Lester, 2012).

Em meados de 2007, começaram a aparecer os primeiros sinais do não cumprimento do pagamento de hipotecas por parte dos norte-americanos, principalmente em um segmento do mercado hipotecário denominado *Subprime*.

Nesse segmento são concedidos financiamentos imobiliários a pessoas com um menor nível de rendimento. Isso naturalmente caracteriza operações com risco de inadimplência superior aos financiamentos concedidos ao segmento denominado *prime* (hipotecas de baixo risco). Até então, julgava-se que certo nível de inadimplência poderia ser suportado por um sistema financeiro considerado robusto.

À época, era comum os bancos oferecerem empréstimos a juros muito baixos para viabilizar a compra de imóveis, mesmo sem a adequada comprovação de renda, o que resultou em uma bolha imobiliária, pois as pessoas financiaram imóveis a um preço muito acima do que valiam. A consequência desse processo foi o início de uma crise, que ocorreu após os bancos aumentarem a taxa de juros e não terem mais dinheiro para as operações, devido à inadimplência de muitas pessoas.

Em agosto de 2007, observou-se uma injeção superior a 90 bilhões de dólares nos sistemas bancários americano e europeu por parte do Sistema de Reserva Federal (*Federal Reserve* [FED]) dos Estados Unidos e do Banco Central Europeu (BCE), respectivamente. Ainda em 2007, ocorreram sucessivos eventos que sinalizavam uma conjuntura de crise. Todavia, a rápida atuação da autoridade monetária americana permitiu que a confiança nos mercados fosse reestabelecida rapidamente (Cecchetti, 2009).

Durante o período de um ano – de setembro de 2007 a setembro de 2008 –, nenhuma das medidas tomadas – essencialmente, sucessivas injeções de liquidez no sistema financeiro e reduções das taxas de juro centrais – trouxeram estabilidade. Em março de 2008, o Banco *Bear Stearns* declarou-se incapaz de honrar seus compromissos financeiros. Em uma tentativa de evitar um movimento de pânico nos mercados, FED e Tesouro americano montaram uma operação de salvamento, que consistiu em uma injeção de liquidez em troca da aquisição parcial da propriedade pelo banco JP Morgan (Amaral, 2009).

Neste sentido, a derrocada aconteceu quando um dos mais tradicionais bancos americanos, o *Lehman Brothers*, declarou falência, seguida por uma queda das bolsas mundiais. O mercado acionário – utilizando o Índice *Dow Jones* como *benchmark* – caiu vertiginosamente de mais de 14.000 pontos, em outubro de 2007, para 7.000 pontos, em março de 2009, com uma queda de quase 2.000 pontos em uma única semana no mês de setembro de 2008. Isso resultou em uma significativa e prolongada recessão. Conforme a teoria do contágio da crise, choques

exógenos foram transmitidos a muitos países, levando ao co-movimento dos mercados de ações (Kothari & Lester, 2012).

Na Europa, por exemplo, a crise se espalhou cerca de dois anos após o início, atingindo, principalmente, a Zona do Euro. No Brasil, por sua vez, houve uma forte queda do índice Bovespa (IBOVESPA) e um aumento significativo no preço do dólar.

1.1.2 A crise político-econômica de 2014-2016

Também conhecida como a grande recessão brasileira, a crise econômica no país teve início em meados de 2014, ano da eleição de Dilma Rousseff para o seu segundo mandato presidencial. Essa crise gerou um recuo no Produto Interno Bruto (PIB) por dois anos seguidos. A economia retraiu-se cerca de 3,5%, em 2015, e 3,3%, em 2016, ano do *impeachment* da presidente Dilma. Como consequência, houve aumento no desemprego, que chegou ao patamar de 13,7%, representando, aproximadamente, 14,2 milhões de brasileiros desempregados (Oreiro, 2017).

Após a acelerada recuperação da crise de 2008 e o início de inquietações com a evolução da inflação, houve mudanças no arranjo de política econômica, com reversão da política fiscal expansionista dos períodos anteriores. De forma concomitante, teve início a diminuição da taxa de juros pelo Banco Central do Brasil (BCB), bem como o controle dos preços de derivados do petróleo, tarifas de energia elétrica e outras *commodities* (Dweck & Teixeira, 2017).

É importante ressaltar que Dilma Rousseff deu início ao seu primeiro mandato, em 2011, em um contexto marcado por uma pressão inflacionária mais contundente, mas ainda mantida próxima ao centro da meta, mesmo sem elevação significativa nas taxas de juros.

Em meados de 2012, no entanto, já existiam evidências de que o governo estava enfrentando dificuldades na gestão macroeconômica; dificuldades essas relacionadas, principalmente, com o ressurgimento de um ambiente inflacionário. Na segunda metade de 2012, a economia brasileira enfrentou uma inflação acima do centro da meta. Posteriormente, foi se confirmando a expectativa de que a economia iria atravessar mais um ano com reduzida taxa de crescimento, tendendo a se repetir no ano seguinte, em virtude do ambiente econômico externo (Contri, 2014).

A partir do final de 2011 e início de 2012, as condições internacionais começaram a mudar drasticamente, tornando-se cada vez mais adversas. A crise da Zona do Euro combinou-se com desaceleração da economia chinesa e uma recuperação muito lenta

dos EUA, com impacto negativo na atividade doméstica. A política monetária manteve o viés expansionista, com o início de um ciclo de rápida redução da taxa básica de juros, combinada com a redução dos *spreads* bancários empreendida por uma intensa concorrência dos bancos públicos com os privados, por meio de expressiva redução das taxas de juros das suas diversas linhas de crédito. Ao final de 2014, frente a novos choques econômicos, houve uma forte desaceleração da atividade, que acelerou a retração da arrecadação e houve piora significativa do resultado fiscal. Ao longo de 2015, foi rompida a ‘convenção do crescimento’, e foram adotadas medidas restritivas em todas as áreas, principalmente, na área fiscal, quando foi realizado um dos maiores ajustes fiscais da história recente, maior inclusive que os de 1999 e 2003. A recessão de 2015, centrou-se na condução da política fiscal, frequentemente tendo como pano de fundo o cumprimento das regras fiscais (Dweck & Teixeira, 2017, p. 2).

A crise foi agravada por escândalos de corrupção, investigados pela Operação Lava Jato, após a vitória de Dilma Rousseff, em 2014, para o seu segundo mandato. Esses fatores contribuíram para a realização de protestos por parte da população em todo o país.

Sob uma série de acusações contra, principalmente, aqueles aliados do governo, que iam desde corrupção na empresa cujo controle majoritário acionário é da União, a Petrobras, até envolvimento com construtoras, a derradeira que levou à votação na Câmara dos Deputados foi a que feria a Lei de Responsabilidade Fiscal. Em 2 de dezembro de 2015, o presidente da Câmara aceitou o processo de acusação. Houve, então, a formação de uma comissão especial que o analisou e foram iniciados os procedimentos burocráticos que levaram à cassação meses depois (Batista, Maia, & Romero, 2018, p. 7).

A foi afastada pelo Senado Federal durante o primeiro semestre de 2016, pois seu mandato presidencial terminou com o *impeachment*, em 31 de agosto do mesmo ano. Em seu lugar, assumiu Michel Temer, vice-presidente.

Em cenários de crise política e econômica como esse, a maior volatilidade no mercado acionário pode ser percebida pelos investidores como aumento no risco do investimento em ações. Esse ambiente de incerteza e desconfiança, gerado por um alto gasto governamental e pelo aumento da inflação e da taxa de juros originaram um cenário controverso ao desempenho do mercado de capitais brasileiro, uma vez que o Ibovespa, índice da Brasil, Bolsa, Balcão (B3), apresentou queda superior a 40% entre setembro de 2014 e janeiro de 2016 (seu ponto máximo e mínimo durante o referido período).

1.1.3 A crise causada pelo Coronavírus

O vírus Sars-CoV-2, causador da pandemia do Covid-19, surgiu em dezembro de 2019, na cidade de Wuhan, na China, e se tornou uma ameaça à saúde e à vida das pessoas em quase

todo o planeta, bem como à economia global; por conseguinte, uma ameaça aos mercados de acionários.

Com o vírus, vieram incertezas envolvendo aspectos como a capacidade de contágio, a prevalência e a sua letalidade. Em decorrência, dúvidas surgiram sobre a capacidade dos sistemas de saúde de enfrentarem os novos desafios e o tempo que seria necessário para o desenvolvimento e a distribuição de uma vacina segura e eficaz.

Em resposta aos relatos de novos casos surgindo diariamente na China e, posteriormente, na Europa, particularmente na Itália, a reação negativa do mercado acionário à disseminação do coronavírus começou em meados de fevereiro de 2020. O primeiro grande *crash* ocorreu em 21 de fevereiro.

Os mercados de ações dos Estados Unidos atingiram um ponto baixo em 23 de março de 2020, após a declaração da Organização Mundial da Saúde (OMS) de uma pandemia, em razão do aumento exponencial de novos casos diários de Covid-19 em todo o mundo e das decisões governamentais em promulgar bloqueios. Mesmo as *commodities*, relativamente mais seguras, sofreram com o avanço da pandemia (Ali, Alam, & Rizvi, 2020; Chan & Marsh, 2021b; Nikolopoulos, Punia, Schäfers, Tsinopoulos, & Vasilakis, 2021).

Com as necessidades de isolamento social, a decretação de *lockdowns*, os fechamentos de fronteiras e as restrições em todo o mundo, a economia mundial sofreu um grande impacto, gerando uma crise econômica sem precedentes. Os números variaram de país para país. De acordo com a Organização para a Cooperação e Desenvolvimento Econômico (OCDE), em 2020, o PIB global teve contração de 3,4%. Isso porque, o gasto com medidas contra a pandemia levou vários países a fecharem aquele ano com recorde de endividamento.

Como estratégia de contenção da pandemia, foram adotadas medidas de distanciamento social, que ocasionaram mudanças nos padrões de consumo da população e refletiram diretamente na saúde financeira empresarial em diversos setores da economia, bem como nas taxas de desemprego, que aumentaram.

Conforme projeções do Banco Mundial, como resultado da pandemia, centenas de milhões de pessoas voltaram à pobreza, com aproximadamente 100 milhões de indivíduos em situação de pobreza extrema.

O desemprego também foi uma dura consequência da Covid-19. Segundo o relatório da Organização Internacional do Trabalho (OIT), foram mais de 114 milhões de empregos perdidos no ano 2020.

No Brasil, o descompasso entre oferta e demanda e a desvalorização da moeda resultaram em uma combinação deletéria para o controle da inflação. Segundo o Tesouro

Nacional, os gastos federais para combater os efeitos da pandemia foram superiores a R\$ 600 bilhões só em 2020 e provocaram uma explosão da dívida pública, aumentando as preocupações sobre a saúde das contas públicas, a sustentabilidade fiscal do país e refletindo diretamente no mercado de capitais brasileiro, principalmente em função do risco percebido pelos investidores.

1.2 PROBLEMA DE PESQUISA

Diante do exposto, são observadas variações nos preços dos ativos e na relação entre os riscos e os retornos obtidos no mercado de ações. Assim sendo, diversos métodos de análise, com o objetivo de precificar as ações, são observados. Contudo, não há consenso na literatura acadêmica quanto a um modelo e suas variáveis ou técnica que possua capacidade explicativa ou preditiva sobre o preço das ações no mercado de capitais brasileiro (Lucena, Silva, Melo, & Gomes, 2013; Machado & Medeiros, 2012; Noda, Martelanc, & Kayo, 2015; Rosa & Lustosa, 2014; Silva & Medeiros, 2019).

Diversas potenciais anomalias no comportamento das taxas de retorno das ações têm sido estudado nas últimas décadas. Essas anomalias motivam pesquisadores a desenvolver modelos que tentam “explicar” tais anomalia como fatores de risco. Dessa forma, esses fatores são incluídos como parte do cálculo do custo de capital.

Neste contexto, verifica-se que o acúmulo de variáveis avançadas para explicar os retornos dos ativos vem se acelerando, apesar da pouca compreensão da estrutura de correlação entre eles. Pode-se considerar que diversas pesquisas publicadas demonstram interesse em formular uma relação fundamentada entre risco e retorno, apresentando um método de “mineração de dados”, que é uma oportunidade oferecida em função da quantidade de dados disponíveis aliada a testes econométricos.

Como exemplo, tem-se o estudo de Barillas e Shanken (2018), no qual foi desenvolvido um procedimento, por meio da abordagem Bayesiana, que permite uma comparação simultânea de modelos, isto é, o cálculo de probabilidades dos modelos de precificação possíveis baseados em subconjuntos dos fatores dados. Os autores ressaltam a importância da mineração de dados na seleção de fatores.

O presente estudo não tem como objetivo identificar anomalias na precificação de ativos, embora não sejam desconsideradas as diferenças entre mercados desenvolvidos, em que os modelos são formulados e testados, e mercados emergentes. Pretende-se priorizar o estudo

das possíveis metodologias e o aprimoramento dos testes a serem aplicados, durante períodos de crise econômica, em modelos de precificação consolidados

Desse modo, o presente estudo busca preencher essa lacuna, tendo como problema de pesquisa: no mercado acionário brasileiro, o *Arbitrage Price Theory* (APT) (Ross, 1976) e o Modelo de 5 Fatores (Fama & French, 2016) possuem capacidade explicativa e preditiva na precificação de ativos em períodos de crise?

1.3 OBJETIVOS

1.3.1 Objetivo geral

Avaliar capacidade explicativa e preditiva dos modelos de precificação de ativos APT (Ross, 1976) e Modelo de 5 Fatores (Fama & French, 2016) no mercado acionário brasileiro, aplicando-os e analisando-os durante três períodos de crise na economia brasileira, a saber: a crise do *Subprime* (2008), a crise político-econômica (2014-2016) e a crise decorrente da pandemia de Covid-19 (2020-2021).

1.3.2 Objetivos Específicos

Analisar a viabilidade e definir a metodologia para a utilização do modelo APT (Ross, 1976) e do Modelo de 5 Fatores (Fama & French, 2016) na precificação de ações negociadas na Bolsa de Valores de São Paulo durante períodos de crise no mercado acionário brasileiro.

→ Identificar as principais variáveis empregadas nos referidos modelos, bem como os períodos de crise a serem analisados.

→ Estimar os parâmetros necessários para a composição dos modelos.

→ Avaliar o desempenho dos modelos na precificação de ações, no mercado acionário brasileiro, em momentos de crise.

→ Verificar a existência de capacidade explicativa adicional dos fatores dos modelos APT e Modelo de 5 Fatores.

→ Realizar a previsão do retorno acionário durante os períodos estudados através do *Dynamic Model Averaging* (DMA).

→ Analisar e comparar a capacidade preditiva dos parâmetros que compõem os modelos adotados nos períodos estudados.

1.4 JUSTIFICATIVA

Compreender e prever o retorno acionário é um dos tópicos mais discutidos na economia financeira, pois gera grandes implicações na escolha da carteira e na gestão de risco incorrido. As pesquisas sobre precificação de ativos são relevantes, visto que nenhum modelo, até o presente momento, foi amplamente aceito pelos diferentes grupos (investidores, analistas, pesquisadores em finanças, gestores de fundos de investimento, empresas com ações negociadas em bolsa, avaliadores, empresas de auditoria, entidades reguladoras e fiscalizadoras dos mercados acionários). Soma-se a isso o fato de que o Brasil não tem uma economia plenamente desenvolvida, seja pelas condições macroeconômicas, sociais e políticas instáveis, seja pelo mercado de ações consequentemente mais volátil do que os de países desenvolvidos. Isso aumenta a insegurança dos investidores sobre a previsibilidade do mercado de ações do país.

Além disso, estudos sobre o desenvolvimento e a previsibilidade do mercado acionário brasileiro não são conclusivos. A vantagem do DMA, a ser utilizado no presente estudo, reside no fato de que esse método permite que ambos os conjuntos de preditores (modelos de previsão), bem como seus coeficientes, mudem ao longo do tempo. Os modos de previsão são recursivos e contínuos. Observa-se que, na comparação entre os desempenhos do DMA e de modelos de previsão tradicionais, como modelos autorregressivos, aquele geralmente apresenta um desempenho superior a estes.

Diante disso, esta tese intenta verificar a aplicabilidade e a capacidade preditiva de modelos de precificação no mercado acionário brasileiro, por meio de uma exposição prática da composição dos modelos, observando sua efetividade na precificação de ações em momentos de crise. Neste sentido, ressalta-se a importância de estudar as mudanças estruturais em mercados emergentes.

Recentemente, artigos que abordam a estimativa de risco sistemático de forma dinâmica têm ganhado espaço na literatura, uma vez que a estrutura de correlação entre os fatores envolvidos nos modelos sofre alterações ao longo do tempo, especialmente quando existem quebras estruturais nas séries temporais, decorrentes, por exemplo, de períodos de crise (Garcia & Bonomo, 2001; Silva *et al.*, 2009).

Entende-se que o estudo consistirá em referência de metodologia para a utilização dos modelos de precificação de ativos no mercado acionário brasileiro e em outros mercados, bem como contribuirá para o acervo de pesquisas e discussões realizadas sobre a precificação de ações nesse mercado.

1.5 LIMITAÇÕES DO ESTUDO

Uma das principais limitações deste estudo, consiste no fato de a análise ser realizada apenas com empresas brasileiras pertencentes a B3, não envolvendo o mercado de capitais de outros países. Desse modo, não é possível expandir os resultados a outras economias.

O estudo não pretende abordar empresas do setor financeiro. Assim, estas serão excluídas da amostra em razão de suas particularidades, principalmente em relação à estrutura de capital. Quanto aos demais setores, não é objeto do estudo tratar qualquer especificidade, bem como identificar modelo de precificação ou método que possua melhor ajuste a determinado setor.

Outra limitação se dá em função do uso de portfólios. Há certo consenso na utilização de carteiras para a composição dos modelos de precificação de ativos. Porém, o uso de portfólios nos testes apresenta algumas limitações. Os retornos médios das carteiras oscilam, com menos variáveis explicativas do que em ações individuais. É possível que a diversificação das carteiras possa disfarçar fenômenos que afetam ações individuais, mas que não estão relacionadas com o conjunto de ativos do portfólio.

Observa-se que, na literatura, podem ser encontrados diversos modelos de precificação de ativos. Assim, de forma alguma pretende-se esgotar o assunto, mas apenas contribuir com as discussões, haja vista que ainda existem muitos outros modelos a serem testados, bem como outras metodologias empíricas, que não serão contempladas pelo estudo.

1.6 ESTRUTURA APRESENTADA

Para o desenvolvimento do estudo apresentado nesta introdução, serão desenvolvidas mais quatro seções, além das referências. A segunda seção apresenta o referencial teórico, em que está presente a teoria de base sobre precificação de ativos. Os modelos serão apresentados, bem como relatados estudos anteriores que visam embasar o desenvolvimento deste trabalho.

A terceira discorre sobre a metodologia de pesquisa, que apresenta as etapas de coleta e tratamento dos dados e os modelos a serem utilizados. A quarta enfatiza os resultados e as análises. E a quinta seção traz as considerações finais.

2 REFERENCIAL TEÓRICO

O referencial teórico divide-se em quatro partes. As três primeiras apresentam a fundamentação conceitual e teórica de finanças e bem como as teorias em que dos modelos de precificação de ativos se baseiam. Em seguida, aborda-se o modelo CAPM, de Sharpe (1964), Lintner (1965) e Mossin (1966). As seções 2.3.2 e 2.3.3 contemplam os modelos APT, de Ross (1976), e o Modelo de 5 Fatores, de Fama e French (2016). Por fim, a última seção apresenta o DMA, relatos de testes empíricos acerca desse método e suas possíveis aplicações.

2.1 A EVOLUÇÃO DA TEORIA DE FINANÇAS

No início da década de 1950, a literatura financeira ainda era composta, em grande parte, por teorias *ad hoc*, ou seja, teorias com o propósito de justificar as anomalias e particularidades encontradas nos mercados financeiros. Iniciava-se com nascimento de uma corporação, e a seguia através de várias decisões político-financeiras e suas consequências, analisando diversos detalhes institucionais, até uma possível falência. A Teoria de Finanças, antes da década de 1950, estava repleta de inconsistências lógicas e era quase totalmente prescritiva, ou seja, normativamente orientada. As principais preocupações do campo eram o investimento ótimo, financiamento e políticas de dividendos. Entretanto, havia pouca consideração à dinâmica dessas decisões e suas possíveis implicações (Jensen & Smith, 1984).

2.1.1 A moderna teoria de finanças

Nesse contexto, nos anos de 1952 e 1958, duas foram as contribuições iniciais à chamada moderna teoria de finanças. Em março de 1952, Harry Markowitz teve seu artigo “*Portfolio Selection*” publicado no *The Journal of Finance*. Antes disso, pouca atenção era dada à seleção de portfólios, e uma carteira era considerada, geralmente, apenas um acúmulo de títulos. Ao considerar o risco (variância do retorno dos títulos) como uma característica indesejável aos investidores, estes deveriam meramente acumular “ativos vencedores”, com o objetivo de maximizar o seu retorno. Assim, as carteiras deveriam ser formadas para minimizar a variância dos retornos, que é a medida do risco para um determinado retorno esperado, e

maximizar os retornos esperados para um determinado nível de risco. Esse processo originou a teoria do portfólio.

Em 1958, Modigliani e Miller publicaram um estudo intitulado “*The cost of capital, corporation finance and the theory of investment*”, mostrando as condições sob as quais as decisões de estrutura de capital de uma empresa, bem como a distribuição dos dividendos, não afetariam o valor da firma, sendo que este depende do fluxo de receita gerado por seus ativos. Nascia, então, o teorema Modigliani-Miller.

Além disso, o núcleo da moderna teoria de finanças é composto por mais três teorias desenvolvidas nas décadas de 1960 e 1970. A primeira foi elaborada por Treynor (1961), Sharpe (1964) e Lintner (1965), que aplicaram a análise normativa de Markowitz (1958), para criar uma teoria positiva da determinação dos preços dos ativos.

Dadas as demandas dos investidores por títulos, implícitas no modelo de seleção de carteira de média-variância de Markowitz (1958), foi desenvolvido o modelo CAPM. Este estabeleceu uma teoria positiva para a determinação dos retornos esperados, vinculando o preço do momento presente à expectativa de fluxos de pagamentos futuros. De acordo com esse modelo, um único fator – o beta (o excesso de retorno da carteira de mercado em relação ao ativo livre de risco) – é capaz de explicar o retorno de um ativo. Há, também, uma contribuição para a definição do custo de oportunidade do capital para as decisões de orçamento de capital da empresa.

Em 1970, foi publicado um artigo seminal intitulado “*Efficient Capital Markets: a review of theory and empirical work*”. Este foi considerado como outro estudo de referência à teoria de finanças. No referido trabalho, Fama (1970) fez uma síntese de pesquisas anteriores sobre a previsibilidade dos retornos dos mercados de capitais, apresentando as noções de *fair game* e *random walk*. O estudo abordou a noção de um mercado eficiente como aquele que tem a capacidade de se adaptar ou ajustar-se rapidamente, sob o pressuposto de que os preços dos títulos “refletem totalmente”, a qualquer momento, todas as informações disponíveis. O autor argumentou que, como todos têm acesso às mesmas informações, seria impossível “bater” regularmente o mercado, porque os preços das ações são, de fato, eficientes, refletindo tudo o que é conhecido pelos participantes do mercado.

O último pilar das finanças modernas é o modelo de precificação de opções, de Black e Scholes (1974). O objetivo central dessa teoria é o de determinar o custo ou o valor da opção. Este pode depender de muitos fatores, incluindo o preço de mercado atual do ativo subjacente, o preço de exercício da opção, a data de vencimento do contrato de opção, o prêmio

especulativo da opção (desvio estimado em relação ao preço do ativo subjacente ao longo da vida da opção) e a taxa de juros sem risco.

Com base nessas variáveis, esse modelo demonstrou que era possível construir uma carteira por meio de hedge dinâmico, ou seja, assumindo posições em títulos (dinheiro), opções e ações subjacentes. Dessa forma, as mudanças no valor da opção seriam compensadas por mudanças iguais no valor das ações subjacentes e do dinheiro.

As premissas em que se assentam as teorias de finanças modernas foram desenvolvidas separadamente, em diferentes estágios do pensamento em finanças, bem como em diferentes circunstâncias, estando voltadas para diferentes propósitos. No entanto, essas teorias compartilham, em geral, um conjunto comum de suposições fundamentais muito restritivas.

Pressupõem alguma forma de existência de mercados de capitais perfeitos, ausência de impostos e custos de transação; no caso do teorema Modigliani-Miller (1958), sem perigo de falência. Além disso, pressupõem que os agentes tenham igual acesso à informação e aos mercados de capitais, e que se ajustem rápida e continuamente às novas informações. No mais, as decisões devem ser tomadas exclusivamente com base nos valores esperados e nos desvios-padrão dos retornos das carteiras, de modo que todos os agentes tenham expectativas homogêneas.

Essas suposições geraram diversas críticas aos modelos. Diante de situações de alta volatilidade nos preços dos ativos, questionou-se, inclusive, a racionalidade dos investidores, dando início às discussões sobre a questão comportamental nas decisões financeiras.

2.1.2 Finanças comportamentais

Por volta de 1980, a consistência do modelo de mercados eficientes estava começando a ser desafiada veementemente. Uma questão inibia a aceitação total dos mercados eficientes: o excesso de volatilidade. Várias teorias foram formadas para descrever as grandes oscilações nos preços dos ativos. Entretanto, foi difícil harmonizar a ideia de que o preço das ações era o valor presente em todos os dividendos futuros esperados, em razão da volatilidade observada nos preços das ações. Isso marcou o início dos questionamentos sobre a racionalidade dos investidores, bem como o que compunha o valor de uma ação.

De acordo com Olsen (1998), os teóricos das finanças comportamentais identificaram atributos de decisão psicológica em potencial, que seriam capazes de orientar as decisões financeiras, sendo alguns deles:

- As preferências dos tomadores de decisão tendem a ser multifacetadas, abertas a mudanças e, muitas vezes, formadas apenas durante o próprio processo de decisão.
- Os tomadores de decisão parecem ser adaptativos, de modo que a natureza da decisão e o ambiente no qual esta é tomada contribuem para a seleção de um processo ou de uma técnica de decisão.
- Os tomadores de decisão buscam soluções satisfatórias em vez de ótimas.

Desde então, o sentimento do investidor passou a receber considerável atenção na precificação de ativos. Assim, a literatura tem investigado, teórica e empiricamente, se e como o sentimento do investidor afeta os preços dos ativos, sendo isso decorrência de crenças excessivamente otimistas ou pessimistas, bem como escolhas de agentes irracionais.

Os agentes irracionais podem reagir de modos insuficiente ou exagerado à informação. A dinâmica do humor do investidor é tida como um processo estocástico. Desse modo, a imprevisibilidade do ambiente econômico criaria alguns riscos para atividades de limites de arbitragem iminentes de investidores racionais, e os preços dos ativos se desviariam de seus valores fundamentais. Discute-se, ainda, se a capacidade do sentimento do investidor de prever os retornos das ações é mais forte sob más condições de mercado (Baker & Wurgler, 2006; Liu, Liang, & Tang, 2003; Long, Shleifer, Summers, & Waldmann, 1990; Shleifer & Vishny, 1997).

2.1.3 Análise fundamentalista

Além da influência do sentimento do investidor no retorno acionário, desde a década de 1960 a capacidade de um único fator – beta – em explicar o retorno dos ativos já era questionada. Os estudos acerca da reação do preço das ações às informações contábeis tiveram como precursores os trabalhos de Ball e Brown (1968), em que foram realizados testes empíricos sobre a existência de uma relação entre o lucro contábil e o retorno acionário.

Por sua vez, o estudo de Basu (1983) examinou a relação empírica entre lucros, tamanho da empresa e retornos sobre as ações ordinárias de empresas listadas na *New York Stock Exchange* (NYSE). Os resultados empíricos apresentados no referido estudo indicaram que, pelo menos durante o período de 1963 a 1980, os retornos sobre as ações ordinárias das empresas da NYSE pareciam estar relacionados com os lucros e o tamanho da organização.

Sob a influência desses estudos seminais, diversas variáveis fundamentalistas e macroeconômicas foram testadas, com base em diferentes metodologias. Entretanto, ainda não

há consenso sobre a capacidade de tais variáveis em explicar o retorno acionário, e a eficiência do mercado de capitais continua sendo questionada (Bhandari, 1988; Chan *et al.*, 1991; Fama & French, 2015; Jegadeesh *et al.*, 2019; Liu, 2006; Ou & Penman, 1989; Shanken, 1990; Singh *et al.*, 2011; Stambaugh *et al.*, 2012).

O rápido crescimento do volume de dados excedeu, em muito, a capacidade de analisá-los manualmente, consequência da era da globalização econômica e das facilidades da tecnologia digital. A geração e o acúmulo de dados financeiros atingiram um ritmo sem precedentes, e as suas influências sobre as decisões dos investidores são questionadas, debatidas e testadas de forma recorrente.

Discute-se que os dados das séries temporais financeiras são afetados por variações cíclicas, variações sazonais e movimentos irregulares. Diante do crescimento contínuo de dados flutuantes e irregulares, houve a necessidade crítica de desenvolver abordagens mais automatizadas, com vistas a uma análise mais eficiente, de modo a obter estatísticas significativas a partir deles (Dash & Dash, 2016).

É importante enfatizar que os participantes do mercado financeiro no século XXI são bastante diferentes daqueles da década de 50 do século passado. Eles não são apenas mais sofisticados financeiramente, como também estão munidos de mais ferramentas, informações e conceitos. Isso faz com que haja um aperfeiçoamento rápido de técnicas, testes e teorias a serem empregados.

2.2 O MERCADO ACIONÁRIO E A HIPÓTESE DE EFICIÊNCIA DE MERCADO

O preço das ações é definido com base em uma série de fatores que se relacionam. Os desempenhos futuros das empresas e da economia formam a expectativa do mercado em relação ao desempenho de um título, sendo que diversas variáveis contábeis e macroeconômicas têm sido estudadas para a compreensão da formação do seu preço (Galdi & Lopes, 2008).

Conforme a teoria do mercado eficiente (Fama, 1970), o ajustamento do preço dos títulos considera três subconjuntos de informações, quais sejam: forma fraca, forma semiforte e forma forte.

Quando os preços das ações refletem completamente toda a informação disponível sobre aqueles títulos, o mercado é considerado eficiente. Neste sentido, a velocidade de reação dos agentes a novas informações disponibilizadas pelo mercado determina a caracterização do tipo de eficiência do mercado.

Segundo Fama (1970), a hipótese de mercado eficiente tem como premissas principais: (a) não há custos de transações na comercialização dos títulos; (b) todas as informações são gratuitas e estão à disposição de todos os participantes do mercado; e (c) todos os participantes do mercado analisam as informações disponíveis de forma igual e projetam da mesma maneira a distribuição futura dos preços dos títulos.

Em termos gerais, a teoria dos mercados eficientes está preocupada com o fato de os preços "refletirem integralmente", a qualquer momento, a informação disponível. Menciona-se que boa parte da literatura empírica disponível é, implícita ou explicitamente, baseada no pressuposto de que as condições de equilíbrio de mercado podem ser definidas em termos de retornos esperados. Esse pressuposto é a base dos modelos de mercados eficientes de retorno esperado ou *fair game*.

O trabalho empírico desenvolvido por Fama (1970) pode ser dividido em três categorias, dependendo da natureza do subconjunto de informações de interesse, quais sejam:

- Testes fortes: preocupados com o fato de investidores individuais ou grupos terem acesso a qualquer informação relevante para a formação dos preços. Não se poderia esperar que um modelo tão extremo fosse uma descrição exata do mundo, e isso é visto mais como uma referência contra a qual a importância dos desvios da eficiência do mercado pode ser julgada.
- Testes semifortes: menos restritivos, sendo que o subconjunto de informações de interesse inclui todas as informações disponíveis ao público.
- Testes fracos: o subconjunto de informações consiste apenas em dados passados, como o preço histórico ou as sequências de retornos.

A relevância da teoria de eficiência de mercado é advinda da ideia de que o mercado pode reagir conforme uma das três premissas apresentadas com relação às informações disponíveis. Salienta-se que, com base em uma dessas três formas, novos estudos podem ser melhor modelados, assumindo uma das premissas, e os resultados obtidos estarão embasados e sujeitos a menos críticas.

2.3 A TEORIA DO PORTIFÓLIO E OS MODELOS DE PRECIFICAÇÃO DE ATIVOS

Em seu estudo, Markowitz (1958) abordou e quantificou o conceito de diversificação, ou não diversificação, introduzindo a noção estatística de uma covariância ou correlação,

recomendando que não se deve investir os recursos, em um mesmo momento, em investimentos cujos retornos estejam altamente correlacionados. Isso porque, se um deles apresentar um desempenho ruim, é provável que os demais tenham o mesmo comportamento.

A teoria do portfólio analisa a questão normativa da formação de uma carteira de ativos, isto é, como escolher carteiras que maximizem o esperado pelos investidores. Markowitz (1958) afirma que o conjunto eficiente de carteiras diz respeito àquelas que fornecem tanto o retorno máximo esperado para uma determinada variância quanto a variância mínima para um determinado retorno esperado. Sua análise de média-variância estabelece um conteúdo formal para o significado de diversificação, uma medida da covariância entre os retornos de títulos para o risco de uma carteira e as regras para a construção de uma carteira eficiente.

No tocante a mercados e investidores, a teoria do portfólio baseia-se nas seguintes suposições:

- Os investidores são racionais, ou sejam, procuram maximizar os retornos enquanto minimizam o risco.
- Os investidores estão dispostos a aceitar montantes mais elevados de risco, se apenas - forem recompensados por retornos esperados mais elevados.
- Os investidores recebem oportunamente todas as informações pertinentes à sua decisão de investimento.
- Os investidores podem pedir emprestado ou emprestar uma quantidade ilimitada de capital a uma taxa livre de risco.
- Os mercados são perfeitamente eficientes.
- Não há custos de transação ou impostos.

Importa mencionar que a teoria da seleção de portfólio é uma teoria normativa. Esta descreve um padrão ou norma de comportamento que os investidores deveriam buscar na construção de uma carteira. Constata-se que teorias de precificação de ativos, como o modelo CAPM, formalizam a relação que deve existir entre o ativo – retornos e risco, se os investidores construíram as carteiras selecionadas, de acordo com a análise de média-variância. Em contraste com teorias normativas, a teoria de precificação de ativos é positiva, ou seja, levanta hipóteses acerca de como os investidores se comportam em vez de como os investidores deveriam se comportar (Fabozzi, Gupta, & Markowitz, 2002).

Juntos, a teoria das carteiras e o CAPM fornecem o arcabouço teórico para a mensuração do risco atrelado a um investimento e ao desenvolvimento da relação entre o retorno esperado

de um ativo e o seu risco; portanto, entre o risco e o retorno exigido por parte de um investidor sobre seu investimento.

2.3.1 Capital Asset Pricing Model (CAPM)

O modelo de precificação de ativos mais utilizado no Brasil é o CAPM, que foi proposto por Sharpe (1964), Lintner (1965) e Mossin (1966). Segundo esse modelo, um único fator – o excesso de retorno da carteira de mercado em relação ao ativo livre de risco – é capaz de explicar o retorno de um ativo. Isso o faz alvo de várias críticas. Discute-se, recorrentemente, se outras variáveis possuem capacidade explicativa adicional, como observado em diversas pesquisas (Araújo, Oliveira, & Silva, 2012; Lucena *et al.*, 2013; Noda *et al.*, 2015).

O CAPM parte do modelo de escolha da carteira desenvolvido por Harry Markowitz (1959). No modelo de Markowitz, um investidor escolhe uma carteira em um momento $t - 1$ que produza um retorno estocástico em t . O modelo admite que os investidores sejam avessos ao risco e que, ao escolherem entre carteiras, preocupem-se apenas com a média e a variância do retorno de seu investimento de um período. Com isso, os investidores escolhem carteiras ‘eficientes em média-variância’ desde que as carteiras 1) minimizem a variância do retorno da carteira dado o retorno esperado e 2) maximizem o retorno esperado dado a variância. Assim, a abordagem de Markowitz é frequentemente chamada de modelo de média-variância’ (Fama & French, 2007, p. 104).

O CAPM é representado pela seguinte equação:

$$R_i = R_f + \beta (R_m - R_f) \quad (1)$$

Onde:

R_i = retorno esperado do ativo;

R_f = retorno do ativo livre de risco no mercado usado como referência;

R_m = taxa esperada de retorno sobre o portfólio geral do mercado de referência;

$(R_m - R_f)$ = prêmio relativo ao risco de mercado de referência;

β = sensibilidade do ativo em relação ao fator de mercado.

O risco total de um ativo pode ser decomposto em riscos assistemático e sistemático. O primeiro refere-se à porção de risco exclusiva de um determinado ativo, e não é muito importante para os investidores, uma vez que esses podem eliminá-lo através da construção de

carteiras eficientes (eventos ruins em uma empresa serão compensados por bons eventos em outra empresa dentro de uma carteira). Em contrapartida, o segundo envolve a parte da variação do retorno que depende de um fator macro em uma economia, como inflação, recessão, altas taxas de impostos e juros. Assim sendo, esse tipo de risco não pode ser eliminado pela diversificação (Phuoc, Kim, & Su, 2018).

Uma vez que o risco total é igual à soma do risco sistemático (não diversificável) com o risco não sistemático (diversificável) e, assumindo que os participantes do mercado diversificam eficientemente suas carteiras, eliminando o risco não sistemático, o único componente que resta do risco total é o risco sistemático, representado pelo beta. Assim, para um mercado em equilíbrio, o risco sistemático de um ativo é suficiente para quantificar seu retorno exigido. Dessa forma, o coeficiente beta é obtido, regredindo-se os retornos em excesso do ativo objeto com os retornos em excesso da carteira de mercado. (Machado & Machado, 2014, p.78)

Dentro do constructo do CAPM, o risco sistemático é mensurado pelo beta, obtido conforme o cálculo apresentado a seguir:

$$\beta_{im} = \frac{Cov(R_i, R_m)}{\sigma_m^2} \quad (2)$$

Onde:

β_{im} = beta de um ativo;

$Cov(R_i, R_m)$ = covariância entre o retorno do ativo e o retorno do mercado de referência;

σ_m^2 = variância do mercado de referência.

O beta de um ativo é tido como medida comparativa do risco incorrido. Caso o seu valor seja próximo a 1, o ativo possui aproximadamente o mesmo risco sistemático que o mercado de referência; se for maior, apresenta maior risco; se for menor, apresenta risco inferior ao do mercado. Todavia, as premissas assumidas no uso do modelo o fazem alvo de diversas críticas, sendo controverso o uso do beta do CAPM como única medida de risco (Carhart, 1997; Fama & French, 1993, 2015; Jegadeesh *et al.*, 2019; Liu, 2006; Ross, 1976; Stambaugh *et al.*, 2012).

A explicação das contradições empíricas do CAPM indica a necessidade de um modelo mais complexo de precificação de ativos. O CAPM se baseia em muitas premissas irreais. Por exemplo, a de que os investidores somente se preocupam com a média e a variância do retorno da carteira em um período é bastante exagerada. É razoável que eles também se importem com a maneira como o retorno de sua carteira covaria em relação ao rendimento do trabalho e a oportunidades futuras de investimento, de modo que a variância do retorno de uma carteira deixa escapar importantes dimensões do risco. Se assim for, o beta de mercado não é uma descrição completa do risco de um ativo, e não devemos nos surpreender ao perceber que

diferenças de retorno esperado não são plenamente explicadas pelas diferenças de beta. Segundo esse ponto de vista, a pesquisa deveria se voltar para modelos de precificação de ativos que expliquem melhor os retornos médios (Fama & French, 2007, p. 111).

O Quadro 1 apresenta alguns estudos precusores que fizeram a inserção de novas variáveis ao modelo CAPM tradicional:

Quadro 1 – Estudos precusores sobre a relação entre o Retorno das Ações e Outras Variáveis

Variáveis	Estudos anteriores
Tamanho da empresa	Banz (1981); Keim (1983); Reiganum (1981).
Alavancagem	Bhandari (1988).
Lucro /Preço	Banz (1981); Basu (1977); Jaffe, Keim e Westerfield (1989).
Indicador valor patrimonial/ valor de mercado	Bondt e Thaler (1985); Chan, Hamao e Lakonishok (1991); Rosenberg, Reid e Lanstein (1985); Statnan (1980).

Fonte: Fellet (2016, p.43).

Outros estudos, como o de Nagano, Merlo e Silva (2017), tiveram como objetivo verificar se no mercado acionário brasileiro existem outras variáveis significativamente relacionadas com os retornos das ações. Para tanto, foram analisadas as relações entre retornos das ações e beta, valor de mercado, vendas/ preço, fluxo de caixa/preço, valor patrimonial/preço, dividendos/preço, lucro/preço e endividamento. Pelo fato de terem sido encontradas associações significativas entre retornos e algumas variáveis, a teoria do CAPM também é questionada no Brasil.

Pode ser observado no quadro abaixo, um conjunto amplo de pesquisas realizadas com variáveis que apresentaram significância estatística:

Quadro 2 - Pesquisas com modelos de precificação de ativos multifatoriais

Autor	Variáveis significativas	Modelos testados
Gonçalves et al, 2012	Retorno de mercado, Fator tamanho e Fator <i>Book-to-Market</i>	3-fatores
Brandão, 2013	Retorno de mercado, Fator tamanho e Fator <i>Book-to-Market</i>	3-fatores
Silva e Machado, 2014	Retorno de mercado, Fator tamanho e Fator <i>Book-to-Market</i>	3-fatores
Piccoli et al, 2015	Retorno de mercado, Fator tamanho e Fator <i>Book-to-Market</i>	3-fatores
Ruiz, 2015	Retorno de mercado, Fator tamanho e Fator <i>Book-to-Market</i> , Fator Rentabilidade e Fator Investimento	5-fatores

Vieira et al, 2017	Retorno de mercado, Fator Rentabilidade e Fator Investimento	5-fatores
Garcia e Santos, 2018	Retorno de mercado e Fator Rentabilidade	5-fatores
Costa Jr. e Neves, 2000	Retorno de mercado, Fator tamanho, Fator <i>Book-to-Market</i> e Lucro/Preço	APT/Multifatoriais
Miranda e Pamplona, 2000	Retorno de mercado, Inflação, PIB, Taxa de Juros	APT/Multifatoriais
Fifield et al, 2002	Retorno de mercado, Inflação, PIB, Taxa de Juros	APT/Multifatoriais
Schor et al, 2002	Retorno de mercado, Inflação, Risco de crédito, Taxa de Juros	APT/Multifatoriais
Leal et al, 2004	Retorno de mercado, Índice de Confiança, e Taxa de Juros	APT/Multifatoriais
Rogers et al, 2009	Retorno de mercado, Fator tamanho	APT/Multifatoriais
Amorim et al, 2012	Lucro Líquido, EBIT/Ativo Total, Crescimento do Lucro por Ação, Crescimento do M/B, D/E Cobertura de Juros	APT/Multifatoriais
Bernardelli e Bernardelli, 2016	PIB, Taxa de Câmbio e Taxa de Juros	APT/Multifatoriais
Galdi et al, 2016	Accruals, Giro do Estoque, Lucro Líquido, Liquidez, Margem Bruta, P/VPA, ROA	APT/Multifatoriais
Leite et al, 2016	Retorno de mercado, Fator tamanho, Fator <i>Book-to-Market</i> e Volatilidade	APT/Multifatoriais
Ottonelli et al, 2016	Retorno de mercado, Preços futuros, Taxa de Câmbio	APT/Multifatoriais

Fonte: Adaptado de Silva (2019).

Com base nessas relações já encontradas, há um estímulo para o desenvolvimento de novas pesquisas, com a formulação de novas variáveis sob novas metodologias

2.3.2 Arbitrage Price Model (APT)

Em 1976, Ross apresentou um modelo multifatorial, em que foram assumidas premissas menos restritivas que as do CAPM. Nesse modelo a precificação de ativos não deve ser atribuída apenas a um único fator (beta do CAPM), pois pode ser influenciada por diversos fatores econômicos.

A teoria APT afirma que o retorno esperado de um ativo financeiro pode ser modelado por meio da função linear de vários fatores macroeconômicos, em que a sensibilidade às mudanças de cada fator é representada por um coeficiente específico referente a cada um deles

inserido no modelo. Dessa forma, a APT é uma combinação linear de diversos fatores, sendo representada pela seguinte equação:

$$R_i = R_f + \beta_1 \lambda_1 + \beta_2 \lambda_2 + \beta_3 \lambda_3 + \dots + \beta_N \lambda_N \quad (3)$$

Onde:

R_i = retorno esperado de um ativo;

R_f = retorno do ativo livre de risco;

β = coeficiente de sensibilidade do ativo i a cada um dos fatores explicativos λ ;

λ_N = N fatores explicativos para o retorno do ativo i ;

A teoria pressupõe que os retornos dos ativos podem ser estimados dependendo de um processo aleatório mostrado por vários fatores de risco incluídos no modelo e deverão afetar os retornos gerados por todos os ativos. Por exemplo, esses múltiplos os fatores de risco podem consistir em inflação, alterações nas taxas de juro, crescimento do PIB ou acontecimentos políticos e económicos, onde se espera que afetem fortemente os retornos de todos os ativos (Elbannan, 2015).

O APT tem duas grandes vantagens frente ao CAPM, sendo elas a exigência de hipóteses menos restritivas para as preferências dos investidores perante risco e retorno e a facilidade com que o modelo pode ser testado empiricamente. Assim, o modelo supõe a não existência de arbitragem e, com isso, coloca-se como uma alternativa ao CAPM, na tentativa de melhor explicar uma relação linear entre os retornos dos ativos e seu respectivo risco. Além disso, o modelo não necessita de algumas hipóteses muito restritivas existentes no CAPM, como, por exemplo, a exigência sobre a distribuição dos retornos dos ativos ou a estrutura de preferências dos indivíduos. A hipótese de equilíbrio, tão cara ao modelo do CAPM, não permanece no APT, que continua a valer mesmo em condições de desequilíbrio na economia, desde que tal situação não crie oportunidades de arbitragem (Leal, 2004, p. 2).

2.3.3 Modelo de 5 fatores

Também críticos de um modelo de fator único, Fama e French (1992, 1993), em seus estudos durante a década de 1990, propuseram o uso de um modelo de 3 fatores para explicar o retorno esperado das ações em *cross-sectional*.

O primeiro dos fatores, assim como o CAPM, trata do excesso de retorno da carteira de mercado de referência em relação ao ativo livre de risco, denominado de fator de mercado no

CAPM. Tendo investigado de forma recorrente o uso do CAPM, Fama e French (2016) relatam que, em média, 70% dos retornos esperados em uma carteira diversificada podem ser explicados pelo fator de mercado, e os outros 30% podem ser atribuídos a outros fatores.

Ao fator de mercado foram acrescentados outros dois fatores, quais sejam: um que diz respeito à diferença entre o retorno da carteira de ações de empresas pequenas (aquelas que apresentam baixo valor de mercado) e grandes (empresas de alto valor de mercado), denominado de fator tamanho – *Small Minus Big* (SMB); e outro que se refere à diferença entre os retornos da carteira formada por ações de empresas com alta capitalização e da carteira de empresas de baixa capitalização (utilizando como *proxy* o índice *Book-to-Market*, ou seja, a razão entre o valor contábil e o valor de mercado, conhecido como *High Minus Low* [HML]), como apresentado a seguir:

$$R_i = R_f + \beta(R_m - R_f) + s(\text{SMB}) + h(\text{HML}) \quad (4)$$

Onde:

R_i = retorno esperado de um ativo;

R_f = retorno do ativo livre de risco;

R_m = taxa esperada de retorno sobre o portfólio geral do mercado;

$(R_m - R_f)$ = taxa de prêmio relativo ao risco de mercado;

SMB: prêmio pelo fator tamanho;

HML: prêmio pelo fator *Book-to-Market*;

β , s , h = representam as sensibilidades em relação aos fatores mercado, tamanho e valor contábil/valor de mercado, respectivamente.

Em diversos estudos, podem ser encontrados outros fatores capazes de influenciar a precificação. Importa mencionar que foram identificadas, ainda, evidências de que o retorno das ações está relacionado com o índice *Book-to-Market*, e que rentabilidade e investimento acrescentam poder explicativo à descrição fornecida pelo índice (Drew, 2003; Gaunt, 2004; Titman, Wei & Xie, 2004; Novak & Petr, 2011; Novy-Marx, 2013).

O fato de essas variáveis estarem relacionadas com o retorno acionário pode ser explicado por meio do modelo de desconto de dividendos. De acordo com o referido modelo, o valor de uma ação é o valor presente dos dividendos esperados, descontados a uma taxa capaz de refletir seu nível de incerteza. Isso tem se apresentado como um desafio à identificação de *proxies* empíricas para a expectativa de lucros futuros e investimentos previstos.

Do ponto de vista teórico, o principal defeito do modelo trifatorial está em sua motivação empírica. Os retornos explicados por SMB e HML não são motivados por previsões a respeito de variáveis de estado de interesse dos investidores. Pelo contrário, são construtos brutos que têm por objetivo captar a maneira como o retorno médio das ações varia com o porte e com o índice *Book-to-Market* (Fama & French, 2007, p. 113).

Testes empíricos em diversas bolsas de valores representam a superioridade do poder explicativo do modelo de 3 fatores sobre o CAPM. No entanto, resultados heterogêneos também podem ser encontrados, uma vez que a seleção de portfólio desempenha um papel crucial nos testes. Depois de publicar seu modelo inovador de três fatores, Fama e French continuaram suas pesquisas, a fim de explicarem melhor o retorno esperado das ações (Blanco, 2012).

Resultados controversos levaram os referidos autores a examinarem uma versão aumentada do modelo de 3 fatores, em que foram incluídos mais dois fatores, como já mencionado: um de rentabilidade, e outro de investimento, dando origem ao chamado modelo de 5 fatores (Fama & French, 2016).

Em 2016, Fama e French apresentaram uma nova composição de seu modelo de precificação, com a inclusão de dois novos fatores, a saber: *Robust Minus Weak* (RMW), que é a diferença entre retorno de empresas de alta e baixa rentabilidade, e *Conservative Minus Agressiva* (CMA), que se refere à diferença do retorno entre empresas de alto e baixo investimento. A equação do modelo é apresentada a seguir:

$$R_i = R_f + \beta(R_m - R_f) + s(\text{SMB}) + h(\text{HML}) + r(\text{RMW}) + c(\text{CMA}) \quad (5)$$

Onde:

R_i = retorno esperado de um ativo;

R_f = retorno do ativo livre de risco;

R_m = taxa esperada de retorno sobre o portfólio geral do mercado;

$(R_m - R_f)$ = taxa de prêmio relativo ao risco de mercado;

SMB: prêmio pelo fator tamanho;

HML: prêmio pelo fator *Book-to-Market*;

RMW: prêmio pelo fator rentabilidade;

CMA: prêmio pelo fator investimento;

β , s , h , r , c = representam as sensibilidades em relação aos fatores.

Estudos sobre este modelo no Brasil não são consensuais sobre o sinal esperado dos fatores, além do retorno de mercado (onde é esperado um sinal positivo). São encontradas na literatura justificativas como a existência de alta taxa de juros, incerteza econômica, falta de maturidade no mercado de capitais de países emergentes e incerteza política (Ruiz, 2015, Vieira, et al, 2017, Quinteiro, Medeiros, & Niyama, 2020; Moreira, et al, 2021)

Alguns dos estudos realizados utilizando o modelo de 5 fatores têm seus resultados descritos no Quadro 3, apresentado a seguir:

Quadro 3 – Estudos utilizando o Modelo de 5 fatores

Foye (2018)	Julho/1997 – Junho/2016	<p>O estudo avalia o desempenho do modelo de 5 fatores de Fama-French na explicação dos retornos das ações em 18 países, em três regiões diferentes. A metodologia envolve a classificação de ações por tamanho e a formação de 32 carteiras ponderadas por valor. O modelo de cinco fatores e o modelo de três fatores são comparados em termos de capacidade explicativa dos retornos das ações.</p> <p>Os resultados mostram que na Europa e nas Américas, o modelo de cinco fatores supera consistentemente o modelo de três fatores. No entanto, na Ásia, isso não ocorre. Além disso, os autores observam que os fatores de investimento e rentabilidade são essenciais para explicar a variação transversal nos retornos das ações, e que o modelo de cinco fatores tem um grande poder de fixação de preços nos mercados em desenvolvimento.</p>
Moreira, Penedo, Pereira e Ambrozini (2021)	2006-2017	<p>Análise da relação entre crises econômicas e a precificação de ativos no mercado de capitais brasileiro, utilizando o modelo de cinco fatores de Fama e French. A metodologia utilizada foi a análise de dados de empresas listadas na B3 em diferentes períodos, incluindo pré-crise internacional, crise internacional, pós-crise internacional, recessão nacional e geral.</p> <p>Os resultados obtidos mostraram que o modelo de cinco fatores se ajusta bem ao mercado de capitais brasileiro e que a rentabilidade foi estatisticamente significativa e com sinal positivo em quatro dos cinco períodos analisados. Além disso, foi observado que a relação entre os fatores e o retorno das ações das empresas varia de acordo com o período analisado.</p>

<p>Maciel, Correia, Amaral e Cavalcanti (2021)</p>	<p>Junho/2000 – Junho/2017</p>	<p>Examina o desempenho do modelo de cinco fatores de Fama e French no mercado de ações brasileiro e o compara aos modelos de 3 e 4 fatores, determinando se tamanho, índice book-to-market, momento, lucratividade e investimento estão relacionados aos prêmios de risco. Foi utilizado o método de Fama e MacBeth. Os resultados das regressões do primeiro estágio sugerem que o modelo de cinco fatores explica melhor os retornos das ações em comparação aos demais. Contudo, as regressões do segundo estágio não incluíram a rentabilidade e investimento aos prêmios de risco, visto que não apresentaram significância estatística. Apenas os riscos de mercado, tamanho e índice book-to-market explicaram consistentemente o retorno transversal das ações</p>
--	--------------------------------	---

Fonte: Elaborado pela autora (2023).

Do mesmo modo que a identificação e validação empírica de fatores capazes de explicar o retorno acionário sempre desafiou pesquisadores, investidores e analistas do mercado, a previsão do retorno acionário apresenta-se como um desafio ainda maior.

2.4 DMA

Os modelos de previsão podem estar sujeitos a quebras estruturais e a outras fontes de instabilidade nos parâmetros. Consequentemente, a influência exercida por diferentes variáveis ou preditores pode variar com o tempo. Essas características podem ser tratadas por meio de modelos de parâmetros variáveis no tempo (TVPs), a saber:

$$\begin{aligned}
 y_t &= z_t \theta_t + \varepsilon_t \\
 \theta_t &= \theta_{t-1} + \eta_t.
 \end{aligned}
 \tag{6}$$

Onde:

y_t = variável dependente;

$z_t = [1, x_{t-1}, y_{t-1}, \dots, y_{t-p}]$ é $1 \times m$ vetor de preditores;

$\theta_t = [\phi_{t-1}, \beta_{t-1}, \gamma_{t-1}, \dots, \gamma_{t-p}]$ é um $m \times 1$ vetor de coeficientes;

ε_t, η_t = termos de erro.

A primeira equação permite que um modelo mais eficiente seja adotado em cada período t , dado que nesse período são exploradas e incorporadas, nos modelos, as informações do período $t - 1$.

$$y_t = \sum_{j=1}^m s_j \theta_{jt} z_{jt} + \varepsilon_t \quad (7)$$

Onde:

$\theta_{jt} z_{jt} = j^{\text{iésimos}}$ elementos de $\theta_t z_t$;

$s_j \in \{0,1\}$ = determina a inclusão do parâmetro, se $s_j = 1$, e a exclusão, se $s_j = 0$.

Os modelos de TVPs tradicionais não permitem que as variáveis explicativas utilizadas no modelo de previsão possam ser modificadas ao longo do período utilizado. O fator determinante da inclusão de cada preditor é a chave da formação do modelo, pois permite que cada preditor seja incluído, se $s_j = 1$, e excluído, se $s_j = 0$. Além disso, se o número de variáveis explicativas for grande, esses modelos tendem a apresentar previsões fracas (Koop & Korobilis, 2012).

Ao partirem da dificuldade de determinação das variáveis de entrada e da identificação do melhor modelo de previsão, Raftery, Kárný e Ettlér (2010) desenvolveram um método denominado de DMA. Este considera a incerteza em relação aos modelos mediante a ponderação bayesiana, admitindo que os parâmetros e os pesos da ponderação podem sofrer alterações a cada período de tempo. Dessa forma, os parâmetros do modelo acompanham a dinâmica da série ao longo do tempo, permitindo um melhor ajuste.

O método foi inicialmente desenvolvido para solucionar o problema de previsão da espessura da tira de saída de uma laminação a frio, onde a saída era medida com um atraso de tempo. Verificou-se que o método foi capaz de convergir rapidamente para o melhor modelo, sendo que o custo da incerteza se mostrou baixo, apresentando melhor desempenho do que o mais eficiente modelo físico.

Diante dos resultados obtidos, a metodologia foi utilizada em diversas áreas do conhecimento, como mostra o Quadro 4:

Quadro 4 – Estudos recentes com a aplicação do DMA em diversas áreas do conhecimento

Título	Objetivo	Resultados
<i>Forecasting carbon emissions with dynamic model averaging approach: time-varying evidence from China.</i> Xu, Zhang e Chen (2020).	Investigar a capacidade preditiva de 15 indicadores de nível macro para a emissão de dióxido de carbono na China com a utilização do DMA.	Os resultados empíricos mostraram que o poder explicativo de cada preditor não energético mudou significativamente com o tempo. O DMA produziu as previsões mais precisas de emissão de carbono na China em comparação com outros métodos de previsão comumente utilizados.
<i>Forecasting the Inflation Rate in Poland and U. S. Using dynamic model averaging (DMA) and Google Queries.</i> Drachal (2020).	Aplicar o DMA para modelar a taxa de inflação nos EUA e na Polônia com a análise adicional da utilidade de dados do Google Trends.	Verificou-se que, no caso dos EUA, a metodologia DMA foi bastante útil e produziu previsões mais precisas do que as alternativas. Em particular, todos os recursos de DMA (parâmetros variáveis no tempo, pesos atualizados dinamicamente na média do modelo) melhoraram a qualidade da previsão. Uma análise semelhante para a Polônia não conduziu a tais conclusões. As implicações práticas para esse país são que a taxa de desemprego é o principal motor da inflação. Para os EUA, os impulsionadores consistiram em mudanças no número de novas casas, oferta de dinheiro, preços das ações, preços da energia, produção industrial, nível de taxa de juros de curto prazo, rendimento de títulos do governo de longo prazo e <i>spread</i> de longo prazo.
<i>Forecasting the Spread of the COVID-19 Epidemic in Lombardy: A Dynamic Model Averaging Approach.</i> Gianmoena e Rios (2021).	Examinar a previsibilidade de casos diários de COVID-19 na região italiana da Lombardia usando os métodos DMA e DMS.	O DMA levou a melhorias preditivas consistentes e substanciais em relação a modelos epidemiológicos alternativos e abordagens de aprendizado de máquina na produção de previsões de curto prazo; forneceu evidências sobre quais conjuntos de preditores são relevantes para a previsão em cada período. Os resultados também sugeriram que futuras incidências podem ser previstas explorando informações sobre a dinâmica da epidemia de regiões vizinhas, padrões de mobilidade humana, poluição e níveis de temperatura.
<i>Investigating the Time-varying Effect of Search Index in Predicting Tourism Volume Using Dynamic Model Averaging.</i> Chen, Ma, Hu, Xiong e Wu (2021).	Construir um modelo de volume de turismo e investigar o efeito variável no tempo dos índices de pesquisa na previsão do volume de turismo.	O índice de pesquisa apresentou características variáveis no tempo, especificamente os índices de pesquisa de hotéis, que apresentaram maiores probabilidades de apoiar a previsão do volume de turismo.
<i>Forecasting Macroeconomic Variables in Emerging</i>	Prever a inflação e o crescimento econômico no Vietnã e comparar seu	Em primeiro lugar, o número e a composição do conjunto de preditores ideais mudaram, indicando mudanças nas relações econômicas

<i>Economies: An Application to Vietnam.</i> Thu e Leon-Gonzalez (2021).	desempenho de previsão com uma ampla gama de outros métodos de série temporal.	ao longo do tempo. Em segundo lugar, o DMA produziu, frequentemente, previsões mais precisas do que outros métodos de previsão, tanto para a inflação quanto para a taxa de crescimento econômico do Vietnã.
--	--	--

Fonte: Elaborado pela autora (2023).

A abordagem desenvolvida por Raftery *et al.* (2010) permite que tanto as variáveis que compõe o modelo de previsão quanto os seus coeficientes possam variar ao longo do tempo. O modelo DMA consiste em duas equações, a saber:

$$\begin{aligned} y_t &= z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \\ \theta_{t+1}^{(k)} &= \theta_t^{(k)} + \eta_t^{(k)} \end{aligned} \quad (8)$$

Onde:

y_t = variável dependente;

$z_t^{(k)} = [1, x_{t-1}, y_{t-1}, \dots, y_{t-p}]$ é $1 \times m$ vetor de preditores;

$\theta_t^{(k)} = [\phi_{t-1}, \beta_{t-1}, \gamma_{t-1}, \dots, \gamma_{t-p}]$ é um $m \times 1$ vetor de coeficientes;

O sobrescrito $k = 1, \dots, K$ representa um conjunto específico de preditores. Se existem m variáveis explicativas, podem existir $k = 2^m$ modelos diferentes de previsão. Dessa forma, tanto o vetor de variáveis explicativas (aplicável também a qualquer subconjunto) quanto o vetor de coeficientes são diferentes para cada modelo e em cada período t . Isso possibilita às variáveis e aos seus respectivos parâmetros modificarem-se ao longo do tempo, compondo novos modelos mais eficientes.

Considerando $\varepsilon_t^{(k)} \in N(0, H_t^{(k)})$, $\eta_t^{(k)} \in N(0, Q_t^{(k)})$ e $L_t \in \{1, 2, \dots, K\}$, é possível inferir qual modelo se aplica a cada período de tempo. Ao prever variáveis de tempo t usando informação ao longo do tempo $t - 1$, o DMA envolve o cálculo $\Pr(L_t = k | y^{t-1})$ para $k = 1, \dots, K$, obtendo a média das previsões entre os modelos por meio dessas probabilidades.

Estima-se, assim, a probabilidade de cada modelo k . O resultado preditivo é encontrado por meio da média ponderada de todos os modelos obtidos e suas respectivas probabilidades. A previsão através do DMA é calculada de acordo com a seguinte equação:

$$y_t^{DMA} = \sum_{j=1}^K s_{jt} y_{jt} + \varepsilon_t \quad (9)$$

Onde:

y_t^{DMA} = variável dependente prevista;

y_{jt} = previsões provenientes de modelos diferentes;

s_{jt} = pesos variáveis associados a cada período da previsão;

ε_t = termo de erro.

A eficiência das previsões realizadas pelo DMA depende da escolha de dois fatores de esquecimento, que determinam a velocidade em que os preditores são alterados. O primeiro deles controla a velocidade de adaptação do vetor de coeficientes de cada modelo linear, enquanto o segundo permite a variação de tempo no estágio de média do modelo.

A modelagem DMA tornou-se uma ferramenta muito útil para lidar com aspectos importantes da análise de séries temporais, como no caso de uma possível instabilidade dos parâmetros ao longo do tempo, bem como em quebras estruturais (Dong & Yoon, 2019).

Koop e Korobilis (2012) argumentam que, ajustando ligeiramente a estrutura original de Raftery *et al.* (2010), é possível melhorar o método, de forma que este possa se ajustar aos padrões tipicamente observados em dados econômicos e financeiros.

Salienta-se que o modelo pode apresentar um bom desempenho em aplicações econômicas, especialmente na previsão de inflação, preços e outras variáveis econômico-financeiras. Nota-se que o método passou a ser amplamente utilizado, tendo como destaque estudos com o objetivo de prever preços, conforme o Quadro 5:

Quadro 5 – Aplicação do DMA com a utilização de dados econômicos e financeiros

Título	Objetivo	Resultados
<i>Forecasting the European carbon Market.</i> Koop e Tole (2013).	Modelar os preços das permissões para emitir dióxido de carbono.	Há fortes evidências de que há turbulência e mudança substanciais nos mercados de carbono. Entretanto, o DMA conseguiu modelar essas características e fazer previsões com precisão em comparação com outras abordagens utilizadas.
<i>Forecasting the Price of Gold Using Dynamic Model Averaging.</i> Aye, Gupta, Hammoudeh e Kim (2015).	Desenvolver diversos modelos para examinar possíveis preditores do retorno do ouro.	Comparando modelos preditivos alternativos, os modelos de média do modelo dinâmico (DMA) e seleção de modelo dinâmico (DMS) superam os modelos lineares (como o passeio aleatório), bem como o modelo de média do modelo bayesiano (BMA). O DMS apresentou-se como o melhor modelo preditivo geral em todos os horizontes de previsão na precificação do ouro.

<p><i>Forecasting copper prices with dynamic averaging and selection models.</i></p> <p>Buncic e Moretto (2015).</p>	<p>Utilizar dados da <i>London Metal Exchange</i> (LME) para prever os retornos mensais do cobre, usando os modelos dinâmicos DMA e DMS.</p>	<p>Utilizando um total de 18 variáveis preditoras, constatou-se que existe um componente preditivo considerável em retornos de cobre. Entretanto, as variáveis preditoras mais relevantes mudaram substancialmente durante o período analisado.</p>
<p><i>Forecasting house prices using dynamic model averaging approach: Evidence from China.</i></p> <p>Wei e Cao (2017).</p>	<p>Prever a taxa de crescimento dos preços da habitação em 30 grandes cidades chinesas por meio da utilização do DMA.</p>	<p>No geral, o DMA superou outros modelos, como a média do modelo bayesiano (BMA), a média do modelo teórico da informação (ITMA) e a média ponderada igual (EW), nos modos de previsão recursiva e contínua. Além disso, nos últimos anos, descobriu-se que o índice de pesquisa do Google, em vez de indicadores macroeconômicos ou monetários fundamentais, desenvolveu maior poder preditivo para o preço das casas na China.</p>
<p><i>Forecasting prices of selected metals with Bayesian data-rich models.</i></p> <p>Drachal (2019b).</p>	<p>Aplicar vários esquemas de combinação de modelos para a previsão de preços à vista de metais.</p>	<p>Os preços (<i>spot</i>) de chumbo, níquel e zinco foram analisados utilizando dados mensais de 1996 a 2017. O DMS apresentou resultados superiores ao DMA.</p>
<p><i>Point and density forecasts of oil returns: The role of geopolitical risks.</i></p> <p>Plakandaras, Gupta e Wong (2019).</p>	<p>Examinar a relação dinâmica entre os preços do petróleo e os índices baseados em notícias de riscos geopolíticos globais (GPRs), bem como uma medida composta para economias emergentes, usando a modelagem DMA.</p>	<p>Os GPRs globais associados a guerras foram mais precisos na previsão dos retornos do petróleo em curto prazo; enquanto os GPRs compostos, provenientes dos mercados emergentes, previram os retornos do petróleo relativamente melhores em horizontes de médio a longo prazo. No entanto, diferenças entre os modelos lineares e não lineares que incorporam informações de GPRs não foram significativas.</p>
<p><i>Analysis of Agricultural Commodities Prices with New Bayesian Model Combination Schemes.</i></p> <p>Drachal (2019a).</p>	<p>Analisar os preços de três <i>commodities</i> agrícolas (trigo, milho e soja), realizando previsões com um mês de antecedência, utilizando o DMA.</p>	<p>A análise foi feita com base nos dados mensais de 1976 a 2016, e sugeriu que o DMA consiste em um modelo com resultados interessantes, pois a interpretação dos pesos variáveis no tempo evidencia que o desenvolvimento econômico das economias emergentes do BRICs (Brasil, Rússia, Índia e China) é um dos mais importantes impulsionadores dos preços de <i>commodities</i> agrícolas.</p>
<p><i>Forecasting Art Prices with Bayesian Models.</i></p> <p>Drachal, Deepmala e Mishra (2021).</p>	<p>Identificar potenciais preditores do preço de bens de arte, tais como: índices do mercado de ações, outros preços de <i>commodities</i>, taxas de câmbio, PIB, renda disponível, consumo, taxas de juros, etc.</p>	<p>A metodologia baseou-se no BMA e no DMA, aplicáveis em caso de incerteza sobre os preditores adequados. Os preços de vários tipos de bens de arte foram analisados. Os resultados sugeriram que o mercado de arte é bastante complexo e, mesmo no caso de incluir muitos preditores, é difícil de ser modelado. No entanto, verificou-se que o DMA superou o BMA.</p>

Fonte: Elaborado pela autora (2023).

O desempenho do DMA depende criticamente da escolha apropriada de dois fatores de esquecimento. O primeiro deles controla a velocidade de adaptação do vetor de coeficientes de cada modelo linear, enquanto o segundo permite a variação de tempo no estágio de média do modelo (Yusupova, Pavlidis, & Pavlidis, 2019).

A vantagem do DMA é que este método permite que ambos os conjuntos de preditores (modelos de previsão), bem como seus coeficientes, mudem ao longo do tempo. Os modos de previsão são recursivos e contínuos. Ao comparar o desempenho do DMA com outros modelos de previsão tradicionais, como modelos autorregressivos, aquele geralmente apresenta um desempenho superior a estes (Koop & Korobilis, 2012).

3 METODOLOGIA

A proposta de pesquisa orientou-se para um estudo exploratório, conforme preconizado por Martins (2002). dado que há pouco conhecimento acumulado e sistematizado sobre a capacidade preditiva dos modelos de precificação de ativos. Utiliza-se o método hipotético-dedutivo, pois são buscadas regularidades e relacionamentos causais entre os elementos da pesquisa. (Chaves, 2007)

Assim, o presente trabalho adota uma abordagem quantitativa, reconhecida por sua natureza objetiva e sistemática em relação à pesquisa qualitativa. A pesquisa quantitativa centra-se na coleta e análise de dados numéricos e estatísticos, operando por meio de um processo metódico que abrange a formulação de hipóteses, a coleta de dados, a análise estatística e a interpretação dos resultados. (Becker, 1993)

Após a coleta de dados, procedeu-se à análise utilizando técnicas estatísticas, visando identificar padrões e relações entre as variáveis. Os resultados obtidos foram interpretados com o intuito de atender aos objetivos estabelecidos para a pesquisa. Cumpre ressaltar que o tratamento estatístico dos dados foi conduzido por meio do *software* Eviews 12. Essa ferramenta proporcionou uma abordagem eficaz para a análise estatística dos dados coletados, contribuindo para a confiabilidade e a robustez dos resultados apresentados.

3.1 FONTE DE DADOS E AMOSTRA

A amostra deste estudo abrange todas as empresas com ações negociadas na B3, no período de 2007 a 2021, excluindo os ativos de empresas do setor financeiro. Esse intervalo de tempo foi subdividido em três partes, cada uma associada a uma crise específica. O primeiro período compreende dados de janeiro de 2007 a novembro de 2011, englobando a crise do *Subprime*, em 2008. O segundo período utiliza dados de janeiro de 2012 a dezembro de 2016, coincidindo com a crise político-econômica de 2014-2016. O terceiro se estende de janeiro de 2017 a dezembro de 2021, abrangendo a crise desencadeada pela pandemia de Covid-19. A definição desses períodos visou otimizar a amostra, garantindo, ao mesmo tempo, a inclusão da quantidade mínima recomendada de observações temporais para a construção dos modelos econométricos adotados neste estudo e a realização dos testes correspondentes.

Os dados dos ativos utilizados para formar as carteiras foram coletados no banco de dados da Economática® e ajustados pelos proventos e pela inflação nos respectivos períodos.

Na composição da amostra, foram incluídas as empresas que realizaram suas ofertas públicas iniciais antes do primeiro mês de cada período. A liquidez dos ativos foi um critério crucial na seleção das ações, resultando na exclusão daquelas que não apresentaram cotação de preço de fechamento na última semana de cada mês durante o período estudado, devido à limitação no cálculo do retorno mensal.

Os ativos incluídos na amostra também foram restritos àquelas com dados de Valor de Mercado (VM), Patrimônio Líquido (PL) positivos, Ativo Total e Valor de Lucro Operacional (LO), disponíveis em 31 de dezembro de cada ano da amostra. Portanto, foram utilizadas ações de 116 empresas no primeiro período de estudo, 159 empresas no segundo e 164 empresas no terceiro período.

Em um primeiro momento, foi realizada a sistematização e padronização dos dados, incluindo o cálculo do retorno, a deflação e a compatibilização da periodicidade dos dados. Por fim, foram conduzidos testes para verificar a existência de raízes unitárias nas séries temporais.

3.2 FORMAÇÃO DE CARTEIRAS

Muitos investidores mantêm participações substanciais em ações individuais e podem ser impactados por mudanças tanto no nível da indústria quanto na volatilidade idiossincrática, que influenciam as ações de maneira específica. Determinados eventos podem afetar ações individuais de maneira diferenciada, e a significância estatística dos retornos anormais relacionados a esses eventos é determinada pela volatilidade dessas ações (Campbell, Lettau, Malkiel, & Xu, 2001).

O risco idiossincrático, caracterizado por fatores microeconômicos que afetam a ação e seu negócio subjacente, tem pouca ou nenhuma associação com fatores macroeconômicos mais amplos, como o risco de mercado. Por outro lado, as forças macroeconômicas impactam conjuntos mais amplos da economia como um todo.

O escopo deste estudo não visou analisar o impacto do risco idiossincrático, e sim o impacto das crises nos ativos como um todo. Portanto, optou-se pela formação de carteiras diversificadas no mercado acionário brasileiro. Uma carteira com mais de 19 ativos é considerada suficientemente diversificada e, seguindo essa premissa, foram compostos 60 portfólios de forma aleatória, cada um contendo 25 ativos, em cada um dos períodos de pesquisa (Farias & Moura, 2014; Martins & Gava, 2010; Oda, Senger, & Chára, 1998; Santiago & Leal, 2015).

Cada ativo na carteira teve seu retorno calculado por meio de capitalização contínua, conforme a equação a seguir, seguido pela obtenção do retorno médio de cada portfólio:

$$R_{i,t} = \ln\left(\frac{P_{i,t}}{P_{i,t-1}}\right) = \ln P_{i,t} - \ln P_{i,t-1} \quad (10)$$

Onde:

$R_{i,t}$ = o retorno da ação i no período t ;

$P_{i,t}$ = o preço da ação i no período t ; e

$P_{i,t-1}$ = o preço da ação i no período $t-1$.

Sendo dado como retorno da carteira, o retorno médio dos 25 ativos pertencentes a cada um dos 60 portfólios. Com relação ao retorno de cada um dos 60 portfólios, foi deduzida a taxa livre de risco local, utilizando o Certificado de Depósito Interbancário (CDI) como *proxy*. Esse processo foi repetido em cada um dos três períodos da amostra. Essas carteiras foram consideradas como a variável dependente tanto no modelo de 5 fatores quanto no modelo APT.

3.3 TRATAMENTO ECONOMETRICO

Ressalta-se que, para a estimativa dos modelos econométricos, foi adotada a metodologia de dados em painel, com o objetivo de analisar a capacidade explicativa do modelo APT e do modelo de 5 fatores.

As regressões *Seemingly Unrelated Regressions With Identical Regressors* (SUR) consistem em um modelo de dados em painel que permite estimar múltiplas equações simultaneamente, sendo que cada equação tem o mesmo conjunto de regressores, mas com variáveis dependentes e potencialmente diferentes. Esse modelo é chamado de "aparentemente não relacionado" porque as variáveis dependentes podem parecer não relacionadas nas equações à primeira vista. Todavia, uma consideração mais cuidadosa permite concluir que, de fato, elas estão relacionadas. Ressalta-se que o método SUR pode tratar da heteroscedasticidade. Ademais, em função dos resultados obtidos, optou-se pela estimação de todos os modelos através do referido método (Brooks, 2008).

Existem três maneiras principais de realizar regressões com dados em painel, quais sejam: regressão agrupada (*pooled*), modelo de efeitos fixos e modelo de efeitos aleatórios.

A regressão *pooled* consiste em uma regressão simples com todas as observações temporais empilhadas em uma única coluna de dados, pressupondo que os valores médios das variações e as relações entre elas são constantes ao longo do tempo e em todas as unidades transversais da amostra.

Por sua vez, o modelo de efeitos fixos sustenta que as relações podem variar de maneira diferente para indivíduos e/ou variações ao longo do tempo em seus interceptos, capturando a heterogeneidade não observada entre esses indivíduos, constante ao longo do tempo.

O modelo de efeitos aleatórios, assim como os de efeitos fixos, permite intercepções específicas do indivíduo, mas também possibilita a correlação das intercepções dele com os regressores. Esse modelo assume que os interceptos específicos do indivíduo são extraídos de uma distribuição comum, estimada juntamente com os demais parâmetros do modelo (Brooks, 2008).

Em um primeiro momento, foram realizados testes para identificação da metodologia de dados em painel mais adequada a cada um dos modelos, em cada um dos períodos. Posteriormente, a capacidade preditiva desses modelos foi testada por meio da metodologia DMA. Em seguida, os testes de robustez foram apresentados.

3.4 ESPECIFICAÇÃO DOS MODELOS A SEREM UTILIZADOS

3.4.1 O Modelo de 5 fatores de Fama e French (2016)

➤ Modelo de 5 fatores

O modelo de 5 fatores será testado segundo a metodologia proposta por Fama e French (2015), como mostra a equação a seguir:

$$R_{i,t} - R_{f,t} = \alpha + \beta(R_{m,t} - R_{f,t}) + s(SMB_t) + h(HML_t) + r(RMW_t) + c(CMA_t) + \varepsilon_{i,t}, \quad (11)$$

Onde:

$R_{i,t}$ = retorno mensal dos portfólios;

$R_{f,t}$ = retorno mensal do ativo livre de risco local em cada mês;

α = intercepto da regressão;

β = coeficiente angular da reta de regressão;

$R_{mL,t}$ = retorno mensal do Ibovespa;

s = coeficiente angular da reta de regressão;
 SMB_t = prêmio pelo fator tamanho no mês t ;
 h = coeficiente angular da reta de regressão;
 HML_t = prêmio pelo fator índice *book-to-market* no mês t ;
 RMW = prêmio pelo fator rentabilidade no mês t ;
 CMA = prêmio pelo fator investimento no mês t ;
 β, s, h, r, c = coeficiente angular da reta de regressão, representando as sensibilidades em relação aos fatores;
 $\varepsilon_{i,t}$ = resíduos da regressão.

Conforme apresentado no modelo, foi regredido o excesso do retorno das carteiras em relação ao ativo livre de risco e o excesso de retorno do mercado em relação ao ativo livre de risco, valendo ressaltar que a mesma metodologia foi utilizada para o modelo de 5 fatores e também para o APT.

➤ Metodologia para definição de carteiras e cálculo dos fatores

Fama e French (2015) delineiam três metodologias ligeiramente distintas para a composição das carteiras nos cálculos dos fatores HML, RMW e CMA. Essas metodologias são conhecidas pelas formas 2 x 2, 2 x 3 e 2 x 2 x 2 x 2. Neste estudo, optou-se pela forma 2 x 2, a qual classifica as empresas em dois grupos por porte e dois grupos por fator de risco, ambos determinados pela mediana.

De acordo com Quinteiro *et al.* (2020), os autores não identificaram diferenças significativas nos resultados do estudo entre as três abordagens. Além disso, a escolha da forma 2 x 2 implica não descartar parte da amostra, resultando em um cálculo dos fatores com um número maior de empresas em comparação com as outras duas abordagens. Isso contribui para minimizar a variância das carteiras base do estudo, especialmente no contexto brasileiro, considerando o menor número de empresas listadas em relação ao mercado norte-americano.

➤ Fator retorno de mercado

O prêmio relativo ao risco de mercado, é dado pela a diferença entre a taxa de retorno sobre a carteira de mercado e a taxa que remunera o ativo livre de risco. Foi utilizado no presente estudo o índice IBOVESPA como *proxy* da carteira de mercado (Retorno de mercado), a taxa real do CDI empregado como ativo livre de risco do mercado acionário brasileiro.

➤ **Fator porte (tamanho pelo valor de mercado)**

O fator SMB representa o prêmio pelo fator porte, e sua determinação envolve o tamanho da empresa, calculado com base em seu *Market Value* (MV). Assim, para estabelecer o porte de cada empresa na amostra, utiliza-se o MV da empresa no encerramento do exercício do ano anterior. A classificação do porte de cada empresa é realizada anualmente ao longo dos períodos de estudo. Se o MV for maior ou igual à mediana dos MVs de todas as empresas da amostra, essas são classificadas como grandes (B); se for inferior à mediana, são classificadas como pequenas ou *small* (S).

Posteriormente, realiza-se o cálculo do fator SMB. Para cada mês nos períodos estudados, a média dos retornos das empresas classificadas como pequenas (S) é subtraída da média dos retornos das empresas classificadas como grandes ou *big*s (B), com base na classificação realizada para o ano correspondente ao mês em questão, conforme preconizado por Fama e French (2015).

➤ **Fator Valor (patrimônio líquido / valor de mercado)**

O fator HML representa o prêmio pelo fator valor, e sua determinação envolve a relação *book-to-market* (PL/VM), obtida pela divisão do Patrimônio Líquido (PL) pelo Valor de Mercado da empresa (VM).

Para avaliar o valor de cada empresa na amostra, assim como no cálculo do fator SMB, considerou-se cada ano dos períodos estudados, utilizando como referência o *book-to-market* da empresa, no encerramento do exercício do ano anterior (PL/VM).

Foram aproveitadas as classificações realizadas na metodologia de cálculo do fator SMB. Inicialmente, concentrou-se no subconjunto das empresas anteriormente classificadas como S em cada ano. Essas empresas são subdivididas em dois grupos: as de alto valor (SH), caso o *book-to-market* (PL/VM) seja maior ou igual à mediana do subconjunto, e as de baixo valor (SL), quando ocorre o contrário.

Dessa forma, seguiu-se, nesta pesquisa, o mesmo procedimento para o subconjunto de empresas anteriormente classificadas como B, subdividindo-as em BH e BL. Assim, foi possível levantar, para cada ano dos períodos estudados, as empresas da amostra classificadas e subdivididas nos seguintes subconjuntos:

- Grandes de alto valor (classificação BH).
- Grandes de baixo valor (classificação BL).
- Pequenas de alto valor (classificação SH).

→ Pequenas de baixo valor (classificação SL).

Diante disso, iniciou-se a análise com o cálculo do fator HML. Para cada mês nos períodos examinados, procedeu-se ao cálculo das médias dos retornos para quatro subconjuntos de empresas: BH, BL, SH e SL.

O fator HML, em cada mês dos períodos estudados, é determinado pela diferença entre a média dos valores calculados anteriormente para os subconjuntos de empresas grandes e pequenas de alto valor (BH e SH, respectivamente) e a média dos valores, também calculados anteriormente, para os subconjuntos de empresas grandes e pequenas de baixo valor (BL e SL, respectivamente), conforme proposto por Fama e French (2015).

Fama e French (2015) observaram uma dependência do fator HML em relação às variáveis do Modelo de Cinco Fatores (RMW e CMA), o que levou à consideração de sua redundância. Como solução, propuseram o cálculo da variável *HML Ortogonal* (HMLO) por meio de regressão linear, tendo HML como variável dependente e as demais variáveis do modelo no lado direito da equação como variáveis explicativas (RM, SMB, RMW e CMA).

Em consonância com as recomendações de Quinteiro *et al.* (2020), que constataram a inexistência de mudanças significativas nos resultados ao adotar HML ou HMLO, optou-se, neste estudo, por manter a versão HML nos modelos subsequentes.

➤ **Fator Rentabilidade (lucro / patrimônio líquido)**

O fator de Rentabilidade (lucro/patrimônio líquido) é fundamental para compreender o desempenho das empresas. O fator RMW representa o prêmio associado à rentabilidade. Para calcular a rentabilidade de uma empresa, divide-se o lucro (L) pelo patrimônio líquido (PL).

A avaliação da rentabilidade de cada empresa na amostra, semelhante aos fatores anteriormente descritos, foi feita observando os períodos estudados, anualmente. Assim, utilizou-se como referência L e PL da empresa no encerramento do exercício do ano anterior (L/PL).

Neste ponto, foram incorporadas as classificações estabelecidas na metodologia de cálculo do fator SMB. Inicialmente, concentrou-se no subconjunto de empresas da amostra previamente classificadas como S a cada ano. Essas empresas são categorizadas como de alta rentabilidade ou robustas (SR) se a rentabilidade (L/PL) for maior ou igual à mediana das rentabilidades do subconjunto, ou de baixa rentabilidade ou fraca (SW) se ocorrer o contrário. O mesmo processo foi aplicado ao subconjunto de empresas classificadas anteriormente como B: anualmente, são classificadas como de alta rentabilidade ou robustas (BR) se a rentabilidade

(L/PL) for maior ou igual à mediana das rentabilidades do subconjunto, ou de baixa rentabilidade ou fraca (BW), se ocorrer o contrário.

Consequentemente, para cada ano relativo aos períodos estudados, foram levantadas as empresas da amostra classificadas e subdivididas nos seguintes subconjuntos:

- Grandes de alta rentabilidade (classificação BR).
- Grandes de baixa rentabilidade (classificação BW).
- Pequenas de alta rentabilidade (classificação SR).
- Pequenas de baixa rentabilidade (classificação SW).

Avançou-se, dessa forma, para o cálculo do fator RMW. Para cada mês nos períodos analisados, as médias dos retornos para cada subconjunto de empresas obtido foram calculadas: empresas de classificações BR, BW, SR e SW.

Assim, o fator RMW, para cada mês nos períodos estudados, é determinado pela média dos valores calculados anteriormente para os subconjuntos das empresas grandes e pequenas de alta rentabilidade ou robustas (BR e SR, respectivamente), subtraída da média dos valores calculados para os subconjuntos das empresas grandes e pequenas de baixa rentabilidade ou fracas (BW e SW, respectivamente), conforme proposto por Fama e French (2015).

➤ **Fator Investimento (total de ativos)**

O fator CMA é o prêmio pelo fator investimento. Para determinar o investimento de cada empresa da amostra, utilizou-se como referência a variação do total de ativos da empresa no encerramento do exercício do ano anterior (VA). A variação foi calculada, para cada empresa, subtraindo o total de ativos de 2 anos anteriores do total de ativo no ano anterior.

Foram aproveitadas também as classificações realizadas na metodologia de cálculo do fator SMB. Desse modo, em um primeiro momento, considerou-se somente o subconjunto das empresas da amostra classificadas anteriormente como S, a cada ano, sendo classificadas como de alto investimento ou simplesmente agressiva (SA), se a variação do total de ativos fosse maior ou igual à mediana das variações dos totais de ativos (VA) das empresas do subconjunto considerado; ou de baixo investimento ou simplesmente conservadora (SC), se prevalecesse o contrário.

Procedeu-se da mesma forma para o subconjunto de empresas da amostra classificadas anteriormente como B: a cada ano, foram classificadas como de alto investimento ou simplesmente agressiva (BA), se a variação do total de ativos (VA) fosse maior ou igual à

mediana das variações dos totais de ativos das empresas do subconjunto considerado; ou de baixa investimento ou simplesmente conservador (BC), se ocorresse o inverso.

Com isso, obteve-se, para a cada ano dos períodos estudados, as empresas da amostra classificadas e subdividas nos seguintes subconjuntos:

- Grandes de alto investimento (classificação BA).
- Grandes de baixo investimento (classificação BC).
- Pequenas de alto investimento (classificação SA).
- Pequenas de baixo investimento (classificação SC).

Partiu-se, assim, para o cálculo o fator CMA. Para cada mês dos períodos estudados, foram calculadas as médias dos retornos relativas a cada um dos subconjuntos de empresas. Dessa forma, o fator CMA consistiu na média dos valores calculados anteriormente para os subconjuntos das empresas grandes e pequenas de alto investimento ou agressivas (BA e AS, respectivamente) menos a média dos valores, também calculados anteriormente, para os subconjuntos das empresas grandes e pequenas de baixo investimento ou conservadoras (BC e SC, respectivamente), como mostram Fama e French (2015).

3.4.2 APT

A estimação do modelo APT foi conduzida mediante a incorporação de fatores macroeconômicos e variáveis que refletem o sentimento do investidor, incluindo aquelas associadas a momentos de crise, todos previamente determinados. O objetivo foi o de identificar fatores que impactam as carteiras de forma abrangente. As variáveis utilizadas estão detalhadas no Quadro 6, a seguir:

Quadro 6 – Variáveis a serem incluídas no modelo APT

Variável	Fonte	Descrição
Retorno de mercado - R_m	ECONOMÁTICA	Retorno da <i>proxy</i> de retorno do mercado local (IBOVESPA) deflacionado
Taxa Livre de risco - R_f	ECONOMÁTICA	CDI deflacionado
Índice de Atividade Econômica - IBCBR	BCB	O IBC-Br é construído com base em proxies representativas dos índices de volume da produção da agropecuária, da indústria e do setor de serviços, além do índice de volume dos impostos sobre a produção. Sendo utilizada a variação percentual do IBCBR

Dólar Comercial - D	BCB	Varição percentual na cotação mensal do Dólar
Ouro - O	BCB	Varição percentual na cotação mensal do Ouro
Importações - I	IPEA	Varição percentual no volume de importações brasileiras
Exportações - E	IPEA	Varição percentual no volume de exportações brasileiras
Produto Interno Bruto - PIB	BCB	Varição percentual do PIB real
<i>Commodities</i> - Petróleo - PPET	IPEA	Varição percentual no preço de petróleo
Inflação – IPCA	BCB	Inflação mensal
Índice de Produção Industrial - IPI	IBGE	Calculado por meio de metodologia baseada no conceito de valor adicionado bruto. Especificamente, o índice é construído agregando dados sobre a produção de uma série de bens industriais, tais como máquinas, equipamentos e bens de consumo, num único índice composto.
<i>Emerging Markets Bond Index</i> – EM	JP Morgan	O <i>Emerging Market Bond Index</i> é um índice de referência que mede o desempenho dos títulos de países emergentes e suas respectivas organizações corporativas.
<i>Dummy</i> de Crise - DCRISE	-	Variável binária, que assume o valor 1 em períodos de crise
Índice de Confiança Empresarial - ICE	FGV	agregação ponderada dos índices de confiança sem ajuste sazonal dos quatro setores pesquisados pela FGV: Indústria de Transformação, Serviços, Comércio e Construção.
Índice de Situação Atual Empresarial - ISAESP	FGV	agregação ponderada dos índices de situação atual/expectativas sem ajuste sazonal dos quatro setores pesquisados pela FGV: Indústria de Transformação, Serviços, Comércio e Construção.
Índice de Confiança do Consumidor - ICC	FGV	Tem como objetivo identificar o sentimento dos consumidores levando em conta suas condições econômicas atuais e suas expectativas quanto à situação econômica futura, e é baseado em uma pesquisa mensal com aproximadamente 2.000 domicílios em sete grandes cidades brasileiras.
Índice de Expectativas Empresarial Com Ajuste Sazonal - IEESP	FGV	Retrata a percepção em relação ao momento atual e o grau de otimismo em relação ao futuro próximo (três a seis meses), de quatro setores pesquisados pela FGV: Indústria de Transformação, Serviços, Comércio e Construção (Varição Percentual em Relação ao Período Anterior)
<i>Brazil News Economic Policy Uncertainty</i> - BNEPU	EPU	São utilizados arquivos de texto do jornal Folha de São Paulo. Em cada mês, o

		número de artigos que contêm os termos "incerto" ou "incerteza", "econômico" ou "economia", e um ou mais dos seguintes termos relevantes para a política: regulação, déficit, orçamento, imposto, banco central, alvorada, planalto, congresso, senado, câmara dos deputados, legislação, lei, tarifa é contado. Para obter a taxa EPU, dimensionamos as contagens brutas pelo número de todos os artigos no mesmo jornal e mês. (Baker, Bloom, & Davis, 2016)
<i>Forecast Disagreement Uncertainty Indicator - FDC</i>	EPU	Indicador baseado no coeficiente de variação derivado das expectativas de especialistas sobre três variáveis econômicas, com informações retiradas do Relatório Focus, publicado pelo Banco Central do Brasil. (Costa et al, 2019)
<i>Daily Infectious Disease Equity Market Volatility Tracker - DINF</i>	EPU	Indicador construído de acordo com a metodologia de Baker, Bloom, Davis e Kost (2019) trata-se de um rastreador de volatilidade do mercado de ações em função de doenças infecciosas, tendo como base a repercussão na mídia (Baker, Bloom, & Davis, 2019)
Indicador de Incerteza da Economia Brasileira - IIEB	FGV	Ponderação entre o Indicador de Incerteza na Mídia (IIE-Br-Mídia) e o Indicador de Dispersão de Expectativas (IIE-Br-Expectativa):
Indicador de Incerteza da Economia Brasileira-Media Component - MC	FGV	Reflete a incidência de termos relacionados à incerteza em artigos publicados em seis dos principais jornais do país. Aproximadamente 30 mil notícias são analisadas por mês.
Indicador de Dispersão de Expectativas - IIE	FGV	Elaborado com base na dispersão das previsões de especialistas para três variáveis macroeconômicas: taxa de câmbio e Selic, 12 meses à frente e o IPCA acumulado para os próximos 12 meses
Dívida Pública - DP	IPEA	Variação da Dívida Pública brasileira

Fonte: Elaborado pela autora (2023).

Conforme destacado por Roll e Ross (1980), que conduziram testes empíricos do modelo APT com o propósito de determinar quantos fatores seriam necessários para explicar os retornos das ações no mercado norte-americano, a aplicação da análise fatorial revelou que, para a maioria dos grupos, aproximadamente cinco fatores eram capazes de oferecer uma explicação satisfatória.

Para a seleção das variáveis a serem incorporadas ao modelo APT, adotou-se a abordagem de regressão *stepwise*. Esta técnica, caracterizada pela adição e remoção interativa

de variáveis, visa identificar o subconjunto que resulta no desempenho ótimo do modelo. Nesse contexto, optou-se pela estratégia de seleção reversa. O modelo se inicia com todas as variáveis e, como consequência, as de menor contribuição ou não significativas são removidas.

O modelo inicialmente proposto é composto pelas variáveis presentes no quadro anterior. Após a estimação de cada um dos modelos, em que as variáveis apresentadas serão inseridas na regressão, foram realizados testes e ajustes necessários para identificar e eliminar a existência de multicolinearidade entre as variáveis. Entretanto, após análise dos resultados prévios, foram definidas três versões do modelo APT, uma para cada subperíodo da amostra.

O modelo definido para o período referente a crise de 2008 é representado por:

$$R_{i,t} - R_{f,t} = \alpha + \beta_1(R_{m,t} - R_{f,t}) + \beta_2(PIB_t) + \beta_3(EM_t) + \beta_4(MC_t) + \beta_5(ICC_t) + \varepsilon_{i,t} \quad (12)$$

Onde:

$R_{i,t}$ = retorno do portfólio em cada mês;

$R_{f,t}$ = retorno do ativo livre de risco em cada mês;

α = intercepto da regressão

β = coeficiente angular da reta de regressão;

$R_{m,t}$ = retorno da carteira de mercado em cada mês;

PIB_t = variação percentual do PIB, no mês t;

EM_t = *Emerging Markets Bond Index*, no mês t;

MC_t = Indicador de Incerteza da Economia Brasileira (*Media Component*), variação no mês t;

ICC_t = Índice de Confiança do Consumidor, variação no mês t;

$\varepsilon_{i,t}$ = resíduos da regressão

Já modelo utilizado para o período referente crise política de 2016, segue descrito a seguir, com a alteração de variáveis em relação ao modelo anterior:

$$R_{i,t} - R_{f,t} = \alpha + \beta_1(R_{m,t} - R_{f,t}) + \beta_2(PIB_t) + \beta_3(BNEPU_t) + \beta_4(ISAESP_t) + \beta_5(FDC_t) + \varepsilon_{i,t} \quad (13)$$

Onde:

$R_{i,t}$ = retorno do portfólio em cada mês;

$R_{f,t}$ = retorno do ativo livre de risco em cada mês;

α = intercepto da regressão

β = coeficiente angular da reta de regressão;

$R_{m,t}$ = retorno da carteira de mercado em cada mês;

PIB_t = variação percentual do PIB, no mês t;

$BNEPU_t$ = *Brazil News Economic Policy Uncertainty*, variação percentual no mês t;

$ISAESP_t$ = Índice de Situação Atual Empresarial, variação no mês t;

FDC_t = *Financial Stress Indicator*, variação no mês t;

$\varepsilon_{i,t}$ = resíduos da regressão

O modelo adotado para o subperíodo referente a crise gerada pela Covid-19, também apresentou alterações nas variáveis do modelo, se comparado aos dois modelos anteriores, e é apresentado como:

$$R_{i,t} - R_{fL,t} = \alpha + \beta_1(R_{m,t} - R_{f,t}) + \beta_2(PIB_t) + \beta_3(DINF_t) + \beta_4(IEESP_t) + \beta_5(PET_t) + \varepsilon_{i,t} \quad (14)$$

Onde:

$R_{i,t}$ = retorno do portfólio em cada mês;

$R_{f,t}$ = retorno do ativo livre de risco em cada mês;

α = intercepto da regressão

β = coeficiente angular da reta de regressão;

$R_{m,t}$ = retorno da carteira de mercado em cada mês;

PIB_t = variação percentual do PIB, no mês t;

$DINF_t$ = *Daily Infectious Disease Equity Market Volatility Tracker*, variação percentual no mês t;

$IEESP_t$ = Índice de Expectativas Empresarial Com Ajuste Sazonal, variação no mês t;

PET_t = variação percentual do preço do Petróleo, no mês t;

$\varepsilon_{i,t}$ = resíduos da regressão

A análise das regressões estimadas, se dará através do teste F e do R^2 . O teste F na análise de regressão testa a significância geral de um conjunto de variáveis independentes em um modelo de regressão. O teste F é usado para determinar se o modelo de regressão como um todo é estatisticamente significativo e se as variáveis independentes em conjunto têm um efeito significativo sobre a variável dependente. A estatística F segue uma distribuição F de Fisher-

Snedecor, sob a hipótese nula de não haver relação significativa entre as variáveis independentes e a variável dependente. Já o R^2 é utilizado na análise de regressão, como uma medida da qualidade do ajuste de um modelo de regressão. O R^2 representa a proporção da variação total da variável dependente que é explicada pelas variáveis independentes do modelo. O R^2 varia de 0 a 1, sendo que valores maiores indicam melhor ajuste do modelo aos dados. (Greene, 2018)

3.4.3 Quebra estrutural e teste de Quandt-Andrews

As quebras estruturais possuem implicações significativas na estimação e interpretação de modelos de regressão. Caracterizada por uma mudança abrupta na relação entre duas variáveis. A quebra estrutural pode ser desencadeada por diversos fatores, como alterações na política econômica, eventos históricos ou mudanças tecnológicas. Dado o enfoque deste estudo em períodos de crise, optou-se por realizar o teste de Quandt-Andrews, a fim de verificar a presença de quebras estruturais, além de conduzir regressões com a inclusão de variáveis *dummy* nos períodos de crise (Wooldridge, 2002).

O teste Quandt-Andrews é um teste não paramétrico e não requer suposições sobre a distribuição dos dados. O teste envolve dividir os dados da série temporal em duas subamostras e estimar modelos de regressão separados para cada subamostra. A estatística de teste é então calculada como a razão entre a soma dos resíduos quadrados da regressão da amostra completa e a soma dos resíduos quadrados das duas regressões de subamostra. A estatística de teste segue uma distribuição F sob a hipótese nula de não haver quebra estrutural. O teste é particularmente útil, pois não existe a necessidade de identificação do período em que ocorreu a possível quebra estrutural (Greene, 2018).

3.4.4 Estacionariedade das séries

Uma série estacionária pode ser definida como aquela com média e variância constantes ao longo do tempo. O teste Dickey-Fuller é um teste estatístico usado para determinar se uma série temporal é estacionária ou não. Se a estatística de teste for menor que o valor crítico, rejeitamos a hipótese nula e concluímos que a série temporal é estacionária. (Wooldridge, 2002, Brooks, 2008).

Séries não-estacionárias não são adequadas para a realização de regressões, sob o risco da obtenção de regressões espúrias. Se fazem necessárias medidas para torná-las estacionárias antes de prosseguir com as análises. Dessa forma, o presente estudo já utilizou todas as variáveis em primeira diferença.

Em um segundo momento, foi realizado o teste de Dickey-Fuller aumentado (ADF) para cada *pool* de dados. Ao garantir que as variáveis sejam estacionárias, é possível obter estimativas confiáveis dos coeficientes e fazer inferências válidas sobre a relação entre as variáveis.

3.4.5 Testes de robustez

➤ Autocorrelação dos resíduos

Na busca por resultados robustos, é imperativo considerar a autocorrelação dos resíduos em um modelo de regressão. A autocorrelação indica a presença de correlação entre os termos de erro, o que pode comprometer a validade das conclusões retiradas do modelo de regressão linear. Quando os resíduos são autocorrelacionados, os coeficientes estimados e os erros padrão podem ser viesados ou ineficientes, resultando em inferências imprecisas (Wooldridge, 2002).

O teste Durbin-Watson é uma ferramenta estatística relevante para identificar a autocorrelação nos resíduos de uma análise de regressão. Essa estatística, variando de 0 a 4, com o valor 2 indicando a ausência de autocorrelação, possui dois valores críticos: dL (limite inferior) e dU (limite superior), determinados pelo número de variáveis independentes k' na regressão (Brooks, 2008).

Valores menores que 2 sugerem autocorrelação positiva, enquanto valores maiores indicam autocorrelação negativa. Para um modelo de 5 fatores, como no caso do APT, os valores de referência para ausência de autocorrelação situam-se entre 1,72 e 2,28. Portanto, uma estatística de Durbin-Watson dentro desse intervalo aponta para a ausência de evidências de autocorrelação nos resíduos da regressão. Caso o resultado esteja entre 1,62 e 1,72 ou 2,28 e 2,38, o teste apresenta um resultado inconclusivo. A análise criteriosa desses resultados é fundamental para assegurar a confiabilidade e a solidez das conclusões derivadas do modelo.

➤ **Multicolinearidade**

A multicolinearidade surge quando duas ou mais variáveis independentes em um modelo de regressão estão altamente correlacionadas entre si, representando um fenômeno que pode impactar adversamente a qualidade da análise. Esse fenômeno pode resultar em dificuldades na estimação dos coeficientes de regressão e erros padrão, tornando-os espúrios, comprometendo a interpretação dos resultados (Wooldridge, 2002, Brooks, 2008).

A presença de multicolinearidade torna desafiador discernir os efeitos individuais de cada variável independente sobre a variável dependente. Isso ocorre porque os coeficientes de regressão tornam-se instáveis e altamente sensíveis a pequenas variações nos dados, prejudicando a confiabilidade das conclusões extraídas (Gujarati, 2006)

Nesse contexto, o Fator de Inflação da Variância (VIF) destaca-se como uma medida estatística essencial para detectar a presença de multicolinearidade em um modelo de regressão. O cálculo do VIF é dado por:

$$VIF = \frac{1}{(1-R^2)} \quad (15)$$

Onde:

VIF= Fator de Inflação da Variância;

R^2 = coeficiente de correlação entre cada regressor e os demais.

O cálculo do VIF é realizado para cada combinação de variáveis independentes no modelo de regressão. Uma das vantagens notáveis da utilização do VIF é sua capacidade de oferecer uma medida quantitativa da magnitude da multicolinearidade em um modelo. Quando o VIF atinge até 4, há indicativo de ausência de multicolinearidade prejudicial ao modelo. Por outro lado, um VIF superior a 4 sugere a presença de multicolinearidade (Wooldridge, 2002; Brooks, 2008).

➤ **Heteroscedasticidade**

A heteroscedasticidade, um conceito estatístico, refere-se à situação em que a variância dos erros (resíduos) em um modelo de regressão não se mantém constante entre as observações. Em termos mais simples, a variabilidade dos erros altera-se à medida que os valores das variáveis independentes se modificam. Essa condição pode resultar em estimativas enviesadas

ou ineficientes dos coeficientes de regressão, impactando a validade dos testes de hipóteses e a construção do intervalo de confiança (Wooldridge, 2002, Brooks, 2008).

Nesse contexto, o teste Breusch-Pagan emerge como uma ferramenta estatística essencial para identificar a presença de heteroscedasticidade em um modelo de regressão. Sua aplicação consiste na regressão dos resíduos quadrados do modelo de regressão original nas variáveis independentes correspondentes. Caso a variância dos resíduos esteja associada às variáveis independentes, o teste revelará a presença de heteroscedasticidade. Esse procedimento visa proporcionar uma avaliação rigorosa da adequação do modelo, contribuindo para a confiabilidade das conclusões derivadas da análise de regressão (Gujarati, 2006).

➤ Normalidade dos resíduos

A verificação da normalidade dos resíduos constitui um pressuposto crucial nos modelos de regressão linear, assegurando que os erros se distribuam aleatoriamente, sem viés em direção a qualquer valor específico. Essa premissa é fundamental para a validade de testes de hipóteses e a construção de intervalos de confiança. No âmbito deste estudo, a avaliação da normalidade dos resíduos baseou-se no teste de Jarque-Bera.

A distribuição normal ou gaussiana caracteriza-se por uma curva em forma de sino, simétrica em torno da média. Na econometria e na estatística, a normalidade dos resíduos implica que esses erros, ou resíduos, em um modelo de regressão, sigam uma distribuição normal, com média zero (0) e variância constante. Os resíduos representam as discrepâncias entre os valores reais da variável dependente e aqueles previstos com base nas variáveis independentes do modelo (Wooldridge, 2002, Brooks, 2008).

O teste de Jarque-Bera configura-se como ferramenta diagnóstica fundamental na estimação de modelos de regressão, permitindo a avaliação da normalidade dos resíduos. Caso os resíduos apresentem uma distribuição normal, isso mostra que o modelo se ajusta adequadamente aos dados, conferindo confiabilidade aos coeficientes estimados. No entanto, se a distribuição dos resíduos não for normal, há indicativo de que o modelo pode estar mal especificado, comprometendo a confiabilidade dos coeficientes estimados, tornando-os passíveis de viés ou ineficiência (Gujarati, 2006).

3.5 DMA

A avaliação da capacidade preditiva dos modelos de precificação foi conduzida empregando o método DMA. Como destacado por Bortoluzzo, et al (2016), a análise do poder preditivo revelou um ganho significativo na qualidade preditiva ao optar por modelos multifatoriais em contraste com o modelo de fator único. Nessa perspectiva, tanto o modelo de 5 fatores quanto o APT atendem a essa especificação.

O modelo DMA, inicialmente proposto por Raftery *et al.* (2010) e aprimorado posteriormente por Koop e Korobolis (2012), permite a variação ao longo do tempo tanto das variáveis que compõem o modelo de previsão quanto de seus coeficientes. Esse modelo é composto por duas equações a serem aplicadas, a saber:

$$\begin{aligned} r_t &= z_t^{(k)} \theta_t^{(k)} + \varepsilon_t^{(k)} \\ \theta_{t+1}^{(k)} &= \theta_t^{(k)} + \eta_t^{(k)} \end{aligned} \tag{16}$$

Onde:

r_t = retorno em excesso esperado do portfólio;

$z_t^{(k)} = [1, x_{t-1}, y_{t-1}, \dots, y_{t-p}]$ é $1 \times m$ vetor de preditores do retorno acionário;

$\theta_t^{(k)} = [\phi_{t-1}, \beta_{t-1}, \gamma_{t-1}, \dots, \gamma_{t-p}]$ é um $m \times 1$ vetor de coeficientes;

ε_t = termo de erro.

O sobrescrito $k = 1, \dots$, representa o conjunto específico de preditores que compõe os modelos. As variáveis explicativas adotadas neste estudo incluem aquelas presentes nos dois modelos selecionados: APT e o modelo de 5 fatores. Nesse sentido, tanto o vetor de variáveis explicativas (aplicável também a qualquer subconjunto) quanto o vetor de coeficientes são distintos para cada modelo e em cada período t . Essa diferenciação permite que as variáveis e seus parâmetros correspondentes variem ao longo do tempo, possibilitando a combinação de variáveis e a geração de novos modelos mais eficientes.

Dessa forma, a probabilidade de cada modelo k é estimada. O resultado preditivo é obtido por meio da média ponderada de todos os modelos obtidos e suas respectivas probabilidades. A previsão utilizando o DMA é calculada de acordo com a seguinte equação:

$$y_t^{DMA} = \sum_{j=1}^K s_{jt} y_{jt} + \varepsilon_t \quad (17)$$

Onde:

y_t^{DMA} = retorno previsto da carteira de ativos;

y_{jt} = previsões dos retornos provenientes dos modelos;

s_{jt} = pesos variáveis associados a cada período da previsão;

ε_t = termo de erro.

Uma das vantagens notáveis do emprego do DMA neste estudo reside na flexibilidade oferecida para que os coeficientes dos fatores nos modelos de precificação possam variar ao longo do tempo. Essa característica possibilita a captura de mudanças rápidas, especialmente em momentos de crise. Outra vantagem importante é a capacidade de lidar com um elevado número de preditores potenciais.

Tanto o modelo APT quanto o modelo de 5 fatores permitem a inclusão de inúmeras variáveis para explicar o retorno dos ativos. O DMA, por sua vez, permite que os fatores relevantes para a previsão variem ao longo do tempo, como é o caso do conjunto de preditores para os retornos acionários, que pode ter diferido durante o período definido na amostra. Assim, é possível obter modelos que se destacam em determinados momentos, mas que não são tão eficazes em outros. Consequentemente, um modelo de previsão com fatores distintos, sejam simples, sejam complexos, pode ser válido em diferentes pontos no tempo.

O desempenho do DMA está intrinsecamente ligado à escolha criteriosa de dois fatores de esquecimento. O primeiro deles controla a velocidade de adaptação do vetor de coeficientes de cada modelo linear, enquanto o segundo possibilita a variação temporal no estágio de média do modelo (Yusupova *et al.*, 2019).

Conforme essa metodologia, é necessário definir um valor para o fator de esquecimento: λ ($0 < \lambda \leq 1$). Esse valor determina a rapidez com que o modelo e seus preditores evoluem, esquecendo fatores com um ritmo relativamente lento ($\lambda > 0,99$), resultando em modelos mais estáveis, ou esquecendo fatores com um ritmo relativamente rápido ($\lambda < 0,90$), gerando modelos mais inconstantes.

Dessa forma, foram adotados dois parâmetros de esquecimento: $\lambda = 0,99$ e $\lambda = 0,90$. Buscou-se, identificar a alternância das variáveis e encontrar um modelo com o menor erro de previsão, conforme mostrado nas pesquisas de Yusupova *et al.* (2019).

As projeções feitas com a utilização do DMA contemplaram os três subperíodos da amostra, e foram feitas projeções utilizando o modelo de 5 fatores e o APT conforme a especificação apresentada na seção anterior, as previsões foram feitas para 2 meses, imediatamente posteriores aos períodos de crise, a título de comparação, também foram feitas previsões para os mesmos meses do ano anterior à crise, tendo como objetivo a análise entre esses resultados.

Importa destacar que a aplicação da modelagem DMA não se restringe à previsão do retorno acionário, podendo ser estendida a diversas séries temporais, com aplicações econômicas ou não, como na previsão de volatilidade, nos preços de imóveis, petróleo e *commodities* de câmbio.

3.5.1 Root Mean-Square Error (RMSE)

O *Root Mean-Square Error* (RMSE) ou Raiz do Erro Quadrático Médio é uma medida da precisão de um modelo de previsão, e é frequentemente utilizada para comparar o desempenho de diferentes modelos. O RMSE é uma medida de erro que leva em consideração tanto a magnitude quanto a direção dos erros, tornando-se uma medida mais robusta do que outras medidas de erro, como o Erro Médio Absoluto (MAE).

O RMSE é calculado através a raiz quadrada da média dos erros quadráticos entre as previsões do modelo e os valores reais da série temporal, conforme descrito na fórmula abaixo:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (18)$$

Onde:

$\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n$ = valores previstos (valores esperados)

y_1, y_2, \dots, y_n = valores observados

n = número de observações

Quanto menor o RMSE, melhor será o ajuste do modelo na previsão de valores futuros. Ao calcular esta medida para dois ou mais métodos de previsão, deve ser adotado o método com o menor RMSE fora da amostra. (WOOLDRIDGE,2002, BROOKS,2008)

4 RESULTADOS

Nessa seção são apresentados os resultados da pesquisa. Em um primeiro momento, foram realizados testes de para identificar a existência de alguma quebra estrutural em algum dos subperíodos da amostra. A quebra estrutural refere-se a uma situação em que a relação entre a variável dependente e as variáveis independentes num modelo muda ao longo do tempo devido a alterações na estrutura econômica subjacente (GRENNE, 2018). De acordo com os resultados dos testes de Quandt-Andrews, não foram encontradas evidências de quebra estrutural em nenhum dos três períodos estudados. Acredita-se que por se tratarem de séries de retorno acionário, ocorreram apenas choques nos períodos de crise.

Em um segundo momento, foram realizados os testes de Redundância dos efeitos fixos e o teste de Hausman com a intenção de identificar o melhor modelo: efeitos fixos, efeitos aleatórios ou *pooled*. Os resultados levaram a estimações utilizando o método *pooled*, e os resultados são apresentados a seguir.

4.1 RESULTADO DAS REGRESSÕES DO MODELO DE 5 FATORES

Nessa seção, são apresentados os resultados das regressões com a utilização do modelo de 5 fatores de Fama e French (2015). Como a amostra foi subdividida em três períodos, serão apresentados dados sobre cada um dos períodos, além da reestimação com a inserção de uma variável *dummy* referente ao período em que cada uma das crises ocorreu.

As análises das regressões têm seu início na verificação dos resultados do teste F, este é utilizado para testar a hipótese geral de que os verdadeiros coeficientes dos ângulos parciais são simultaneamente iguais a zero. A hipótese nula do teste afirma que os coeficientes são todos iguais a zero (Gujarati, 2006). Se a hipótese não for rejeitada, significa que a relação entre as variáveis dependentes e independentes se deve a um componente aleatório, já a rejeição da hipótese nula representa de fato um efeito das variáveis independentes sobre a variável dependente.

Vale enfatizar que, conforme é preconizado pela teoria do CAPM, em sua forma tradicional, a variável retorno de mercado apresentou significância estatística ao nível de 1% e demonstrou estar positivamente correlacionada com o retorno das carteiras em todos os modelos e durante todos os períodos.

4.1.1 Desempenho do modelo de 5 fatores durante a Crise de 2008

A crise de 2008, causada pela bolha imobiliária (*subprime*) dos EUA, causou uma crise de confiança no sistema financeiro, tendo um impacto significativo na economia global. A tabela 1 apresenta a performance do modelo de 5 fatores durante o período da crise de 2008 como é mostrado a seguir:

Tabela 1 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2007 à 2011

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
Crise de 2008	α	-0.004447	0.003530	-1.259834	0.2078	3600	0.803959	0.000000
	$\beta_1 (R_{mL} - R_{fL})$	0.702181	0.068195	10.29660	0.0000			
	<i>s</i> (SMB)	0.340139	0.089223	3.812236	0.0001			
	<i>h</i> (HML)	0.181781	0.078442	2.317397	0.0205			
	<i>r</i> (RMW)	0.233636	0.090793	2.573269	0.0101			
	<i>c</i> (CMA)	0.148844	0.068588	2.170119	0.0301			

Fonte: Elaborado pela autora

A Tabela 1 apresenta os resultados obtidos das regressões para o modelo 5 Fatores, durante o primeiro período da amostra, bem como os coeficientes estimados e as respectivas probabilidades. Em consonância aos resultados de Fama e French (2015), Ruiz (2015) e Moreira et al. (2021) todos os fatores do modelo foram significantes ao nível de 5%. Por se tratar de um período de crise, foi inserida uma variável *dummy* ao modelo e os resultados são apresentados na tabela 2.

Tabela 2 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2007 à 2011 com a variável *dummy*

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
Crise de 2008	α	0.013792	0.009216	1.496554	0.1346	3600	0.8145	0.000000
	$\beta_1 (R_{mL} - R_{fL})$	0.697408	0.065760	10.60532	0.0000			
	<i>s</i> (SMB)	0.324145	0.086314	3.755405	0.0002			
	<i>h</i> (HML)	0.175081	0.075662	2.313988	0.0207			
	<i>r</i> (RMW)	0.128924	0.066759	1.931190	0.0535			
	<i>c</i> (CMA)	0.220224	0.087727	2.510340	0.0121			
	<i>d</i> (CRISE)	-0.021188	0.009950	-2.129468	0.0333			

Fonte: Elaborado pela autora

Na segunda regressão do modelo 5 Fatores, ainda durante o primeiro período da amostra, é possível observar a significância da variável *dummy* (representando um período de crise) ao nível de 5% e apresenta o sinal esperado, dado que uma crise impacta negativamente o retorno das carteiras.

Vale ressaltar também que, a inserção da variável *dummy* foi capaz de melhorar o poder explicativo do modelo de 5 fatores. A regressão anterior apresentava um R^2 igual 0,803, e com a *dummy* passou a representar 0,814.

No que diz respeito às demais variáveis, a variável Rentabilidade (RMW) deixa de ser significativa ao nível de 5% e passa a ser significativa apenas ao nível de 10%. E não são observadas diferenças nos sinais dos coeficientes de cada um dos fatores

4.1.2 Desempenho do modelo de 5 fatores durante a crise política (governo Dilma)

De forma semelhante ao que aconteceu internacionalmente durante a crise de 2008, o Brasil enfrentou dificuldades decorrentes do período de 2014–2016. Uma série de fatores como: a crise fiscal, os escândalos de corrupção e a instabilidade política, indicam que houve um aumento da incerteza econômica durante o referido período e gerando impactos no mercado de capitais brasileiro. Na tabela 3 são apresentados os resultados do modelo de 5 fatores durante este período:

Tabela 3 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2012 à 2016

		Coefficiente	Erro padrão	Estatística t	Prob.	n° de observações	R^2	Prob. Teste F
	α	0.002163	0.002311	0.935691	0.3495			
	$\beta_1 (R_{mL} - R_{fL})$	0.893110	0.053754	16.61467	0.0000			
Crise política	s (SMB)	0.228569	0.059543	3.838695	0.0001	3600	0.8253	0.000000
	h (HML)	0.228569	0.059601	2.161329	0.0307			
	r (RMW)	0.024815	0.032222	0.770133	0.4413			
	c (CMA)	0.056574	0.033730	1.677240	0.0936			

Fonte: Elaborado pela autora

Durante o segundo período de crise, há um pequeno aumento no poder explicativo do modelo. Entretanto, é possível observar uma alteração nas variáveis Rentabilidade e Investimento. A variável Rentabilidade deixa de apresentar significância estatística, e é

observado um p-valor=0,44. Já a variável Investimento passar a ser significativa apenas ao nível de 10%.

Os demais fatores não apresentam alterações de significância ou sinal, e o intercepto da regressão também não apresenta significância estatística, o que é preconizado pela teoria subjacente. A seguir são apresentados os resultados do mesmo modelo com a inserção da variável *dummy*:

Tabela 4 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2012 à 2016 com a variável *dummy*

	Coefficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
α	0.002243	0.002342	0.957539	0.3384			
$\beta_1 (R_{mL} - R_{fL})$	0.892296	0.053882	16.56023	0.0000			
Crise política	<i>s</i> (SMB)	0.229347	0.059645	3.845190	0.0001	3600	0.8253
	<i>h</i> (HML)	0.129356	0.059643	2.168850	0.0302		
	<i>r</i> (RMW)	0.025311	0.032301	0.783585	0.4333		
	<i>c</i> (CMA)	0.056522	0.033723	1.676051	0.0938		
	<i>d</i> (CRISE)	-0.002177	0.010388	-0.209538	0.8340		

Fonte: Elaborado pela autora

Na segunda regressão do modelo 5 Fatores, ainda durante o segundo período da amostra, é possível observar que a variável *dummy* (representando um período de crise) não apresentou significância estatística e praticamente não apresentou alterações em relação ao modelo apresentado anteriormente, não gerando nenhuma alteração na interpretação dos resultados do modelo anterior

4.1.3 Desempenho do modelo de 5 fatores durante a crise da Covid-19

A Crise da Covid-19 teve diversos impactos na economia brasileira e conseqüentemente em seu mercado de capitais. Isso abre precedentes, inclusive, para alterações no comportamento das variáveis do modelo de 5 fatores. Os resultados do desempenho do modelo de 5 fatores são apresentados na tabela a seguir:

Tabela 5 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2017 à 2021

		Coefficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	-0.000501	0.002432	-0.205810	0.8370			
	$\beta_1 (R_{mL} - R_{fL})$	0.893074	0.041343	21.60179	0.0000			
Covid-19	s (SMB)	0.542623	0.077558	6.996396	0.0000	3600	0.8898	0.000000
	h (HML)	-0.251450	0.119322	-2.107329	0.0352			
	r (RMW)	-0.130153	0.110295	-1.180052	0.2381			
	c (CMA)	0.253224	0.102140	2.479173	0.0132			

Fonte: Elaborado pela autora

Ao analisar a regressão referente ao terceiro período de crise, é possível observar uma alteração no sinal da variável HML, que continua significativa ao nível de 5%, porém apresentou um sinal negativo, em contraposição ao sinal apresentado nas regressões anteriores.

A variável Rentabilidade não apresenta significância estatística, e a variável Investimento volta a ser significativa ao nível de 5%.

É possível levantar um questionamento sobre a influência da inflação nas variáveis *Book-to-Market* (Fator Valor) e Rentabilidade, dado que, para seu cálculo são utilizadas informações contábeis das empresas que compõe as carteiras, e não se sabe até que ponto a inflação pode distorcer essas informações, principalmente o valor do Patrimônio Líquido de empresas mais antigas. A tabela 6 mostra os resultados da mesma regressão, porém com a variável *dummy*.

Tabela 6 - Resumo dos resultados estatísticos do modelo de 5 fatores durante o período de 2017 à 2021 com a variável *dummy*

		Coefficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	0.004278	0.002696	1.586685	0.1127			
	$\beta_1 (R_{mL} - R_{fL})$	0.891367	0.038168	23.35394	0.0000			
Covid-19	s (SMB)	0.552716	0.071664	7.712610	0.0000	3600	0.8961	0.000000
	h (HML)	-0.251502	0.110148	-2.283311	0.0225			
	r (RMW)	-0.101530	0.102207	-0.993381	0.3206			
	c (CMA)	0.236775	0.094427	2.507483	0.0122			
	d (CRISE)	-0.013575	0.004242	-3.199917	0.0014			

Fonte: Elaborado pela autora

Assim como na regressão do primeiro período é possível observar a significância da variável *dummy* ao nível de 1%, além de continuar apresentando o sinal esperado, e impactando negativamente o retorno dos ativos. O poder explicativo, representado pelo R^2 do modelo de 5 fatores, apresentou um leve aumento.

Considerando contexto de crise econômica durante os três períodos, pode ser observada a existência de uma relação positiva entre o fator tamanho e o retorno acionário. Esses achados corroboram os estudos Mussa, Famá & dos Santos (2012) e Oliveira, Silva & Martins (2016), que relatam que essa relação ocorre por permitir ao investidor incorrer em menor risco, ao investir em grandes empresas, dado à demonstração da resiliência de grandes empresas ao mercado e à capacidade de sobreviver em períodos de instabilidade econômica.

É possível observar que a capacidade explicativa do modelo de 5 fatores aumentou ao longo dos períodos do estudo e em algumas regressões foi reativa a inclusão da variável *dummy* referente às crises.

4.2 RESULTADO DAS REGRESSÕES DO MODELO APT

Nessa seção são apresentados os resultados das regressões do modelo APT para os três períodos do estudo, também são descritos os resultados dos modelos após a inserção da variável *dummy* referente a cada uma das crises econômicas enfrentadas pelo país durante o período de 2007 à 2021.

4.2.1 Desempenho do modelo APT durante a crise de 2008

Na tabela 7, a seguir, são apresentados os resultados acerca do desempenho do modelo APT durante a crise de 2008:

Tabela 7 - Resumo dos resultados estatísticos do modelo APT durante o período de 2007 à 2011

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	0.035251	0.090071	0.391367	0.6955			
	$\beta_1 (R_{mL} - R_{fL})$	0.676951	0.058928	11.48771	0.0000			
Crise de 2008	β_2 (PIB)	-0.238953	0.090904	-2.628624	0.0086	3600	0.791575	0.000000
	β_3 (EM)	-0.041601	0.008960	-4.642925	0.0000			
	β_4 (MC)	0.098423	0.050920	1.932896	0.0533			
	β_5 (ICC)	-0.130345	0.062057	-2.100412	0.0358			

Fonte: Elaborado pela autora

O PIB é um indicador importante para avaliar o desempenho econômico de qualquer país, já que reflete a produção de bens e serviços e o nível de atividade econômica. Uma variação positiva no PIB indica um crescimento econômico, juntamente com o aumento na produção de bens e serviços. Dessa forma, era esperado que a variável PIB estivesse positivamente correlacionada com o retorno acionário. Entretanto o PIB apresentou significância estatística ao nível de 1%, mas com sinal negativo em seu coeficiente.

A variável MC é um dos componentes do Indicador de Incerteza da Economia Brasileira que reflete a incidência de termos relacionados à incerteza, sendo calculado mensalmente. Valores mais altos indicam maior incidência de termos relacionados à incerteza. Esta variável é utilizada para monitorar a incerteza econômica no país e para identificar possíveis riscos sistêmicos. Desta forma, espera-se uma relação inversa com o desempenho do mercado de capitais brasileiro. Em acordo ao esperado, a variável apresentou significância ao nível de 10%, além do sinal do coeficiente de acordo com o esperado.

A variável EM baseia-se no *Emerging Markets Bond Index*, sendo um índice de referência calculado com base no desempenho de títulos emitidos por governos e empresas de países em desenvolvimento, sendo tratada como uma medida de risco país. Esta variável apresentou significância, ao nível de 1%.

Já o ICC que tem como objetivo identificar a percepção dos consumidores em relação à economia atual e futura, apresentou p-valor inferior a 0,05, porém o sinal do coeficiente é negativo, contrariando a ideia natural de que este indicador deveria se correlacionar positivamente com o mercado. Já na tabela a seguir, são apresentados os resultados após a inserção da variável *dummy*:

Tabela 8 - Resumo dos resultados estatísticos do modelo APT durante o período de 2007 à 2011 com a variável *dummy*

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	0.029086	0.094802	0.306808	0.7590			
	$\beta_1 (R_{mL} - R_{fL})$	0.680093	0.060820	11.18200	0.0000			
Crise de 2008	β_2 (PIB)	-0.238192	0.090957	-2.618729	0.0089	3600	0.791693	0.000000
	β_3 (EM)	-0.040520	0.010355	-3.913083	0.0001			
	β_4 (MC)	0.099492	0.051167	1.944452	0.0519			
	β_5 (ICC)	-0.122942	0.071527	-1.718822	0.0857			
	β_6 (CRISE)	-0.002857	0.013734	-0.208004	0.8352			

Fonte: Elaborado pela autora

Na segunda regressão do modelo do modelo de 5 fatores, ainda para o primeiro período da amostra, é possível observar que a variável *dummy* (representando o momento de crise) não foi estatisticamente significativa e praticamente não apresentou modificações ao modelo apresentado anteriormente, o que não acarreta alterações na interpretação dos resultados. Apenas a variável ICC deixou de apresentar significância ao nível de 5% e passando a 10%.

4.2.2 Desempenho do modelo APT durante a Crise política

A crise político-econômica de 2014-2016 no Brasil, teve início em meados de 2014, ano da eleição de Dilma Rousseff para o seu segundo mandato presidencial. A crise gerou um recuo no Produto Interno Bruto (PIB) por dois anos seguidos. A economia retraiu cerca de 3,5%, em 2015, e 3,3%, em 2016, ano do impeachment da presidente Dilma.

A crise foi agravada por escândalos de corrupção investigados na Operação Lava Jato, após a vitória da presidente Dilma Rousseff em 2014. Além disso, a alta dos preços das commodities, que afetou as exportações brasileiras e foi um dos pilares dessa crise econômica.

Tabela 9 - Resumo dos resultados estatísticos do modelo APT durante o período de 2012 à 2016

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	-0.021146	0.017924	-1.179751	0.2382			
	$\beta_1 (R_{mL} - R_{fL})$	0.962615	0.039632	24.28879	0.0000			
Crise política	β_2 (PIB)	0.103941	0.052725	1.971394	0.0488	3600	0.825298	0.000000
	β_3 (BNEPU)	-0.005746	0.002242	-2.563477	0.0104			
	β_4 (ISAESP)	0.308823	0.124919	2.472194	0.0135			
	β_5 (PPET)	0.029750	0.019456	1.529122	0.1263			

Fonte: Elaborado pela autora

De acordo com os resultados apresentados na tabela anterior, O PIB se mostrou significativo e neste modelo apresentou o sinal do coeficiente em acordo ao esperado corroborando estudos de Miranda e Pamplona (2000), Fifield et al (2002) e Fellet (2016)

A variável ISAESP é um indicador da FGV, importante para medir e avaliar a confiança das empresas em relação à economia, pois reflete a percepção das empresas sobre a situação atual do mercado e suas expectativas para os próximos meses. Uma variação positiva nessa variável pode indicar que as empresas estão mais confiantes em relação à economia, mais propensas a investir, contratar em busca de um melhor desempenho. A variável apresentou significância ao nível de 5% e apresentou sinal positivo conforme esperado.

O BNEPU também se mostrou significativo ao nível de 5%, trata-se de um indicador importante para avaliar a incerteza econômica no Brasil, pois reflete a percepção dos jornalistas e analistas em relação à política econômica do país. Uma variação positiva indica que há uma maior incerteza em relação à política econômica, o que pode afetar negativamente o investimento e o crescimento econômico e conseqüentemente, o retorno acionário.

Tabela 10 - Resumo dos resultados estatísticos do modelo APT durante o período de 2012 à 2016 com a variável *dummy*

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	-0.021412	0.018020	-1.188228	0.2348			
	$\beta_1 (R_{mL} - R_{fL})$	0.961967	0.039890	24.11570	0.0000			
	β_2 (PIB)	0.103949	0.052723	1.971617	0.0487			
Crise política	β_3 (BNEPU)	-0.005710	0.002255	-2.532005	0.0114	3600	0.825322	0.000000
	β_4 (ISAESP)	0.310870	0.125735	2.472416	0.0135			
	β_5 (PPET)	0.030001	0.019534	1.535810	0.1247			
	β_6 (CRISE)	-0.001523	0.010675	-0.142698	0.8865			

Fonte: Elaborado pela autora

Na segunda regressão do modelo do modelo APT, ainda no segundo período da amostra, é possível observar que a variável *dummy* (representando o momento de crise) não foi estatisticamente significativa e praticamente não apresentou modificações ao modelo apresentado anteriormente, o que não acarreta alterações na interpretação de seus resultados.

4.2.3 Desempenho do modelo APT durante a pandemia da Covid-19

A crise causada pela pandemia do Coronavírus, que surgiu em dezembro de 2019 e se tornou uma séria ameaça à saúde das pessoas, bem como à economia. A crise afetou a economia global, com muitos países adotando medidas de isolamento social e fechando suas fronteiras para tentar conter a propagação do vírus. Isso levou a uma queda significativa nos mercados financeiros, com muitas empresas sofrendo perdas e muitos trabalhadores sendo demitidos. No Brasil, a crise do Coronavírus também teve um impacto bastante significativo na economia.

Tabela 11 - Resumo dos resultados estatísticos do modelo APT durante o período de 2017 à 2021

		Coeficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	0.004899	0.003826	1.280560	0.2004			
	$\beta_1 (R_{mL} - R_{fL})$	1.006452	0.044911	22.40975	0.0000			
Covid-19	β_2 (DINF)	-2.24E-05	9.63E-06	-2.329071	0.0199	3600	0.850142	0.000000
	β_3 (IEESP)	0.069479	0.043021	1.614998	0.1064			
	β_4 (PPET)	0.105447	0.054232	1.944366	0.0519			
	β_5 (PIB)	-0.163503	0.095375	-1.714323	0.0866			

Fonte: Elaborado pela autora

A variável DINF é uma medida do impacto dos surtos de doenças infecciosas nos mercados financeiros. O índice se baseia-se num cálculo diário do índice EPU, que mede o nível de incerteza da política económica nos Estados Unidos, e em dados sobre o número de novos casos de COVID-19 nos Estados Unidos, essa variável conseguiu captar o impacto da Covid-19 aqui no Brasil, se mostrando significativa ao nível de 5%.

A variável PPET utilizada neste estudo para representar a variação percentual no preço do petróleo. Essa variável é importante porque o preço do petróleo é um fator que pode influenciar o desempenho do mercado acionário brasileiro, especialmente em momentos de crise. Quando o preço do petróleo sobe, por exemplo, as empresas que atuam no setor de petróleo e gás podem ter um desempenho melhor na bolsa de valores, enquanto outras empresas que dependem de combustíveis fósseis podem ter um desempenho pior. Na regressão do período anterior, a mesma não se mostrou significativa. Entretanto, no período de 2017 à 2021, é significativa ao nível de 10%.

O PIB, por sua vez, também se mostrou significativo ao nível de 10%. Entretanto, apresentou um sinal negativo, contrariando o resultado da regressão do período anterior, onde se mostrou significativa ao nível de 5% e com sinal positivo, sendo que esse resultado é comumente encontrado na literatura acadêmica.

Tabela 12 - Resumo dos resultados estatísticos do modelo APT durante o período de 2017 à 2021 com a variável *dummy*

	Coefficiente	Erro padrão	Estatística t	Prob.	n° de observações	R ²	Prob. Teste F
	α	0.003932	0.003694	1.064608	0.2871		
	$\beta_1 (R_{mL} - R_{fL})$	0.922702	0.056710	16.27041	0.0000		
Covid-19	β_2 (DINF)	-1.02E-05	1.07E-05	-0.959122	0.3376		
	β_3 (IEESP)	0.057092	0.041619	1.371786	0.1702	3600	0.856759
	β_4 (PPET)	0.126052	0.052798	2.387453	0.0170		
	β_5 (PIB)	-0.169329	0.091506	-1.850474	0.0643		
	β_6 (CRISE)	-0.082961	0.036542	-2.270311	0.0232		

Fonte: Elaborado pela autora

Ao inserir a variável *dummy* que reflete a crise gerada pela Covid-19, têm-se duas variáveis independentes medindo um mesmo conceito subjacente. Como resultado, a variável DINF não apresentou significância estatística, após a inserção da variável *dummy*, entretanto a variável ainda terá enfoque nesse estudo, dado que será utilizada na composição do DMA para a realização das previsões.

É observável que a variável retorno de mercado apresentada pelo CAPM tradicional, foi inserida nos dois modelos e nos três subperíodos da amostra e em cada uma das doze regressões, e mostrou-se significativa a 1%, com $p = 0,00$ em todos os casos. Conclui-se então que, esta variável é o principal fator na explicação dos retornos das carteiras. O que é consistente com a maioria dos estudos sobre este assunto, porém não é o único significativo, e outros fatores podem aumentar o poder explicativo. Fama e French (2016) descrevem que, em média, 70% dos retornos esperados em uma carteira diversificada podem ser explicados pelo fator de mercado, e apenas os outros 30% podem ser atribuídos a outros fatores.

De acordo com Leite, Pinto e Klotzle (2016), um modelo multifatorial, que reflete a rentabilidade de portfólios, apresenta seu intercepto, geralmente definido por α , estatisticamente não significativo. Caso sejam obtidos nas estimações dos modelos, uma constante diferente de zero e estatisticamente significativa pode ser um indicativo da omissão de fatores relevantes. Esse resultado serve como um indicador de quão bem especificado o modelo está. Em todas as regressões os resultados não apresentaram interceptos significantes estatisticamente.

Então, têm-se resultados positivos para a utilização do modelo de 5 fatores neste mercado acionário, assim como apontamentos de que as variáveis escolhidas para o modelo APT, são capazes de explicar o retorno dos ativos. É possível observar que a capacidade

explicativa dos dois modelos aumentou ao longo dos períodos pesquisados e em algumas regressões ambos foram reativos a inclusão da variável *dummy* referente a crise.

4.3 RESULTADOS DOS TESTES DE ROBUSTEZ

Os testes de robustez têm grande relevância na análise de regressão, pois permitem identificar os resultados obtidos no modelo de regressão são confiáveis e se as conclusões tiradas do modelo são válidas, além de permitir a identificação e tratamento de possíveis problemas de estimação. Os testes de robustez realizados têm seus resultados apresentados nas próximas seções do presente estudo.

4.3.1 Testes de raiz unitária

A estacionariedade se faz necessária na estimação de regressões. Trata-se de uma propriedade importante em uma série, que indica que a média e a variância da série são constantes ao longo do tempo. Isto significa que a série não mostra tendências ou padrões sistemáticos que mudam ao longo do tempo. A estacionariedade é importante porque evita a ocorrência de regressões espúrias, permitindo uma modelagem mais precisa e confiável das propriedades estatísticas da série.

Tabela 13 - Resultado dos testes de raiz unitária

		Levin, Lin & Chu		ADF		PP-Fisher	
		Estatística	Prob.	Estatística	Prob.	Estatística	Prob.
Crise de 2008	Modelo de 5 fatores	-39.5371	0.0000	1290.90	0.0000	1289.03	0.0000
	APT	-34.4040	0.0000	1199.62	0.0000	1192.21	0.0000
Crise política	Modelo de 5 fatores	-52.7072	0.0000	1796.02	0.0000	1786.73	0.0000
	APT	-47.9281	0.0000	1708.55	0.0000	1740.46	0.0000
Covid-19	Modelo de 5 fatores	-53.6417	0.0000	1891.47	0.0000	2252.98	0.0000
	APT	-52.7296	0.0000	1908.95	0.0000	2256.00	0.0000

Fonte: Elaborado pela autora

Os resultados de rejeição da hipótese nula, ou seja, da existência de um processo não estacionário nas séries do estudo, em cada um dos subperíodos da amostra, estão de acordo com os resultados esperados, dado que todas as séries já se encontram em primeira diferença.

4.3.2 Testes de autocorrelação dos resíduos e heterocedasticidade

Conforme já mencionado na metodologia, a estimação através do método Seemingly Unrelated Regressions With Identical Regressors (SUR), adotado na estimação de todos os modelos do presente estudo, é capaz de suportar heterocedasticidade e autocorrelação dos resíduos, partindo da utilização de uma matriz de covariância robusta aos erros. Apesar disso foram realizados os testes de Breusch-Pagan e Durbin-Watson para testar a heterocedasticidade e autocorrelação dos resíduos, respectivamente. (BROOKS, 2008)

Os valores de referência dos 2 valores críticos para a ausência de autocorrelação no teste de Durbin-Watson com k' igual a 5 são 1,72 e 2,28. Dessa forma, caso a estatística esteja entre 1,72 e 2,28, não existirão evidências de autocorrelação dos resíduos da regressão. Caso o resultado esteja entre 1,62 e 1,72 ou 2,28 e 2,38, o teste apresenta um resultado inconclusivo.

Tabela 14 - Resultado dos testes de Durbin-Watson

		Estatística	k'	dl	du	4-du	4-dl	Conclusão
Crise de 2008	Modelo de 5 fatores	1.924716	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação
	APT	1.852133	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação
Crise política	Modelo de 5 fatores	2.149032	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação
	APT	2.155401	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação
Covid-19	Modelo de 5 fatores	1.721292	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação
	APT	1.905183	5	1.62	1.72	2.28	2.38	Não há evidências de autocorrelação

Fonte: Elaborado pela autora

De acordo com a tabela acima, os resultados dentro dos limites críticos inferior ($dL=1,72$) e superior ($dU=2,28$) evidenciam a não existência de autocorrelação dos resíduos em todos os subperíodos da amostra. Vale ressaltar que os modelos onde foram inseridas as *dummies* de crise não constam na tabela acima, entretanto nenhuma das 12 regressões apresentou evidências de autocorrelação dos resíduos. A seguir são apresentados os resultados dos testes de Breusch-Pagan.

Tabela 15 – Resultados dos testes de Breusch-Pagan

		g.l.	Prob.	Conclusão
Crise de 2008	Modelo de 5 fatores	5	0.172	Os resíduos são Homocedásticos
	APT	5	0.002	Há evidências de Heterocedasticidade
Crise política	Modelo de 5 fatores	5	0.128	Os resíduos são Homocedásticos
	APT	5	0.001	Há evidências de Heterocedasticidade
Covid-19	Modelo de 5 fatores	5	0.000	Há evidências de Heterocedasticidade
	APT	5	0.000	Há evidências de Heterocedasticidade

Fonte: Elaborado pela autora

De acordo com os resultados dos testes de Breusch-Pagan, foram encontradas evidências de heterocedasticidade nas regressões estimadas no primeiro, no segundo e no terceiro subperíodos da amostra, tanto para o modelo de 5 fatores, quanto para o APT. Esse fato justificou a adoção do método SUR no processo de estimação de todas as regressões.

4.3.3 Teste de Multicolinearidade

O teste de multicolinearidade é importante para determinar se duas ou mais variáveis independentes em um modelo de regressão estão correlacionadas, o que pode levar a problemas na estimativa dos coeficientes de regressão e erros padrão, tornando a regressão espúria, além de inviabilizar a interpretação dos resultados da análise (Greene, 2007).

De acordo com Gujarati (2006), pode-se usar o fator de inflação de variância (VIF) como um indicador de multicolinearidade, sendo que quanto maior o valor de VIF, maiores as evidências colinearidade entre as variáveis.

O presente estudo adotou como 4 o valor de referência, sendo esse o valor para que a multicolinearidade não seja prejudicial aos modelos estimados. Seguem abaixo os resultados dos testes de multicolinearidade dos modelos utilizados nesta pesquisa.

Os testes foram realizados considerando os modelos de 5 fatores e APT, para cada um dos períodos estudados. O primeiro período testado engloba a crise do *subprime* de 2008, tendo início em janeiro de 2007 e findando em dezembro de 2011. A tabela a seguir mostra o resultado dos testes de fator de inflação da variância (VIF) para esse período, considerando o modelo de 5 fatores:

Tabela 16 - Resultados dos testes do fator de inflação da variância (VIF) do 1º período da amostra

		$(R_{mL} - R_{fL})$	(SMB)	(HML)	(RMW)	(CMA)
Modelo de 5 Fatores	$(R_{mL} - R_{fL})$	-	1,11	3,47	2,31	1,06
	(SMB)	1,11	-	1,55	1,47	1,03
	(HML)	3,47	1,55	-	2,98	1,34
	(RMW)	2,31	1,47	2,98	-	1,41
	(CMA)	1,06	1,03	1,34	1,41	-

Fonte: Elaborado pela autora

A tabela mostra os valores calculados do fator de inflação da variância entre as 5 variáveis do modelo: fator mercado ($R_{mL} - R_{fL}$), fator tamanho (SMB), fator valor (HML), fator rentabilidade (RMW) e fator investimento (CMA). Os resultados apresentados no período em questão, são inferiores a 4. Com isso, é possível concluir que não há presença de multicolinearidade entre as variáveis inseridas no modelo. Note que há uma colinearidade um pouco maior para as entre variáveis fator rentabilidade (RMW) e de fator valor (HML), e ainda para tais variáveis contra o fator mercado (retorno mercado menos a taxa livre de risco), entretanto ainda se encontram dentro do valor admitido, não comprometendo a rejeição de colinearidade entre as referidas variáveis.

Abaixo segue a tabela com o resultado dos testes de fator de inflação da variância (VIF), ainda para o primeiro período, considerando o modelo APT:

Tabela 17 – Resultados dos testes do Fator de inflação da variância (VIF) DO 1º período da amostra

		$(R_{mL} - R_{fL})$	(PIB)	(EM)	(MC)	(ICC)
APT	$(R_{mL} - R_{fL})$	-	1,10	1,729	1,14	1,08
	(PIB)	1,10	-	1,09	1,08	1,01
	(EM)	1,72	1,09	-	3,14	1,71
	(MC)	1,14	1,08	3,14	-	1,97
	(ICC)	1,08	1,01	1,71	1,97	-

Fonte: Elaborado pela autora

A tabela acima mostra os valores de VIF calculados para as variáveis independentes do modelo APT: fator de mercado ($R_{mL} - R_{fL}$), variação do PIB, risco país (EM), indicador de incerteza econômica (MC) e índice de confiança do consumidor (ICC) - para o primeiro período. É possível notar que, assim como visto no teste de multicolinearidade para as variáveis do modelo de 5 fatores, os valores calculados também ficaram abaixo de 4.

Embora os valores de VIF calculados entre a variável “indicador de incerteza econômica (MC)” e as variáveis de “risco país (EM)” e “índice de confiança do consumidor (ICC)” tenha destoado dos demais, isso não indica presença de colinearidade. Dessa forma, conclui-se que, também não há presença de multicolinearidade entre as variáveis inseridas no modelo APT.

Com isso, verificou-se que não há indicação de multicolinearidade para as variáveis independentes no primeiro período, que engloba a crise dos *Subprime* de 2008, tanto para o modelo de 5 fatores quanto para o modelo APT.

A seguir, é apresentada a análise dos resultados do segundo período da amostra, que engloba a crise política e fiscal do governo da ex-presidente Dilma Rousseff, tendo seu início em janeiro de 2012 e finaliza em dezembro de 2016.

A tabela a seguir mostra os resultados dos testes de fator de inflação da variância (VIF), já para o segundo período, considerando o modelo 5 fatores:

Tabela 18 – Resultados dos testes do fator de inflação da variância (VIF) do 2º período da amostra

	$(R_{mL} - R_{fL})$	(SMB)	(HML)	(RMW)	(CMA)	
	$(R_{mL} - R_{fL})$	-	1,15	3,24	1,02	1,01
	(SMB)	1,15	-	1,02	1,01	1,13
Modelo de 5 Fatores	(HML)	3,24	1,02	-	1,01	1,03
	(RMW)	1,02	1,01	1,01	-	1,41
	(CMA)	1,01	1,13	1,03	1,41	-

Fonte: Elaborado pela autora

Como pode ser notado, a tabela acima mostra os valores de VIF calculados para as variáveis independentes do modelo de 5 fatores para o segundo período estudado. Os valores calculados são todos inferiores a 4, e com isso é possível concluir que não há presença de multicolinearidade entre as variáveis inseridas no modelo. Note que o valor de VIF calculado entre as variáveis fator tamanho (SMB) e fator valor (HML) fica um pouco acima dos demais, entretanto sem comprometer a rejeição de colinearidade entre as referidas variáveis.

Abaixo segue a tabela com o resultado dos testes de fator de inflação da variância (VIF), também considerando o segundo período, porém com a utilização das variáveis do modelo APT:

Tabela 19 – Resultados dos testes do fator de inflação da variância (VIF) do 2º período da amostra

		$(R_{mL} - R_{fL})$	(PIB)	(BNEPU)	(ISAESP)	(FDC)
APT	$(R_{mL} - R_{fL})$	-	1,11	1,13	1,21	1,34
	(PIB)	1,11	-	1,14	1,02	1,19
	(BNEPU)	1,13	1,14	-	1,04	2,23
	(ISAESP)	1,21	1,02	1,04	-	1,35
	(FDC)	1,34	1,19	2,23	1,35	-

Fonte: Elaborado pela autora

A tabela exibe os valores de VIF que foram calculados para as variáveis independentes do modelo APT: fator de mercado ($R_{mL} - R_{fL}$), PIB, BNEPU, ISAESP e FDC, para o segundo período da amostra. É possível notar que, assim como visto no teste de multicolinearidade das variáveis do modelo de 5 fatores, os valores calculados também ficaram abaixo de 4.

Embora o VIF calculados entre a variável BNEPU e FDC tenha se sobressaído sobre os demais, não se constatou a presença de colinearidade entre as referidas variáveis. Dessa forma, conclui-se que, também não há presença de multicolinearidade entre as variáveis inseridas no modelo APT, para o período em questão.

Portanto, verificou-se também que não há indicação de multicolinearidade para as variáveis independentes no segundo período, que engloba a crise política e fiscal de 2014-2016, tanto para o modelo de 5 fatores quanto para o modelo APT.

A última análise será realizada sobre os testes de multicolinearidade para o terceiro período, que tem seu início em janeiro de 2017 e é finalizado em dezembro de 2021. Esse período engloba a crise decorrente da pandemia da COVID-19.

A tabela a seguir mostra os resultados dos testes de fator de inflação da variância (VIF), enfim para o terceiro período, considerando o modelo 5 fatores:

Tabela 20 – Resultados dos testes do fator de inflação da variância (VIF) do 3º período da amostra

		$(R_{mL} - R_{fL})$	(SMB)	(HML)	(RMW)	(CMA)
Modelo de 5 Fatores	$(R_{mL} - R_{fL})$	-	1,88	1,13	2,58	1,18
	(SMB)	1,88	-	1,21	1,88	1,08
	(HML)	1,13	1,21	-	1,22	2,20
	(RMW)	2,58	1,88	1,22	-	1,01
	(CMA)	1,18	1,08	2,20	1,01	-

Fonte: Elaborado pela autora

Os valores de VIF calculados para as variáveis independentes do modelo de 5 fatores para o terceiro período estudado são apresentados na tabela 20. Todos os resultados obtidos

foram significativamente inferiores a 4, e com isso é possível concluir que não há presença de multicolinearidade entre as variáveis inseridas neste modelo durante este período.

É possível observar que os valores de VIF calculados entre as variáveis fator mercado ($R_{mL} - R_{fL}$) e fator rentabilidade (HML) e entre os fatores valor (HML) e rentabilidade (RMW) assumem valores um pouco acima dos demais, mas, assim como em todos os testes realizados, não há comprometimento do modelo estimado com a utilização das referidas variáveis durante o período em estudo.

E então, por último, foram realizados os testes de fator de inflação da variância (VIF), para terceiro e último período, finalmente utilizando as variáveis para o modelo APT. Conforme a tabela 21 onde os resultados são apresentados:

Tabela 21 – Resultados dos testes do fator de inflação da variância (VIF) do 3º período da amostra

		($R_{mL} - R_{fL}$)	(DINF)	(IEESP)	(PET)	(PIB)
APT	($R_{mL} - R_{fL}$)	-	1,30	1,18	1,02	1,09
	(DINF)	1,30	-	1,17	1,04	1,03
	(IEESP)	1,18	1,17	-	1,03	1,43
	(PET)	1,02	1,04	1,03	-	1,73
	(PIB)	1,09	1,03	1,43	1,73	-

Fonte: Elaborado pela autora

A tabela expõe os valores de VIF calculados para as variáveis independentes do modelo APT: fator de mercado ($R_{mL} - R_{fL}$), PIB, DINF, IEESP e PET para o último período. Assim como no teste de multicolinearidade para as variáveis do modelo de 5 fatores, os valores calculados também ficaram abaixo de 4. Os valores de VIF calculados entre todas as variáveis do modelo ficaram próximos de 1, o que indica uma colinearidade muito baixa entre as variáveis inseridas no modelo APT, para o período em análise.

Portanto, verificou-se também que não há indicação de multicolinearidade, tanto para o modelo de 5 fatores quanto para o modelo APT, considerando o terceiro e último período, que engloba a crise da pandemia da COVID-19.

4.3.3 Teste de Normalidade dos resíduos

O teste de normalidade dos resíduos é um pressuposto fundamental dos modelos de regressão linear, que garante que os erros sejam distribuídos aleatoriamente e não enviesados para qualquer valor específico. Esta suposição é essencial para a validade dos testes de hipóteses

e para a construção de intervalos de confiança. No contexto deste estudo, a avaliação da normalidade residual baseou-se no teste de Jarque-Bera. (Gujarati, 2006)

Se os resíduos apresentarem distribuição gaussiana, isso significa que o modelo se ajusta adequadamente aos dados e garante a confiabilidade dos coeficientes estimados. Porém, se a distribuição residual não for normal, indica que o modelo pode estar mal especificado, comprometendo a confiabilidade dos coeficientes estimados e tornando-os propensos a vieses ou ineficiência.

Tabela 22– Resultados dos testes de normalidade dos resíduos

		D.P.	Assimetria	Curtose	Estatística J.B.	Prob.	Conclusão
Crise de 2008	Modelo de 5 fatores	0.023	-0.251	3.046	0.636	0.727	Evidências de normalidade a 5%
	APT	0.019	0.293	3.419	1.302	0.521	Evidências de normalidade a 5%
Crise política	Modelo de 5 fatores	0.021	0.378	2.854	1.481	0.476	Evidências de normalidade a 5%
	APT	0.023	0.441	2.427	2.771	0.250	Evidências de normalidade a 5%
Covid-19	Modelo de 5 fatores	0.020	-0.142	2.471	0.902	0.636	Evidências de normalidade a 5%
	APT	0.022	0.368	3.272	1.542	0.462	Evidências de normalidade a 5%

Fonte: Elaborado pela autora

Se os erros apresentarem distribuição normal, significa que o modelo se ajusta adequadamente aos dados e garante a confiabilidade dos coeficientes estimados. Porém, se a distribuição residual não for normal, indica que o modelo pode estar mal especificado, comprometendo a confiabilidade dos coeficientes estimados e tornando-os propensos a vieses ou ineficiência. Conforme os resultados da tabela 22, pode ser observado que, em todas as estimações realizadas, foram obtidos resíduos com evidências de normalidade a 5%.

4.4 RESULTADOS DAS PROJEÇÕES DO DMA

Nessa seção, são apresentados os resultados das previsões realizadas para 10 carteiras, com a utilização do modelo de 5 fatores de Fama e French (2015) e do modelo APT. Como a amostra foi subdividida em três períodos, serão apresentados dados sobre cada um dos períodos, com a utilização de cada um dos modelos.

As previsões se dividem em “pré-crise” e “pós-crise”, de modo que, os resultados sobre o desempenho das previsões dos modelos possam ser comparados sem nenhum viés. As projeções foram realizadas para os períodos logo após a ocorrência das crises, e para fins de comparação, foram feitas para os mesmos meses, porém no ano anterior e se valerem de dois fatores de esquecimento, sendo eles: $\lambda = 0,99$ e $\lambda = 0,90$.

Tabela 23 – Resultados das projeções com o modelo de 5 fatores no 1º período da amostra

		Período	Retorno Realizado (a)	Previsão 5 Fatores (b) $\lambda = 0,99$	Erro (a-b)	Previsão 5 Fatores (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	11/2007	-0,058	0,048	-0,106	0,037	-0,095
		12/2007	0,006	0,073	-0,068	0,077	-0,071
	Pós-crise	11/2008	-0,065	-0,020	-0,044	-0,027	-0,038
		12/2008	0,013	-0,005	0,018	0,010	0,003
Carteira 2	Pré-crise	11/2007	-0,112	0,025	-0,136	0,030	-0,141
		12/2007	-0,047	0,070	-0,117	0,101	-0,148
	Pós-crise	11/2008	-0,010	-0,002	-0,008	-0,023	0,012
		12/2008	0,029	-0,005	0,034	-0,023	0,052
Carteira 3	Pré-crise	11/2007	-0,066	0,044	-0,110	0,075	-0,141
		12/2007	-0,001	0,066	-0,068	0,061	-0,062
	Pós-crise	11/2008	-0,059	-0,011	-0,047	-0,011	-0,048
		12/2008	-0,011	0,012	-0,023	0,011	-0,022
Carteira 4	Pré-crise	11/2007	-0,064	0,031	-0,095	0,018	-0,082
		12/2007	-0,050	0,056	-0,105	0,014	-0,064
	Pós-crise	11/2008	-0,031	-0,017	-0,013	-0,015	-0,016
		12/2008	0,003	-0,017	0,020	0,000	0,003
Carteira 5	Pré-crise	11/2007	-0,058	0,045	-0,103	0,049	-0,107
		12/2007	-0,033	0,078	-0,110	0,080	-0,113
	Pós-crise	11/2008	-0,060	-0,015	-0,045	-0,008	-0,052
		12/2008	0,011	-0,015	0,026	0,002	0,009
Carteira 6	Pré-crise	11/2007	-0,080	0,036	-0,116	0,045	-0,125
		12/2007	-0,040	0,070	-0,110	0,104	-0,144
	Pós-crise	11/2008	-0,052	-0,020	-0,032	-0,013	-0,039
		12/2008	-0,005	-0,020	0,015	-0,001	-0,004
Carteira 7	Pré-crise	11/2007	0,007	0,013	-0,006	0,024	-0,018
		12/2007	-0,005	0,055	-0,060	0,095	-0,100
	Pós-crise	11/2008	-0,003	-0,032	0,029	-0,028	0,025
		12/2008	-0,016	-0,032	0,016	-0,014	-0,002
Carteira 8	Pré-crise	11/2007	-0,086	0,025	-0,112	0,016	-0,102
		12/2007	-0,043	0,057	-0,101	0,049	-0,093
	Pós-crise	11/2008	-0,031	-0,016	-0,015	-0,020	-0,011
		12/2008	-0,019	-0,016	-0,003	-0,003	-0,016
Carteira 9	Pré-crise	11/2007	-0,096	0,007	-0,103	0,004	-0,100
		12/2007	-0,011	0,060	-0,070	0,051	-0,062
	Pós-crise	11/2008	0,015	-0,017	0,032	-0,006	0,020
		12/2008	0,011	-0,009	0,019	-0,011	0,021
Carteira 10	Pré-crise	11/2007	-0,078	0,047	-0,125	0,032	-0,111
		12/2007	-0,015	0,085	-0,100	0,071	-0,086
	Pós-crise	11/2008	-0,068	0,008	-0,077	0,015	-0,083
		12/2008	0,039	-0,001	0,040	0,010	0,029

Fonte: Elaborado pela autora

As previsões realizadas para as 10 carteiras, utilizando o modelo de 5 fatores, apesar disso, as previsões apresentaram valores semelhantes. O retorno médio das carteiras durante esse período foi igual a -0,031, e podem ser observados sinais negativos na maior parte dos retornos. No que tange às previsões, temos valores previstos médios de 0,018 e 0,022. De modo geral, observa-se um erro elevado em todas as previsões.

Tabela 24 – Resultados das projeções com o modelo de 5 fatores no 2º período da amostra

		Período	Retorno Realizado (a)	Previsão 5 Fatores (b) $\lambda = 0,99$	Erro (a-b)	Previsão 5 Fatores (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	10/2015	0,041	-0,023	0,064	-0,023	0,064
		11/2015	-0,037	-0,021	-0,016	-0,022	-0,015
	Pós-crise	10/2016	0,004	-0,047	0,051	-0,034	0,038
		11/2016	-0,055	-0,051	-0,004	-0,031	-0,024
Carteira 2	Pré-crise	10/2015	-0,004	-0,037	0,032	-0,041	0,036
		11/2015	-0,058	-0,031	-0,028	-0,029	-0,030
	Pós-crise	10/2016	0,048	-0,056	0,105	-0,044	0,093
		11/2016	-0,039	-0,061	0,022	-0,047	0,008
Carteira 3	Pré-crise	10/2015	0,014	-0,027	0,041	-0,033	0,047
		11/2015	0,015	-0,020	0,034	-0,023	0,038
	Pós-crise	10/2016	0,029	-0,016	0,045	-0,023	0,052
		11/2016	-0,096	-0,016	-0,080	-0,028	-0,068
Carteira 4	Pré-crise	10/2015	0,052	-0,031	0,083	-0,037	0,090
		11/2015	-0,002	-0,020	0,017	-0,022	0,020
	Pós-crise	10/2016	0,052	-0,013	0,065	-0,016	0,068
		11/2016	-0,086	-0,003	-0,083	-0,009	-0,077
Carteira 5	Pré-crise	10/2015	0,017	-0,025	0,042	-0,033	0,050
		11/2015	-0,028	-0,020	-0,009	-0,024	-0,004
	Pós-crise	10/2016	0,014	-0,018	0,033	-0,021	0,036
		11/2016	-0,075	-0,009	-0,066	-0,021	-0,054
Carteira 6	Pré-crise	10/2015	0,010	-0,030	0,040	-0,033	0,043
		11/2015	-0,051	-0,023	-0,028	-0,023	-0,028
	Pós-crise	10/2016	0,016	-0,015	0,032	-0,019	0,036
		11/2016	-0,115	-0,008	-0,107	-0,016	-0,098
Carteira 7	Pré-crise	10/2015	-0,013	-0,032	0,018	-0,036	0,023
		11/2015	-0,024	-0,027	0,004	-0,027	0,003
	Pós-crise	10/2016	0,027	-0,054	0,081	-0,037	0,064
		11/2016	-0,091	-0,058	-0,032	-0,038	-0,053
Carteira 8	Pré-crise	10/2015	0,006	-0,022	0,028	-0,016	0,022
		11/2015	-0,013	-0,018	0,005	-0,016	0,002
	Pós-crise	10/2016	0,028	-0,042	0,070	-0,030	0,059
		11/2016	-0,090	-0,045	-0,045	-0,030	-0,060
Carteira 9	Pré-crise	10/2015	-0,013	-0,029	0,017	-0,028	0,015
		11/2015	-0,035	-0,026	-0,009	-0,024	-0,011
	Pós-crise	10/2016	0,054	-0,012	0,066	-0,021	0,074
		11/2016	-0,102	0,000	-0,103	-0,015	-0,087
Carteira 10	Pré-crise	10/2015	0,050	-0,024	0,074	-0,029	0,080
		11/2015	-0,028	-0,019	-0,009	-0,021	-0,007
	Pós-crise	10/2016	0,025	-0,014	0,039	-0,020	0,045
		11/2016	-0,079	-0,004	-0,075	-0,014	-0,065

Fonte: Elaborado pela autora

As previsões realizadas com o modelo de 5 fatores, durante o segundo período de crise apresentaram apenas valores negativos, mesmo com diferentes fatores de esquecimento. Através da análise sobre separação entre um período pré-crise e pós-crise, nota-se que isso não gerou impacto na qualidade das previsões, nas duas situações são apresentadas altas diferenças entre retorno previsto e retorno realizado.

Tabela 25 – Resultados das projeções com o modelo de 5 fatores no 3º período da amostra

		Período	Retorno Realizado (a)	Previsão 5 Fatores (b) $\lambda = 0,99$	Erro (a-b)	Previsão 5 Fatores (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	05/2019	0,016	0,006	0,010	0,003	0,013
		06/2019	0,043	0,024	0,019	0,032	0,011
	Pós-crise	05/2020	0,063	0,032	0,031	0,047	0,017
		06/2020	0,157	0,048	0,109	0,041	0,116
Carteira 2	Pré-crise	05/2019	0,015	0,015	0,000	0,020	-0,004
		06/2019	0,045	0,034	0,011	0,041	0,004
	Pós-crise	05/2020	0,048	0,038	0,010	0,038	0,009
		06/2020	0,162	0,058	0,104	0,061	0,101
Carteira 3	Pré-crise	05/2019	0,006	0,009	-0,003	0,008	-0,002
		06/2019	0,069	0,015	0,054	0,018	0,051
	Pós-crise	05/2020	0,027	0,036	-0,009	0,055	-0,029
		06/2020	0,156	0,067	0,089	0,051	0,105
Carteira 4	Pré-crise	05/2019	0,033	0,005	0,028	0,009	0,024
		06/2019	0,043	0,012	0,032	0,005	0,038
	Pós-crise	05/2020	0,055	0,057	-0,003	0,053	0,002
		06/2020	0,097	0,028	0,069	0,034	0,063
Carteira 5	Pré-crise	05/2019	0,030	0,010	0,020	0,008	0,023
		06/2019	0,051	0,020	0,031	0,016	0,035
	Pós-crise	05/2020	0,053	0,041	0,012	0,037	0,016
		06/2020	0,122	0,047	0,075	0,051	0,071
Carteira 6	Pré-crise	05/2019	0,036	0,003	0,032	0,001	0,035
		06/2019	0,071	0,016	0,055	0,024	0,047
	Pós-crise	05/2020	0,031	0,024	0,006	0,036	-0,005
		06/2020	0,107	0,064	0,042	0,056	0,050
Carteira 7	Pré-crise	05/2019	0,002	0,008	-0,006	0,008	-0,007
		06/2019	0,047	0,014	0,033	0,008	0,039
	Pós-crise	05/2020	0,031	0,034	-0,003	0,035	-0,004
		06/2020	0,081	0,024	0,057	0,027	0,054
Carteira 8	Pré-crise	05/2019	0,020	0,009	0,011	0,008	0,012
		06/2019	0,056	0,010	0,046	0,011	0,045
	Pós-crise	05/2020	0,061	0,025	0,036	0,035	0,025
		06/2020	0,090	0,054	0,036	0,048	0,042
Carteira 9	Pré-crise	05/2019	0,027	0,009	0,018	0,008	0,018
		06/2019	0,040	0,021	0,019	0,022	0,018
	Pós-crise	05/2020	0,030	0,035	-0,005	0,043	-0,013
		06/2020	0,096	0,065	0,032	0,050	0,047
Carteira 10	Pré-crise	05/2019	0,049	0,011	0,038	0,014	0,035
		06/2019	0,059	0,013	0,046	0,012	0,047
	Pós-crise	05/2020	0,096	0,036	0,060	0,036	0,060
		06/2020	0,143	0,012	0,131	0,017	0,125

Fonte: Elaborado pela autora

Já as previsões realizadas com o modelo de 5 fatores, durante o terceiro período de crise apresentaram apenas valores positivos, mesmo com diferentes fatores de esquecimento, isso está em consonância ao retorno realizado, dado que todas as carteiras apresentaram retornos positivos durante os períodos em análise. A seguir são apresentados os resultados das previsões com a utilização das variáveis do modelo APT.

Tabela 26 – Resultados das projeções com o modelo APT no 1º período da amostra

		Período	Retorno Realizado (a)	Previsão APT (b) $\lambda = 0,99$	Erro (a-b)	Previsão APT (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	11/2007	-0,058	0,057	-0,114	0,054	-0,112
		12/2007	0,006	0,056	-0,050	0,054	-0,048
	Pós-crise	11/2008	-0,065	-0,305	0,240	-0,293	0,228
		12/2008	0,013	-0,252	0,265	-0,248	0,261
Carteira 2	Pré-crise	11/2007	-0,112	0,012	-0,124	0,030	-0,141
		12/2007	-0,047	0,038	-0,085	0,030	-0,077
	Pós-crise	11/2008	-0,010	-0,310	0,299	-0,298	0,287
		12/2008	0,029	-0,250	0,278	-0,249	0,278
Carteira 3	Pré-crise	11/2007	-0,066	0,048	-0,114	0,075	-0,141
		12/2007	-0,001	0,032	-0,034	0,061	-0,062
	Pós-crise	11/2008	-0,059	-0,289	0,230	-0,267	0,209
		12/2008	-0,011	-0,238	0,227	-0,228	0,217
Carteira 4	Pré-crise	11/2007	-0,064	0,036	-0,100	0,036	-0,101
		12/2007	-0,050	0,037	-0,086	0,037	-0,087
	Pós-crise	11/2008	-0,031	-0,273	0,242	-0,266	0,236
		12/2008	0,003	-0,225	0,228	-0,225	0,228
Carteira 5	Pré-crise	11/2007	-0,058	0,035	-0,093	0,036	-0,093
		12/2007	-0,033	0,040	-0,073	0,036	-0,068
	Pós-crise	11/2008	-0,060	-0,310	0,250	-0,303	0,243
		12/2008	0,011	-0,258	0,269	-0,256	0,267
Carteira 6	Pré-crise	11/2007	-0,080	0,029	-0,109	0,036	-0,116
		12/2007	-0,040	0,033	-0,073	0,053	-0,093
	Pós-crise	11/2008	-0,052	-0,263	0,211	-0,244	0,192
		12/2008	-0,005	-0,219	0,214	-0,216	0,212
Carteira 7	Pré-crise	11/2007	0,007	0,015	-0,009	0,010	-0,004
		12/2007	-0,005	0,022	-0,026	0,016	-0,020
	Pós-crise	11/2008	-0,003	-0,304	0,301	-0,292	0,289
		12/2008	-0,016	-0,250	0,234	-0,247	0,231
Carteira 8	Pré-crise	11/2007	-0,086	0,031	-0,117	0,031	-0,117
		12/2007	-0,043	0,048	-0,092	0,035	-0,079
	Pós-crise	11/2008	-0,031	-0,270	0,239	-0,265	0,234
		12/2008	-0,019	-0,222	0,203	-0,222	0,203
Carteira 9	Pré-crise	11/2007	-0,096	0,007	-0,103	0,027	-0,123
		12/2007	-0,011	0,033	-0,044	0,027	-0,038
	Pós-crise	11/2008	0,015	-0,279	0,293	-0,272	0,287
		12/2008	0,011	-0,228	0,239	-0,230	0,241
Carteira 10	Pré-crise	11/2007	-0,078	0,037	-0,115	0,035	-0,114
		12/2007	-0,015	0,066	-0,081	0,083	-0,098
	Pós-crise	11/2008	-0,068	-0,276	0,208	-0,266	0,198
		12/2008	0,039	-0,228	0,267	-0,227	0,266

Fonte: Elaborado pela autora

Na tabela 26 foram apresentados os resultados das previsões com a utilização do APT para o período da crise de 2008. Durante este período podem ser observadas previsões com valores excessivamente baixos, mas que de forma alguma refletem os valores realizados, embora durante esses períodos as carteiras não tenham apresentado um bom desempenho.

Tabela 27 – Resultados das projeções com o modelo APT no 2º período da amostra

		Período	Retorno Realizado (a)	Previsão APT (b) $\lambda = 0,99$	Erro (a-b)	Previsão APT (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	10/2015	0,041	-0,013	0,054	-0,008	0,048
		11/2015	-0,037	-0,015	-0,022	-0,011	-0,025
	Pós-crise	10/2016	0,004	0,041	-0,038	0,039	-0,035
		11/2016	-0,055	0,035	-0,090	0,032	-0,087
Carteira 2	Pré-crise	10/2015	-0,004	-0,022	0,018	-0,026	0,022
		11/2015	-0,058	-0,014	-0,044	-0,020	-0,038
	Pós-crise	10/2016	0,048	0,037	0,012	0,033	0,015
		11/2016	-0,039	0,030	-0,070	0,023	-0,063
Carteira 3	Pré-crise	10/2015	0,014	-0,007	0,021	-0,018	0,032
		11/2015	0,015	0,010	0,005	-0,015	0,030
	Pós-crise	10/2016	0,029	0,027	0,002	0,026	0,003
		11/2016	-0,096	0,021	-0,117	0,021	-0,116
Carteira 4	Pré-crise	10/2015	0,052	-0,021	0,074	-0,023	0,076
		11/2015	-0,002	-0,004	0,002	-0,015	0,012
	Pós-crise	10/2016	0,052	0,032	0,020	0,031	0,021
		11/2016	-0,086	0,027	-0,113	0,026	-0,112
Carteira 5	Pré-crise	10/2015	0,017	-0,008	0,025	-0,010	0,027
		11/2015	-0,028	0,006	-0,034	-0,012	-0,016
	Pós-crise	10/2016	0,014	0,027	-0,012	0,022	-0,008
		11/2016	-0,075	0,022	-0,096	0,018	-0,092
Carteira 6	Pré-crise	10/2015	0,010	-0,024	0,034	-0,033	0,043
		11/2015	-0,051	-0,011	-0,040	-0,023	-0,028
	Pós-crise	10/2016	0,016	0,038	-0,021	0,038	-0,022
		11/2016	-0,115	0,032	-0,146	0,032	-0,147
Carteira 7	Pré-crise	10/2015	-0,013	-0,013	0,000	-0,014	0,001
		11/2015	-0,024	0,003	-0,026	-0,014	-0,010
	Pós-crise	10/2016	0,027	0,041	-0,014	0,040	-0,013
		11/2016	-0,091	0,034	-0,125	0,031	-0,122
Carteira 8	Pré-crise	10/2015	0,006	-0,009	0,016	-0,016	0,022
		11/2015	-0,013	-0,003	-0,010	-0,016	0,002
	Pós-crise	10/2016	0,028	0,040	-0,011	0,034	-0,006
		11/2016	-0,090	0,033	-0,123	0,027	-0,118
Carteira 9	Pré-crise	10/2015	-0,013	-0,015	0,003	-0,012	0,000
		11/2015	-0,035	0,017	-0,052	-0,011	-0,024
	Pós-crise	10/2016	0,054	0,040	0,014	0,038	0,016
		11/2016	-0,102	0,035	-0,138	0,033	-0,135
Carteira 10	Pré-crise	10/2015	0,050	-0,012	0,063	-0,018	0,068
		11/2015	-0,028	-0,001	-0,027	-0,014	-0,014
	Pós-crise	10/2016	0,025	0,038	-0,013	0,035	-0,009
		11/2016	-0,079	0,032	-0,111	0,029	-0,108

Fonte: Elaborado pela autora

O segundo período de previsões com o APT apresentou o melhor desempenho em comparação aos demais dado que não foram obtidos valores tão discrepantes. Entretanto, isso não pode ser considerado como algum tipo de eficiência preditiva, dado que ainda podem ser observados erros altos na previsão

Tabela 28 – Resultados das projeções com o modelo APT no 3º período da amostra

		Período	Retorno Realizado (a)	Previsão APT (b) $\lambda = 0,99$	Erro (a-b)	Previsão APT (c) $\lambda = 0,90$	Erro (a-c)
Carteira 1	Pré-crise	05/2019	0,016	-0,005	0,021	0,001	0,015
		06/2019	0,043	-0,020	0,063	-0,023	0,066
	Pós-crise	05/2020	0,063	-0,009	0,072	-0,011	0,074
		06/2020	0,157	0,029	0,128	-0,056	0,212
Carteira 2	Pré-crise	05/2019	0,015	0,007	0,008	-0,003	0,019
		06/2019	0,045	-0,007	0,052	-0,021	0,066
	Pós-crise	05/2020	0,048	-0,032	0,080	-0,016	0,064
		06/2020	0,162	-0,172	0,334	-0,169	0,330
Carteira 3	Pré-crise	05/2019	0,006	0,001	0,005	0,007	-0,001
		06/2019	0,069	0,002	0,067	0,001	0,068
	Pós-crise	05/2020	0,027	-0,020	0,046	-0,029	0,056
		06/2020	0,156	-0,191	0,347	-0,298	0,454
Carteira 4	Pré-crise	05/2019	0,033	-0,004	0,036	-0,001	0,034
		06/2019	0,043	-0,013	0,056	-0,016	0,059
	Pós-crise	05/2020	0,055	0,001	0,054	-0,009	0,064
		06/2020	0,097	0,122	-0,025	-0,036	0,134
Carteira 5	Pré-crise	05/2019	0,030	0,002	0,028	-0,004	0,034
		06/2019	0,051	0,007	0,045	-0,003	0,054
	Pós-crise	05/2020	0,053	-0,013	0,066	-0,007	0,060
		06/2020	0,122	-0,058	0,180	-0,129	0,250
Carteira 6	Pré-crise	05/2019	0,036	-0,007	0,043	-0,014	0,050
		06/2019	0,071	-0,008	0,079	-0,017	0,088
	Pós-crise	05/2020	0,031	-0,029	0,060	-0,019	0,049
		06/2020	0,107	-0,186	0,292	-0,166	0,273
Carteira 7	Pré-crise	05/2019	0,002	0,004	-0,002	0,005	-0,003
		06/2019	0,047	0,002	0,045	-0,001	0,048
	Pós-crise	05/2020	0,031	-0,011	0,043	-0,014	0,045
		06/2020	0,081	-0,187	0,268	-0,257	0,338
Carteira 8	Pré-crise	05/2019	0,020	-0,008	0,028	-0,011	0,031
		06/2019	0,056	-0,004	0,060	-0,013	0,069
	Pós-crise	05/2020	0,061	-0,002	0,062	-0,003	0,063
		06/2020	0,090	-0,064	0,154	-0,113	0,203
Carteira 9	Pré-crise	05/2019	0,027	-0,014	0,041	-0,018	0,045
		06/2019	0,040	-0,014	0,054	-0,020	0,060
	Pós-crise	05/2020	0,030	-0,078	0,108	-0,072	0,101
		06/2020	0,096	-0,648	0,745	-0,602	0,698
Carteira 10	Pré-crise	05/2019	0,049	0,002	0,047	-0,006	0,055
		06/2019	0,059	-0,001	0,060	-0,007	0,066
	Pós-crise	05/2020	0,096	-0,018	0,114	-0,022	0,117
		06/2020	0,143	-0,160	0,302	-0,237	0,380

Fonte: Elaborado pela autora

Durante o terceiro período de crise as previsões com a utilização do APT produziram um excesso de previsões com altos valores negativos, enquanto as carteiras tinham um bom desempenho e apresentavam retornos positivos. Inclusive, podem ser observados valores que podem ser considerados outliers, como os resultados da carteira 9. Isso acarretou erros de previsão muito elevados, e isso sugere que uma (ou mais) das variáveis do modelo APT, distorceu as previsões durante esse período.

De modo geral, os resultados obtidos nas previsões não foram satisfatórios, em todas as situações foram encontrados valores discrepantes e erros de previsão muito altos, entretanto por se tratarem de apenas 10 carteiras, esses resultados não podem ser generalizados. Para fins de uma análise mais objetiva dos resultados, foi utilizado o RMSE e os resultados são apresentados na próxima seção.

4.4.1 RMSE

O RMSE é uma medida da precisão de um modelo de previsão e é frequentemente usado para comparar o desempenho de diferentes modelos, já que leva em consideração tanto a magnitude quanto a direção dos erros. A tabela 29 apresenta os resultados do RMSE para os modelos durante os três períodos da amostra:

Tabela 29 - Resultados do RMSE

		APT Erro $\lambda = 0,99$	APT Erro $\lambda = 0,90$	5 Fatores $\lambda = 0,99$	5 Fatores Erro $\lambda = 0,90$
Previsão Pré- crise	Crise 20008	0,088	0,094	0,101	0,103
	Crise política	0,034	0,033	0,037	0,039
	Covid	0,046	0,051	0,031	0,031
Previsão Pós- crise	Crise 20008	0,248	0,242	0,032	0,032
	Crise política	0,082	0,081	0,066	0,062
	Covid	0,241	0,261	0,059	0,061
Total	Crise 20008	0,186	0,183	0,074	0,076
	Crise política	0,063	0,061	0,053	0,052
	Covid	0,173	0,187	0,047	0,048

Fonte: Elaborado pela autora

Ao analisar o RMSE do modelo APT, observa-se que os erros nas previsões durante o período pós-crise são substancialmente maiores em comparação ao período pré-crise. Já o modelo de 5 fatores não apresenta tanta discrepância entre seus resultados, entretanto, os erros são consistentemente altos.

O fator de esquecimento, definido na aplicação do DMA, não foi capaz de melhorar os resultados das projeções; pelo contrário, foram obtidas projeções muito semelhantes com fatores de esquecimento diferentes, ocorrendo de maneira semelhante no modelo de 5 fatores e no APT durante todos os períodos. Um indicativo é a similaridade na ordem de grandeza e comportamento dos erros.

Ambos os modelos, em todos os períodos, apresentaram erros de previsão muito elevados, o que inviabiliza a utilização desse método sob os mesmos parâmetros para a predição do retorno acionário nas carteiras da amostra. No entanto, isso reforça a ideia de eficiência do mercado, uma vez que os dados passados não foram capazes de prever resultados futuros.

Esses resultados estão alinhados com a pesquisa de Mussa, Rogers e Securato (2009). Embora tenham testado modelos diferentes, também objetivaram avaliar a capacidade preditiva de modelos de precificação. No caso deles, foram testados o CAPM, o modelo de 3 fatores de Fama e French (1993) e o de 4 fatores de Carhart (1997). A conclusão foi que nenhum dos modelos foi eficiente para prever os retornos de ações brasileiras. Desse modo, isso corrobora a ideia de que a validação de previsões sobre o mercado acionário brasileiro ainda requer esforços futuros.

5 CONSIDERAÇÕES FINAIS

Desde a década de 60, com a formulação do CAPM de Sharpe, Lintner e Mossin (1965), a literatura sobre a precificação de ativos tem crescido consideravelmente, abrangendo tanto mercados desenvolvidos quanto emergentes. São abordados fatores com capacidade explicativa sobre o retorno acionário, e constantemente novas pesquisas são apresentadas, incorporando variáveis inovadoras e diversas metodologias

Em meio a essa diversidade, a ausência de consenso acadêmico em relação à capacidade explicativa dos modelos de precificação de ativos, isso torna a previsão do retorno acionário ainda mais desafiadora. Diversos outros estudos utilizam redes neurais, modelos autorregressivos e outras abordagens hodiernas, no âmbito de *machine learning* e Inteligência Artificial (IA). A antecipação dos preços e retornos dos ativos permanece um dos problemas mais intrigantes e estimulantes, tanto para a área de pesquisa em finanças quantitativas quanto para analistas do mercado financeiro. Esse desafio é acentuado pelo considerável aumento no volume de dados gerados nos últimos anos, oferecendo amplas oportunidades para o desenvolvimento de pesquisas. (Simin, 2008; Miranda, Ceretta & Lopes, 2015; Silva & Machado, 2015; Santana, Dantas, & Loiola, 2016)

Em períodos de crise financeira, a interconexão entre os mercados pode resultar em riscos de contágio significativos. Além da possibilidade de quebra estrutural, observam-se alterações na volatilidade e nas correlações entre as séries. Esses riscos incluem a transmissão de choques, criando um ambiente permeado por incertezas que torna a precificação de ativos mais desafiadora. Isso abre espaço para novos conjuntos de variáveis, especialmente aquelas relacionadas ao sentimento do investidor e à percepção de mercado por parte dos analistas (Baker & Wurgler, 2006; Liu, Liang, & Tang, 2003; Long, Shleifer, Summers, & Waldmann, 1990; Shleifer & Vishny, 1997).

O presente estudo teve como objetivo avaliar a capacidade explicativa e preditiva do modelo de 5 fatores de Fama e French (2015) e do APT (1970) de Ross no mercado acionário brasileiro em períodos de crise. Foram selecionados três períodos de crise: a crise de 2008, o impeachment de Dilma Rousseff e a crise gerada pelo Coronavírus. O estudo abrange o período de 2007 a 2021, dividido em três subperíodos iguais. Participaram do estudo 116 empresas no primeiro período, 159 no segundo e 164 no terceiro, todas com ações negociadas na B3.

Barillas & Shanken (2015) destacaram que o CAPM é o modelo mais popular e amplamente utilizado pelos profissionais. No entanto, modelos como o APT de Ross (1976) e

o modelo de 5 fatores de Fama e French (2015) têm a capacidade de agregar poder explicativo ao modelo de um único fator.

Assim, a variável retorno de mercado, preconizada pelo CAPM tradicional, e incorporada em cada um dos modelos durante todos os períodos da amostra, revelou-se significativa, com p -valor = 0,00 em todos os casos. Nesse contexto, percebe-se que o fator risco de mercado é, de fato, o principal na explicação do retorno das carteiras, alinhando-se com a maioria das pesquisas sobre o tema. De acordo com Fama e French (2016), aproximadamente 70% dos retornos esperados em uma carteira diversificada podem ser explicados pelo fator de mercado, enquanto o restante pode ser atribuído a outros fatores.

No presente estudo, foram empregados fatores diferentes dentro do modelo APT em cada uma das subamostras, o que se apresenta como um ponto positivo, abrindo possibilidades de pesquisa, incluindo a realização de testes com a formulação de novas variáveis. A ausência de uma especificação dos fatores de risco permite que o usuário analise de forma intuitiva e empírica as variáveis que mais interferem no desempenho esperado de uma determinada empresa, carteira, setor econômico e até mesmo em um determinado período. A especificação de diferentes modelos permitiu a obtenção de achados distintos ao longo dos períodos da amostra.

Na composição do Modelo APT, as variáveis relacionadas a expectativa e incerteza econômica no Brasil apresentaram capacidade explicativa satisfatória, uma variação positiva indica que há uma maior incerteza em relação à política econômica, o que pode afetar negativamente o investimento e o crescimento econômico e conseqüentemente, o retorno acionário.

A variável DINF foi utilizada como uma medida do impacto dos surtos de doenças infecciosas nos mercados financeiros. A mesma, mede o nível de incerteza da política econômica nos Estados Unidos, e em dados sobre o número de novos casos de COVID-19 nos Estados Unidos. Essa variável foi capaz de captar o impacto da Covid-19 aqui no Brasil, se mostrando significativa ao nível de 5% durante o período de 2017 à 2021.

Em contrapartida, destacam-se o modelo CAPM, com sua simplicidade, e o modelo de 5 fatores, que já apresenta suas variáveis bem especificadas, representando facilidade na hora de sua utilização. Essas considerações devem ser ponderadas por pesquisadores e analistas financeiros ao escolher um modelo de precificação de ativos.

Por meio das estimações do modelo de 5 fatores, foram obtidos resultados satisfatórios para os fatores: tamanho (SMB), valor (HML) e investimento (CMA), entretanto o fator rentabilidade (RMW) só apresentou significância estatística no primeiro período da amostra.

De maneira geral, o modelo de 5 fatores apresentou um R^2 ajustado levemente superior ao APT no primeiros e terceiro períodos da amostra. No entanto, no segundo período, foram encontrados resultados semelhantes. Essas constatações estão em linha com os resultados obtidos por Vieira et al. (2017), Leite et al. (2018) e Carvalho et al. (2021), que também observaram um desempenho superior do modelo de 5 fatores em comparação com outros modelos, incluindo o APT.

Ademais, é possível notar inversões nos sinais dos fatores ao longo dos três períodos, assim como alterações na significância dos fatores. Os resultados apresentados, respaldados pelos estudos de Bortoluzzo et al. (2016), Oliveira, Silva & Martins (2016) e Moreira et al. (2021), indicam que os fatores de risco que compõem os modelos de precificação de ativos, com exceção do fator risco de mercado, apresentam um comportamento condicionado à situação econômica do país.

Entretanto, de acordo com Leite, Pinto e Klotzle (2016), um modelo multifatorial de precificação de ativos, apresenta um intercepto, que é, em sua maioria, definido por α , não significativo. Se, nas estimativas dos modelos, a constante é significativa há indícios da omissão de fatores relevantes. Esse resultado é uma indicação do quão bem definido o modelo está. Em todas as regressões deste estudo, os resultados não apresentaram interceptos estatisticamente significativos, isso sinaliza que uma boa especificação nos modelos foi alcançada.

Então, têm-se resultados positivos para a utilização do modelo de 5 fatores neste mercado acionário, assim como apontamentos de que as variáveis escolhidas para o modelo APT, são apropriadas para explicar o retorno acionário no mercado brasileiro. É possível observar que a capacidade explicativa, medida pelo R^2 , aumentou nos dois modelos ao longo dos períodos da amostra e em algumas regressões ambos foram reativos a inclusão da variável *dummy* referente a crise.

Quanto à capacidade preditiva dos modelos de 5 fatores e APT, após a formação de 10 carteiras aleatórias e realização de previsões para dois meses após o período de crise, e para os mesmos dois meses, porém no ano anterior à crise e com a utilização de dois fatores de esquecimento, foram obtidas 160 previsões para cada subperíodo da amostra. Contudo, não foram encontradas evidências de eficiência nessas previsões em nenhuma das situações, uma vez que os erros de previsão sempre se mostraram elevados.

Esses resultados estão em consonância com as hipóteses de eficiência de mercado, sustentando a premissa de que o mercado é eficiente em refletir todas as informações públicas disponíveis e que existe independência entre os retornos ao longo dos períodos. Portanto, informações passadas não contribuiriam para a previsão de retornos acionários futuros.

Com base nisso, os achados sobre a previsibilidade do retorno acionário corroboram pesquisas como a de Simin (2008), que examinou erros de previsão de séries temporais de retornos esperados com a utilização de modelos de precificação de ativos, tanto para portfólios quanto para ações de empresas individuais, além de relatar a existência de erros quadráticos médios elevados. Espera-se que os resultados deste estudo forneçam aos pesquisadores informações adicionais relevantes sobre os modelos de precificação de ativos utilizados, orientando a seleção de modelos e variáveis explicativas. Além disso, buscou-se agregar evidências que podem ser utilizadas como referência em pesquisas futuras.

Uma limitação do presente estudo é a realização dos testes com dados apenas da B3. Dessa forma, esses resultados não podem ser estendidos a outros mercados. Como sugestão para futuras pesquisas, propõe-se a inclusão de testes em outros mercados emergentes. Investidores podem ter grandes participações em ações individuais e podem ter seu investimento afetado por volatilidade idiossincrática, causada tanto por mudanças nos resultados da própria empresa quanto por efeitos externos, como alterações na legislação ou volatilidade do mercado. Certos eventos podem afetar ações individuais de maneira diferenciada.

Diante disso, sugere-se, para pesquisas futuras, testes com ativos individuais e fatores idiossincráticos como variáveis explanatórias, verificando tanto sua capacidade explicativa quanto preditiva, além da adoção de novos métodos de previsão. Neste sentido, caberá a utilização da recente ferramenta da Inteligência Artificial, na precificação de ativos em particular e em finanças em geral, o que poderá revolucionar a área de finanças como a conhecemos.

6 REFERÊNCIAS

- Abennadher, E., & Hallara, S. (2018). Structural breaks and stock market volatility in emerging countries. *International Journal of Business and Risk Management*, 1(1), 9-16.
- Ali, M., Alam, N., & Rizvi, S. A. R. (2020). Coronavirus (COVID-19) – An epidemic or pandemic for financial markets. *Journal of Behavioral and Experimental Finance*, 27, 100341.
- Amaral, L. (2009). Crises financeiras: história e actualidade. *Relações Internacionais (R: I)*, 23, 119-138.
- Amorim, A. L. G. C., Lima, I. S., & Murcia, F. D. R. (2012). Análise da relação entre as informações contábeis e o risco sistemático no mercado brasileiro. *Revista Contabilidade & Finanças*, 23, 199-211.
- Araújo, E. A. T., Oliveira, V. C., & Silva, W. A. (2012). CAPM em estudos brasileiros: uma análise da pesquisa. *Revista de Contabilidade e Organizações*, 6(15), 95-12.
- Assaf, A., Neto, Lima, F. G., & Araújo, A. M. P. (2008). Uma proposta metodológica para o cálculo do custo de capital no Brasil. *Revista de Administração*, 43(1), 72-83.
- Aye, G., Gupta, R., Hammoudeh, S., & Kim, W. J. (2015). Forecasting the price of gold using dynamic model averaging. *International Review of Financial Analysis*, 41, 257-266.
- Baker, M., & Wurgler, J. (2006). Investor sentiment and the cross-section of stock returns. *The Journal of Finance*, 61(4), 1645-1680.
- Baker, S. R., Bloom, N., & Davis, S. J. (2016). Measuring economic policy uncertainty. *The quarterly journal of economics*, 131(4), 1593-1636.
- Becker, H. S. (1993). *Métodos de pesquisa em Ciências Sociais*. São Paulo: Hucitec.
- Ball, R., & Brown, P. (1968). An Empirical Evaluation of Accounting Income Numbers. *Journal of Accounting Research*, 6(6), 59-178.
- Barillas, F., & Shanken, J. (2018). Comparing asset pricing models. *The Journal of Finance*, 73(2), 715-754.
- Basu, S. (1983). The relationship between earnings' yield, market value and return for NYSE common stocks: Further Evidence. *Journal of Financial Economics*, 12, 129-156.
- Batista, A. R. A., Maia, U., & Romero, A. (2018). Mercado acionário sob o impeachment presidencial brasileiro de 2016: um teste na forma semiforte da hipótese do mercado eficiente. *Revista Contabilidade & Finanças*, 29, 405-417.
- Batista, T. C., Oliveira, J. F., & Macedo, M. A. (2017). Relevância da informação contábil para o mercado brasileiro de capitais: uma análise comparativa entre lucro líquido, lucro abrangente e fluxo de caixa operacional. *RACE-Revista de Administração, Contabilidade e Economia*, 16(1), 381-408.

- Beaver, W. H. (1968). The information content of annual earnings announcements. *Journal of Accounting Research*, 6(Supplement), 67-92.
- Bernardelli, L. V., & Bernardelli, A. G. (2016). Análise sobre a Relação do Mercado Acionário com as Variáveis Macroeconômicas no Período de 2004 a 2014. *Revista Evidenciação Contábil & Finanças*, 4(1), 4-17.
- Bhandari, L. C. (1988). Debt/equity ratio and expected common stock returns: Empirical evidence. *The Journal of Finance*, 43(2), 507-528.
- Black, F., & Scholes, M. (1974). The effects of dividend yield and dividend policy on common stock prices and returns. *Journal of Financial Economics*, 1(1), 1-22.
- Blanco, B. (2012). The use of CAPM and Fama and French Three Factor Model: portfolios selection. *Public and Municipal Finance*, 1(2), 61-70.
- Bortoluzzo, A. B., Venezuela, M. K., Bortoluzzo, M. M., & Nakamura, W. T. (2016). Influência da crise financeira de 2008 na previsibilidade dos modelos de apreçamento de ativos de risco no Brasil. *Revista Contabilidade & Finanças*, 27, 408-420.
- Brandão, C. S. (2013). Desempenho dos Modelos APT e CAPM no Mercado Acionário Brasileiro (Doctoral dissertation, PUC-Rio).
- Brooks, C. (2008). *Introductory Econometric for Finance*. Cambridge: Cambridge University Press.
- Buncic, D., & Moretto, C. (2015). Forecasting copper prices with dynamic averaging and selection models. *The North American Journal of Economics and Finance*, 33, 1-38.
- Campbell, J. Y., Lettau, M., Malkiel, B. G., & Xu, Y. (2001). Have individual stocks become more volatile? An empirical exploration of idiosyncratic risk. *The Journal of Finance*, 56(1), 1-43.
- Carhart, M. M. (1997). On persistence in mutual fund performance. *The Journal of Finance*, 52(1), 57-82.
- Cecchetti, S. G. (2009). Crisis and responses: the Federal Reserve in the early stages of the financial crisis. *Journal of Economic Perspectives*, 23(1), 51-75.
- Chan, K. F., & Marsh, T. (2021a). Asset pricing on earnings announcement days. *Journal of Financial Economics*, 144(3), 1022-1042.
- Chan, K. F., & Marsh, T. (2021b). Asset prices, midterm elections, and political uncertainty. *Journal of Financial Economics*, 141(1), 276-296.
- Chan, L. K. C., Hamao, Y., & Lakonishok, J. (1991). Fundamentals and stock returns in Japan. *The Journal of Finance*, 46(5), 1739-1764.
- Chen, Y., Ma, Y., Hu, Z., Xiong, T., & Wu, J. (2021). Investigating the Time-varying Effect of Search Index in Predicting Tourism Volume Using Dynamic Model Averaging. *Wuhan International Conference on e-Business*, 38-45.

- Contri, A. L. (2014). Uma avaliação da economia brasileira no Governo Dilma. *Indicadores Econômicos FEE*, 41(4), 9-20.
- Costa, H. C., Mazzeu, J. H. G., & Costa, N. C. A., Jr. (2016). O comportamento dos componentes da volatilidade das ações no Brasil. *Brazilian Review of Finance*, 14(2), 225-268.
- Costa, H. C., Porto, S. S., Jr., & Menezes, G. (2018). Um estudo empírico da dinâmica da correlação do retorno das ações do Brasil. *Brazilian Review of Finance*, 16(4), 635-667.
- Dantas, J. A., Medeiros, O. R., & Lustosa, P. R. B. (2006). Reação do mercado à alavancagem operacional: Um Estudo Empírico no Brasil. *Revista Contabilidade e Finanças da USP*, 41, 72-86.
- Dash, R., & Dash, P. K. (2016). A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science*, 2(1), 42-57.
- de Miranda, V. A. M., & de Oliveira Pamplona, E. (2000). Análise de projetos em condições de risco com a utilização da Arbitrage Pricing Theory (APT): uma aplicação no setor energético. *Revista de Administração da Universidade de São Paulo*, 35(3).
- do Lago Quinteiro, L. G., de Medeiros, O. R., & Niyama, J. K. (2020). Modelo de Cinco-Fatores de Fama e French eo risco de incerteza econômica no mercado acionário brasileiro. *GCG: revista de globalización, competitividad y gobernabilidad*, 14(1), 116-134.
- Dong, X., & Yoon, S.-M. (2019). What global economic factors drive emerging Asian stock market returns? Evidence from a dynamic model averaging approach. *Economic Modelling*, 77, 204-215.
- Drachal, K. (2019a). Analysis of agricultural commodities prices with new Bayesian model combination schemes. *Sustainability*, 11(19), 5305.
- Drachal, K. (2019b). Forecasting prices of selected metals with Bayesian data-rich models. *Resources Policy*, 64, 101528.
- Drachal, K. (2020). Forecasting the Inflation Rate in Poland and US Using Dynamic Model Averaging (DMA) and Google Queries. *Romanian Journal of Economic Forecasting*, 23(2), 18-34.
- Drachal, K., Deepmala, K., & Mishra, L. N. (2021). Forecasting Art Prices with Bayesian Models. *Thai Journal of Mathematics*, 19(2), 479-491.
- Drew, M. (2003). Beta, firm size, book-to-market equity and stock returns. *Journal of the Asia Pacific Economy*, 8(3), 354-379.
- Dweck, E., & Teixeira, R. A. (2017). *A política fiscal do governo Dilma e a crise econômica*. Recuperado de <https://www.eco.unicamp.br/images/arquivos/artigos/3532/TD303.pdf>
- Elbannan, M. A. (2015). The capital asset pricing model: an overview of the theory. *International Journal of Economics and Finance*, 7(1), 216-228.

- Fabozzi, F. J., Gupta, F., & Markowitz, H. M. (2002). The legacy of modern portfolio theory. *The Journal of Investing*, 11(3), 7-22.
- Fama, E. (1970). Efficient Capital Markets: a review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417.
- Fama, E. F., & French, K. R. (1992). The cross-section of expected stock returns. *The Journal of Finance*, 47(2), 427-465.
- Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3-56.
- Fama, E. F., & French, K. R. (2007). O modelo de precificação de Ativos de Capital: teoria e evidências. *Revista de Administração de Empresas*, 47(2), 103-118.
- Fama, E. F., & French, K. R. (2015). A Five-Factor Asset Pricing Model. *Journal of Financial Economics*, 116(1), 1-22.
- Fama, E. F., & French, K. R. (2016). Dissecting anomalies with a five-factor model. *Review of Financial Studies*, 29(1), 69-103.
- Fama, E. F., & Macbeth, J. D. (1973). Risk, return, and equilibrium: Empirical tests. *The Journal of Political Economy*, 81(3), 607-636.
- Farias, T., & Moura, F. R. (2014). Carteiras eficientes e ingênuas: uma análise comparativa com o uso do modelo de Markowitz. *Revista de Economia Mackenzie*, 11(2), 114-152.
- Fellet, B. G. (2016). *Avaliação de modelos de precificação de ativos no mercado acionário brasileiro* (Dissertação de mestrado). Universidade de Brasília, Brasília, DF, Brasil.
- Foye, J. (2018). Testing alternative versions of the Fama–French five-factor model in the UK. *Risk Management*, 20, 167-183.
- Galdi, F. C., & Lopes, A. B. (2008). Relação de longo prazo e causalidade entre o lucro contábil e o preço das ações: evidências do mercado latino-americano. *Revista de Administração da USP*, 43(2), 186-201.
- Galdi, F. C., & Lima, V. S. M. (2016). Value & Growth Investing e Pead PEAD no Brasil. *Brazilian Review of Finance*, 14(4), 551-577.
- Garcia, R., & Bonomo, M. (2001). Tests of conditional asset pricing models in the Brazilian stock market. *Journal of International Money and Finance*, 20(1), 71-90.
- Gaunt, C. (2004). Size and book to market effects and the Fama French three factor asset pricing model: evidence from the Australian stock market. *Accounting & Finance*, 44(1), 27-44.
- Gianmoena, L., & Rios, V. (2021). Forecasting the Spread of the COVID-19 Epidemic in Lombardy: A Dynamic Model Averaging Approach. *MedRXIV*, 1-53.
- Gonçalves, A. S., Iquiapaza, R. A., & Bressan, A. A. (2012). Latent Fundamentals Arbitrage with a Mixed Effects Factor Model. *Revista Brasileira de Finanças*, 10(3), 317-335.

- Greene, W. H. (2007). *Econometric analysis* 6th edition. International edition, New Jersey: Prentice Hall, 201-215.
- Gujarati, D. N. (2006). *Econometria Básica*. Prentice Hall.
- Jegadeesh, N., & Mangipudi, C. S. (2021). What do fund flows reveal about asset pricing models and investor sophistication? *The Review of Financial Studies*, 34(1), 108-148.
- Jegadeesh, N., Noh, J., Pukthuanthong, K., Roll, R., & Junbo, W. (2019). Empirical tests of asset pricing models with individual assets: Resolving the errors-in-variables bias in risk premium estimation. *Journal of Financial Economics*, 133(2), 273-298.
- Jensen, M. C., & Smith, C. W. (1984). *The modern theory of corporate finance*. São Paulo: McGraw-Hill Companies.
- Jensen, M. C., Black, F., & Scholes, M. S. (1972). *The capital asset pricing model: Some empirical tests*. New York: Praeger.
- Koop, G., & Korobilis, D. (2012). Forecasting inflation using dynamic model averaging. *International Economic Review*, 53(3), 867-886.
- Koop, G., & Tole, L. (2013). Forecasting the European carbon market. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 176(3), 723-741.
- Kothari, S. P., & Lester, R. (2012). The role of accounting in the financial crisis: Lessons for the future. *Accounting Horizons*, 26(2), 335-351.
- Leal, R. P. C. (2004). Uma ilustração da implementação do APT para carteiras de ações de valor e de crescimento brasileiras. *Revista Eletrônica de Administração*, 10(4), 1-12.
- Leite, A. L., Pinto, A. C. F., & Klotzle, M. C. (2016). Efeitos da volatilidade idiossincrática na precificação de ativos. *Revista Contabilidade & Finanças*, 27, 98-112.
- Levy, H. (1978). Equilibrium in an imperfect market: a constraint on the number of securities in the portfolio. *American Economic Review*, 68(4), 643-658.
- Lintner, J. (1965). The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. *Review of Economics and Statistics*, 47(1), 13-37.
- Liu, W. (2006). A liquidity-augmented capital asset pricing model. *Journal of Financial Economics*, 82(3), 631-671.
- Liu, X., Liang, X., & Tang, B. (2003). Behavior finance and a model of investor sentiment. *Journal of Natural Science of Heilongjiang University*, 2.
- Long, J. B., Shleifer, A., Summers, L. H., Waldmann, R. J. (1990). Positive feedback investment strategies and destabilizing rational speculation. *The Journal of Finance*, 45(2), 379-395.
- Lucena, E. R. F., Silva, C. A. T., Melo, C. L. L., & Gomes, A. M. (2013). Custo Médio Ponderado de Capital: um estudo dos erros contidos em seu cálculo nas ofertas públicas

de aquisições de ações registradas na Comissão de Valores Mobiliários (CVM). *Registro Contábil*, 4(1), 19-32.

Machado, M. A. V., & Medeiros, O. R. (2012). Existe o efeito liquidez no mercado acionário brasileiro? *Brazilian Business Review*, 9(4), 28-51.

Machado, M. A. V., & Machado, M. R. (2014). Liquidez e precificação de ativos: evidências do mercado brasileiro. *BBR-Brazilian Business Review*, 11(1), 73-95.

Maciel, C. F., Correia, L. F., Amaral, H. F., & Cavalcanti, J. M. M. (2021). Performance do modelo de cinco fatores de Fama e French na precificação de anomalias no mercado brasileiro. *Revista Contemporânea de Contabilidade*, 18(49), 145-161.

Malkiel, B. G., & Xu, Y. (2002). *Idiosyncratic risk and security returns*. University of Texas at Dallas.

Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91.

Markowitz, H. (1958). *Portfolio selection: Efficient diversification of investment*. Connecticut: Yale University Press.

Martins, G. A. (2002). *Manual para elaboração de monografia e dissertações* (3a ed.). São Paulo: Atlas.

Martins, H. C., & Gava, A. (2010). Aplicação de modelos de precificação de ativos no mercado acionário brasileiro-um teste de CAPM, D-CAPM e APT. *Anais do Encontro Nacional de Engenharia de Produção*, São Carlos, SP, Brasil, 20.

Merton, R. (1987). A Simple model of capital market equilibrium with incomplete information. *Journal of Finance*, 42(3), 483-510.

Miranda, A. P., Ceretta, P. S., & Lopes, L. F. D. (2015). Estratégias de mercado acionário utilizando previsão de redes neurais em comparação com modelos autorregressivos. *Revista de Administração da Universidade Federal de Santa Maria*, 8(1), 42-59.

Modigliani, F., & Miller, M. H. (1958). The cost of capital, corporation finance and the theory of investment. *The American Economic Review*, 48(3), 261-297.

Moreira, K. D. S., Penedo, A. S. T., Pereira, V. S., & Ambrozini, M. A. (2021). Crises e precificação de ativos no mercado de capitais brasileiro: os cinco fatores de Fama & French. *Revista Gestão Organizacional*, 14(2), 95-115.

Mossin, J. (1966). Equilibrium in a capital asset market. *Econometrica*, 34(4), 768-783.

Nagano, M. S., Merlo, E. M., & Silva, M. C. (2017). As variáveis fundamentalistas e seus impactos na taxa de retorno de ações no Brasil. *Revista da FAE*, 6(2), 13-28.

Nascimento, F. M. (2019). *A evolução das fintechs no sistema financeiro brasileiro: uma aliada ou ameaça aos bancos?* (Monografia). Universidade do Sul de Santa Catarina, Palhoça, SC, Brasil.

- Nguyen, D. K., & Bellalah, M. (2008). Stock market liberalization, structural breaks and dynamic changes in emerging market volatility. *Review of Accounting and Finance*, 7(4), 396-411.
- Nikolopoulos, K., Punia, S., Schäfers, A., Tsinopoulos, C., & Vasilakis, C. (2021). Forecasting and planning during a pandemic: COVID-19 growth rates, supply chain disruptions, and governmental decisions. *European Journal of Operational Research*, 290(1), 99-115.
- Noda, R. F., Martelanc, R., & Kayo, E. K. (2015). O Fator de Risco Lucro/Preço em Modelos de Precificação de Ativos Financeiros. *Revista Contabilidade & Finanças*, 27(70), 67-79.
- Novak, J., & Petr, D. (2011). CAPM Beta, Size, Book-to-Market, and Momentum in Realized Stock Returns. *Czech Journal of Economics and Finance (Finance a uver)*, 61(1), 447-460.
- Oda, A. L., Senger, M. C. M., & Chára, A. N. (1998). Um estudo sobre diversificação na Bolsa de Valores de São Paulo. *Anais do Encontro da Associação Nacional de Pós-Graduação em Administração (ENANAP)*, Rio de Janeiro, RJ, Brasil, 22.
- Olsen, R. A. (1998). Behavioral finance and its implications for stock-price volatility. *Financial Analysts Journal*, 54(2), 10-18.
- Oreiro, J. L. (2017). A grande recessão brasileira: diagnóstico e uma agenda de política econômica. *Estudos Avançados*, 31, 75-88.
- Otonelli, J., Grings, T. C., & Ceretta, P. S. (2016). Market factors impact on agricultural prices returns. *Organizações Rurais e Agroindustriais*, 18(3), 228-237.
- Ou, J. A., & Penman, S. R. (1989). Financial Statement Analysis and the Prediction of stocks returns. *Journal of Accounting and Economics*, 11, 295-329.
- Phuoc, L. T., Kim, K. S., & Su, Y. (2018). Reexamination of Estimating Beta Coecient as a Risk Measure in CAPM. *The Journal of Asian Finance, Economics, and Business*, 5(1), 11-16.
- Piccoli, P. G. R., Souza, A., Silva, W. V. D., & Cruz, J. A. W. (2015). Revisitando as estratégias de momento: o mercado brasileiro é realmente uma exceção?. *Revista de Administração (São Paulo)*, 50, 183-195.
- Plakandaras, V., Gupta, R., & Wong, W.-K. (2019). Point and density forecasts of oil returns: The role of geopolitical risks. *Resources Policy*, 62, 580-587.
- Quinteiro, L. G. L., Medeiros, O. R., & Niyama, J. K. (2020). Modelo de Cinco-Fatores de Fama e French e o risco de incerteza econômica no mercado acionário brasileiro. *GCG: Revista de Globalización, Competitividad y Gobernabilidad*, 14(1), 116-134.
- Raftery, A. E., Kárny, M., & Ettlér, P. (2010). Online prediction under model uncertainty via dynamic model averaging: Application to a cold rolling mill. *Technometrics*, 52(1), 52-66.

- Ribeiro, J. E., Silva, E. A., dos Santos Pires, R. C., & de Souza, A. A. (2023). Modelo de cinco fatores: desempenho na precificação de anomalias no mercado de capitais brasileiro. *Revista Foco*, 16(7), e2331-e2331.
- Roll, R. (1977). A critique of the asset pricing theory's tests Part I: On past and potential testability of the theory. *Journal of Financial Economics*, 4(2), 129-176.
- Roll, R., & Ross, S. A. (1980). An empirical investigation of the arbitrage pricing theory. *Journal of Finance*, 35(5), 1073-1103.
- Rosa, M. S. S., & Lustosa, P. R. B. (2014). Mercado e desempenho operacional contábil de longo prazo. *Revista de Administração e Contabilidade da Unisinos*, 11(1), 34-46.
- Ross, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, 13(3), 341-360.
- Ruiz, R. H. (2015). Modelo de cinco fatores de Fama e French: o caso do mercado brasileiro. *Inspere*
- Santana, R. E., Dantas, M. J. P., & Loiola, R. G. (2016). Aplicação de redes neurais para a predição no mercado de ações nacional. Anais do XLVIII SBPO, 1188-1199.
- Santiago, D. C., & Leal, R. P. C. (2015). Carteiras igualmente ponderadas com poucas ações e o pequeno investidor. *Revista de Administração Contemporânea*, 19(5), 544-564.
- Sarlo, A., Neto, Lopes, A. B., & Dalmácio, F. Z. (2010). A influência da estrutura de propriedade sobre a informatividade dos lucros contábeis divulgados pelas empresas negociadas na Bovespa. *BASE - Revista de Administração e Contabilidade da Unisinos*, 7(4), 301-314.
- Shanken, J. (1990). Intertemporal asset pricing: An empirical investigation. *Journal of Econometrics*, 45(1), 99-120.
- Sharpe, W. F. (1964). Capital asset prices: a theory of market equilibrium under conditions of risk. *Journal of Finance*, 19(3), 425-442.
- Sharpe, W. F., & Cooper, G. M. (1972). Risk-return classes of New York stock exchange common stocks, 1931-1967. *Financial Analysts Journal*, 28(2), 46-54.
- Shleifer, A., & Vishny, R. W. (1997). The limits of arbitrage. *The Journal of Finance*, 52(1), 35-55.
- Silva, A. M. C., & Medeiros, O. R. (2019). An econometric Panel-MIDAS model of asset returns in the Brazilian stock market. *GCG: revista de globalización, competitividad y gobernabilidad*, 13(2), 101-115.
- Silva, C. P., & Machado, M. A. (2015). A utilização de Redes Neurais Artificiais para previsibilidade de retornos: uma comparação com os modelos lineares CAPM e Três Fatores. *Revista de Finanças Aplicadas*, 4, 1-33.
- Silva, C. D. S. (2019) Teoria de precificação por arbitragem (APT): Um estudo sobre as companhias baianas de capital aberto (Doctoral dissertation, UESC).

- Silva, D. F., Assis, V. F., & Oliveira, J. P. L. (2020). De uma pequena corretora a um banco múltiplo estudo de caso sobre a XP investimentos. *Revista Brasileira de Desenvolvimento*, 6(11), 87593-87605.
- Silva, W. A. C., Pinto, E. A., Melo, A. O., & Camargos, M. A. (2009). Análise comparativa entre o CAPM e o C-CAPM na precificação de índices acionários: evidências de mudanças nos coeficientes estimados de 2005 à 2008. *Anais do Encontro Brasileiro de Finanças*, São Leopoldo, SP, Brasil, 9.
- Simin, T. (2008). The poor predictive performance of asset pricing models. *Journal of Financial and Quantitative Analysis*, 43(2), 355-380.
- Singh, T., Mehta, S., & Varsha, M. S. (2011). Macroeconomic factors and stock returns: Evidence from Taiwan. *Journal of Economics and International Finance*, 2(4), 217-227.
- Stambaugh, R. F., Yu, J., & Yuan, Y. (2012). The short of it: Investor sentiment and anomalies. *Journal of Financial Economics*, 104(2), 288-302.
- Strong, N., & Xu, X. G. Explaining the cross-section of UK expected stock returns. *The British Accounting Review*, 29(1), 1-23.
- Thu, L. H., & Leon-Gonzalez, R. (2021). *Forecasting Macroeconomic Variables in Emerging Economies: An Application to Vietnam*. Tokyo: National Graduate Institute for Policy Studies.
- Titman, S., Wei, K. J., & Xie, F. (2004). Capital investments and stock returns. *Journal of financial and Quantitative Analysis*, 39(4), 677-700.
- Vargas, I. F., & Santos, N. P. (2020). A Inclusão Financeira por meio de Plataformas Digitais: experiências de países emergentes e análise do estado da arte no Brasil. *Revista da Procuradoria-Geral do Banco Central*, 14(2), 49-62.
- Vieira, M. D. V., Maia, V. M., Klotzle, M. C., & Pinto, A. C. F. (2017). Modelo de Cinco Fatores de Risco: precificando carteiras setoriais no mercado acionário brasileiro. *Revista Catarinense da Ciência Contábil*, 16(48), 86-104.
- Wei, Y., & Cao, Y. (2017). Forecasting house prices using dynamic model averaging approach: Evidence from China. *Economic Modelling*, 61, 147-155.
- Wooldridge, J. M. (2002). *Econometric analysis of cross section and panel data*. Cambridge: The MIT Press.
- Xu, S., Zhang, Y., & Chen, X. (2020). Forecasting carbon emissions with dynamic model averaging approach: time-varying evidence from China. *Discrete Dynamics in Nature and Society*, 2020.
- Yusupova, A., Pavlidis, N. G., & Pavlidis, E. G. (2019). Adaptive Dynamic Model Averaging with an Application to House Price Forecasting. *ARXIV*, 1-43.

APÊNDICE

APÊNDICE A – EMPRESAS QUE FAZEM PARTE DA AMOSTRA NO PERÍODO DE 2007
À 2021

Amostra no período de 2007 à 2011

Nome	Classe	Código	Subsetor Bovespa
Alfa Consorç	ON	BRGE3	Previdência e seguros
Alpargatas	PN	ALPA4	Tecidos vestuário e calçados
Ambev S/A	ON	ABEV3	Bebidas
Ampla Energ	ON	CBEE3	Energia elétrica
Atmasa	ON	ATMP3	Serviços diversos
B Tech Eqi	ON	BLUT3	Outros
Bahema	ON	BAHI3	Diversos
Bardella	ON	BDLL3	Máquinas e equipamentos
Bradespar	PN	BRAP4	Mineração
Braskem	PNA	BRKM5	Químicos
BRF SA	ON	BRFS3	Alimentos processados
CCR SA	ON	CCRO3	Transporte
Ceb	PNB	CEBR6	Energia elétrica
Cedro	ON	CEDO3	Tecidos vestuário e calçados
Ceee-T	PN	EEEL4	Energia elétrica
Celpe	PNA	CEPE5	Energia elétrica
Cemig	PN	CMIG4	Energia elétrica
Coelba	ON	CEEB3	Energia elétrica
Coelce	PNA	COCE5	Energia elétrica
Comgas	PNA	CGAS5	Gás
Copel	PNB	CPLE6	Energia elétrica
Cosern	ON	CSRN3	Energia elétrica
Coteminas	PN	CTNM4	Tecidos vestuário e calçados
CPFL Energia	ON	CPFE3	Energia elétrica
Csu Cardsyst	ON	CARD3	Serviços financeiros diversos
Cyrela Realt	ON	CYRE3	Construção civil
Dasa	ON	DASA3	Serviços médico-hospitalares análises e diagnósticos
Dexxos Par	ON	DEXP3	Químicos
Dimed	ON	PNVL3	Comércio e distribuição
Dohler	PN	DOHL4	Tecidos vestuário e calçados
Elektro	PN	EKTR4	Energia elétrica
Eletrobras	ON	ELET3	Energia elétrica
Eletropar	ON	LIPR3	Energia elétrica
Emae	PN	EMAE4	Energia elétrica
Embraer	ON	EMBR3	Material de transporte
Energias BR	ON	ENBR3	Energia elétrica
Energisa Mt	ON	ENMT3	Energia elétrica

Engie Brasil	ON	EGIE3	Energia elétrica
Eqtl Maranhao	ON	EQMA3B	Energia elétrica
Eqtl Para	ON	EQPA3	Energia elétrica
Equatorial	ON	EQTL3	Energia elétrica
Eternit	ON	ETER3	Construção e engenharia
Eucatex	PN	EUCA4	Madeira e papel
Ferbasa	PN	FESA4	Siderurgia e metalurgia
Fras-Le	ON	FRAS3	Material de transporte
Gafisa	ON	GFSA3	Construção civil
Ger Paranap	PN	GEPA4	Energia elétrica
Gerdau	PN	GGBR4	Siderurgia e metalurgia
Gerdau Met	PN	GOAU4	Siderurgia e metalurgia
Gol	PN	GOLL4	Transporte
GP Invest	A	GPIV33	Serviços financeiros diversos
Grazziotin	PN	CGRA4	Comércio
Grendene	ON	GRND3	Tecidos vestuário e calçados
Grupo Natura	ON	NTCO3	Produtos de uso pessoal e de limpeza
Guararapes	ON	GUAR3	Comércio
Habitasul	PNA	HBTS5	Exploração de imóveis
Iguatemi SA	UNT	IGTI11	Exploração de imóveis
Inepar	ON	INEP3	Máquinas e equipamentos
Iochp-Maxion	ON	MYPK3	Automóveis e motocicletas
Joao Fortes	ON	JFEN3	Construção civil
Karsten	PN	CTKA4	Tecidos vestuário e calçados
Klabin S/A	UNT N2	KLBN11	Madeira e papel
Light S/A	ON	LIGT3	Energia elétrica
Localiza	ON	RENT3	Diversos
Lojas Renner	ON	LREN3	Comércio
Lupatech	ON	LUPA3	Petróleo gás e biocombustíveis
M.Diasbranco	ON	MDIA3	Alimentos processados
Mangels Indl	PN	MGEL4	Siderurgia e metalurgia
Marcopolo	PN	POMO4	Material de transporte
Metal Iguacu	PN	MTIG4	Embalagens
Metal Leve	ON	LEVE3	Automóveis e motocicletas
Metisa	PN	MTSA4	Máquinas e equipamentos
Mont Aranha	ON	MOAR3	Holdings diversificadas
Mundial	ON	MNDL3	Tecidos vestuário e calçados
Odontoprev	ON	ODPV3	Serviços médico-hospitalares análises e diagnósticos
Oi	ON	OIBR3	Telecomunicações
P.Acucar-Cbd	ON	PCAR3	Comércio e distribuição
Padtec	ON	PDTC3	Programas e serviços
Panatlantica	PN	PATI4	Siderurgia e metalurgia
Par Al Bahia	PN	PEAB4	Holdings diversificadas
Petrobras	PN	PETR4	Petróleo gás e biocombustíveis
Plascar Part	ON	PLAS3	Automóveis e motocicletas
Porto Seguro	ON	PSSA3	Previdência e seguros

Portobello	ON	PTBL3	Construção e engenharia
Profarma	ON	PFRM3	Comércio e distribuição
RaiaDrogasil	ON	RADL3	Comércio e distribuição
Randon Part	PN	RAPT4	Material de transporte
Rede Energia	ON	REDE3	Energia elétrica
Romi	ON	ROMI3	Máquinas e equipamentos
Rossi Resid	ON	RSID3	Construção civil
Rumo S.A.	ON	RAIL3	Transporte
Sabesp	ON	SBSP3	Água e saneamento
Sanepar	UNT N2	SAPR11	Água e saneamento
Santanense	PN	CTSA4	Tecidos vestuário e calçados
Sao Carlos	ON	SCAR3	Exploração de imóveis
Saraiva Livr	PN	SLED4	Comércio
Sid Nacional	ON	CSNA3	Siderurgia e metalurgia
Sondotecnica	PNA	SOND5	Construção e engenharia
Suzano S.A.	ON	SUZB3	Madeira e papel
Taurus Armas	PN	TASA4	Máquinas e equipamentos
Tecnosolo	PN	TCNO4	Construção e engenharia
Tekno	PN	TKNO4	Siderurgia e metalurgia
Telef Brasil	ON	VIVT3	Telecomunicações
Tim	ON	TIMS3	Telecomunicações
Totvs	ON	TOTS3	Programas e serviços
Tupy	ON	TUPY3	Material de transporte
Ultrapar	ON	UGPA3	Petróleo gás e biocombustíveis
Unipar	PNB	UNIP6	Químicos
Usiminas	PNA	USIM5	Siderurgia e metalurgia
Vale	ON	VALE3	Mineração
Valid	ON	VLID3	Serviços diversos
Via	ON	VIA3	Comércio
Weg	ON	WEGE3	Máquinas e equipamentos
Whirlpool	PN	WHRL4	Utilidades domésticas
Wlm Ind Com	PN	WLMM4	Comércio

Amostra no período de 2012 à 2016

Nome	Classe	Código	Subsetor Bovespa
Aco Altona	PN	EALT4	Máquinas e equipamentos
Alfa Consorc	ON	BRGE3	Previdência e seguros
Aliansconae	ON	ALSO3	Exploração de imóveis
Alpargatas	PN	ALPA4	Tecidos vestuário e calçados
Alper S.A.	ON	APER3	Previdência e seguros
Ambev S/A	ON	ABEV3	Bebidas
Americanas	ON	AMER3	Comércio
Ampla Energ	ON	CBEE3	Energia elétrica
Arezzo Co	ON	ARZZ3	Comércio

Atmasa	ON	ATMP3	Serviços diversos
Azevedo	PN	AZEV4	Construção e engenharia
B3	ON	B3SA3	Serviços financeiros diversos
Bahema	ON	BAHI3	Diversos
Bardella	ON	BDLL3	Máquinas e equipamentos
Baumer	PN	BALM4	Equipamentos
Bic Monark	ON	BMKS3	Viagens e lazer
BR Malls Par	ON	BRML3	Exploração de imóveis
BR Propert	ON	BRPR3	Exploração de imóveis
Bradespar	PN	BRAP4	Mineração
Brasilagro	ON	AGRO3	Agropecuária
Braskem	PNA	BRKM5	Químicos
BRF SA	ON	BRFS3	Alimentos processados
CCR SA	ON	CCRO3	Transporte
Ceb	PNB	CEBR6	Energia elétrica
Celesc	PN	CLSC4	Energia elétrica
Celpe	PNA	CEPE5	Energia elétrica
Cemig	PN	CMIG4	Energia elétrica
Cielo	ON	CIEL3	Serviços financeiros diversos
Coelba	ON	CEEB3	Energia elétrica
Coelce	PNA	COCE5	Energia elétrica
Cogna ON	ON	COGN3	Diversos
Comgas	PNA	CGAS5	Gás
Copasa	ON	CSMG3	Água e saneamento
Copel	PNB	CPLE6	Energia elétrica
Cosan	ON	CSAN3	Petróleo gás e biocombustíveis
Coteminas	PN	CTNM4	Tecidos vestuário e calçados
CPFL Energia	ON	CPFE3	Energia elétrica
Cr2	ON	CRDE3	Construção civil
Cristal	PNA	CRPG5	Químicos
Csu Cardsyst	ON	CARD3	Serviços financeiros diversos
Cyrela Realt	ON	CYRE3	Construção civil
Dasa	ON	DASA3	Serviços médico-hospitalares análises e diagnósticos
Dexco	ON	DXCO3	Madeira e papel
Dimed	ON	PNVL3	Comércio e distribuição
Direcional	ON	DIRR3	Construção civil
Dohler	PN	DOHL4	Tecidos vestuário e calçados
Dtcom Direct	ON	DTCY3	Serviços diversos
Ecorodovias	ON	ECOR3	Transporte
Elektro	PN	EKTR4	Energia elétrica
Eletrobras	ON	ELET3	Energia elétrica
Eletropar	ON	LIPR3	Energia elétrica
Emae	PN	EMAE4	Energia elétrica
Embraer	ON	EMBR3	Material de transporte
Enauta Part	ON	ENAT3	Petróleo gás e biocombustíveis
Energias BR	ON	ENBR3	Energia elétrica

Energisa	UNT N2	ENGI11	Energia elétrica
Energisa Mt	ON	ENMT3	Energia elétrica
Eneva	ON	ENEV3	Energia elétrica
Engie Brasil	ON	EGIE3	Energia elétrica
Eqtl Maranhao	ON	EQMA3B	Energia elétrica
Eqtl Para	ON	EQPA3	Energia elétrica
Equatorial	ON	EQTL3	Energia elétrica
Eternit	ON	ETER3	Construção e engenharia
Eucatex	PN	EUCA4	Madeira e papel
Even	ON	EVEN3	Construção civil
Excelsior	PN	BAUH4	Alimentos processados
Eztec	ON	EZTC3	Construção civil
Fer Heringer	ON	FHER3	Químicos
Ferbasa	PN	FESA4	Siderurgia e metalurgia
Fleury	ON	FLRY3	Serviços médico-hospitalares análises e diagnósticos
Fras-Le	ON	FRAS3	Material de transporte
Generalshopp	ON	GSHP3	Exploração de imóveis
Gerdau	PN	GGBR4	Siderurgia e metalurgia
Gerdau Met	PN	GOAU4	Siderurgia e metalurgia
Grazziotin	PN	CGRA4	Comércio
Grendene	ON	GRND3	Tecidos vestuário e calçados
Grupo Natura	ON	NTCO3	Produtos de uso pessoal e de limpeza
Guararapes	ON	GUAR3	Comércio
Habitasul	PNA	HBTS5	Exploração de imóveis
Helbor	ON	HBOR3	Construção civil
Iguatemi SA	UNT	IGTI11	Exploração de imóveis
Iochp-Maxion	ON	MYPK3	Automóveis e motocicletas
Irani	ON	RANI3	Embalagens
JBS	ON	JBSS3	Alimentos processados
JHSF Part	ON	JHSF3	Construção civil
Josapar	ON	JOPA3	Alimentos processados
Kepler Weber	ON	KEPL3	Máquinas e equipamentos
Klabin S/A	UNT N2	KLBN11	Madeira e papel
Light S/A	ON	LIGT3	Energia elétrica
Localiza	ON	RENT3	Diversos
Log-In	ON	LOGN3	Transporte
Lojas Marisa	ON	AMAR3	Comércio
Lojas Renner	ON	LREN3	Comércio
Lopes Brasil	ON	LPSB3	Exploração de imóveis
M.Diasbranco	ON	MDIA3	Alimentos processados
Magazine Luiza	ON	MGLU3	Comércio
Marcopolo	PN	POMO4	Material de transporte
Marfrig	ON	MRFG3	Alimentos processados
Metal Leve	ON	LEVE3	Automóveis e motocicletas
Metisa	PN	MTSA4	Máquinas e equipamentos
Mills	ON	MILS3	Máquinas e equipamentos

MRV	ON	MRVE3	Construção civil
Multiplan	ON	MULT3	Exploração de imóveis
Nexpe	ON	NEXP3	Exploração de imóveis
Odontoprev	ON	ODPV3	Serviços médico-hospitalares análises e diagnósticos
Oi	ON	OIBR3	Telecomunicações
Paranapanema	ON	PMAM3	Siderurgia e metalurgia
Petrobras	PN	PETR4	Petróleo gás e biocombustíveis
Petrorio	ON	PRIO3	Petróleo gás e biocombustíveis
Pettenati	ON	PTNT3	Tecidos vestuário e calçados
Porto Seguro	ON	PSSA3	Previdência e seguros
Portobello	ON	PTBL3	Construção e engenharia
Positivo Tec	ON	POSI3	Computadores e equipamentos
Profarma	ON	PFRM3	Comércio e distribuição
Qualicorp	ON	QUAL3	Serviços médico-hospitalares análises e diagnósticos
Randon Part	PN	RAPT4	Material de transporte
Renova	PN	RNEW4	Energia elétrica
Rni	ON	RDNI3	Construção civil
Romi	ON	ROMI3	Máquinas e equipamentos
Rossi Resid	ON	RSID3	Construção civil
Sabesp	ON	SBSP3	Água e saneamento
Sanepar	UNT N2	SAPR11	Água e saneamento
Santanense	PN	CTSA4	Tecidos vestuário e calçados
Santos Brp	ON	STBP3	Transporte
Sao Carlos	ON	SCAR3	Exploração de imóveis
Sao Martinho	ON	SMTO3	Alimentos processados
Saraiva	PN	SLED4	Comércio
Schulz	PN	SHUL4	Máquinas e equipamentos
Seg Al Bahia	PN	CSAB4	Previdência e seguros
Sid Nacional	ON	CSNA3	Siderurgia e metalurgia
Simpar	ON	SIMH3	Holdings diversificadas
SLC Agricola	ON	SLCE3	Agropecuária
Springs	ON	SGPS3	Tecidos vestuário e calçados
Sul America	UNT N2	SULA11	Previdência e seguros
Suzano S.A.	ON	SUZB3	Madeira e papel
Syn Prop Tec	ON	SYNE3	Exploração de imóveis
Taesa	UNT N2	TAEE11	Energia elétrica
Technos	ON	TECN3	Tecidos vestuário e calçados
Tecnisa	ON	TCSA3	Construção civil
Tegma	ON	TGMA3	Transporte
Telef Brasil	ON	VIVT3	Telecomunicações
Terrasantapa	ON	LAND3	Agropecuária
Tim	ON	TIMS3	Telecomunicações
Time For Fun	ON	SHOW3	Viagens e lazer
Totvs	ON	TOTS3	Programas e serviços
Tran Paulist	PN	TRPL4	Energia elétrica
Trisul	ON	TRIS3	Construção civil

Triunfo Part	ON	TPIS3	Transporte
Tupy	ON	TUPY3	Material de transporte
Ultrapar	ON	UGPA3	Petróleo gás e biocombustíveis
Usiminas	PNA	USIM5	Siderurgia e metalurgia
Vale	ON	VALE3	Mineração
Valid	ON	VLID3	Serviços diversos
Vulcabras	ON	VULC3	Tecidos vestuário e calçados
Weg	ON	WEGE3	Máquinas e equipamentos
Whirlpool	PN	WHRL4	Utilidades domésticas
Wilson Sons	ON	PORT3	Transporte
Wlm Ind Com	PN	WLMM4	Comércio
Yduqs Part	ON	YDUQ3	Diversos

Amostra no período de 2017 à 2021

Nome	Classe	Código	Subsetor Bovespa
AES Brasil	ON	AESB3	Energia elétrica
Afluenta T	ON	AFLT3	Energia elétrica
Alfa Consorc	ON	BRGE3	Previdência e seguros
Alianscesonae	ON	ALSO3	Exploração de imóveis
Alliar	ON	AALR3	Serviços médico-hospitalares análises e diagnósticos
Alpargatas	PN	ALPA4	Tecidos vestuário e calçados
Alper S.A.	ON	APER3	Previdência e seguros
Alupar	UNT N2	ALUP11	Energia elétrica
Ambev S/A	ON	ABEV3	Bebidas
Americanas	ON	AMER3	Comércio
Ampla Energ	ON	CBEE3	Energia elétrica
Anima	ON	ANIM3	Diversos
Arezzo Co	ON	ARZZ3	Comércio
B3	ON	B3SA3	Serviços financeiros diversos
Baumer	PN	BALM4	Equipamentos
BBSeguridade	ON	BBSE3	Previdência e seguros
Bic Monark	ON	BMKS3	Viagens e lazer
Biommm	ON	BIOM3	Medicamentos e outros produtos
BR Malls Par	ON	BRML3	Exploração de imóveis
BR Propert	ON	BRPR3	Exploração de imóveis
Bradespar	PN	BRAP4	Mineração
Brasilagro	ON	AGRO3	Agropecuária
BRF SA	ON	BRFS3	Alimentos processados
CCR SA	ON	CCRO3	Transporte
Ceb	PNB	CEBR6	Energia elétrica
Cedro	ON	CEDO3	Tecidos vestuário e calçados
Ceee-T	PN	EEEL4	Energia elétrica
Celesc	PN	CLSC4	Energia elétrica
Celpe	PNA	CEPE5	Energia elétrica

Cemig	PN	CMIG4	Energia elétrica
Cielo	ON	CIEL3	Serviços financeiros diversos
Coelba	ON	CEEB3	Energia elétrica
Coelce	PNA	COCE5	Energia elétrica
Cogna ON	ON	COGN3	Diversos
Comgas	PNA	CGAS5	Gás
Copasa	ON	CSMG3	Água e saneamento
Copel	PNB	CPLE6	Energia elétrica
Cosan	ON	CSAN3	Petróleo gás e biocombustíveis
Cosern	ON	CSRN3	Energia elétrica
CPFL Energia	ON	CPFE3	Energia elétrica
Cr2	ON	CRDE3	Construção civil
Cristal	PNA	CRPG5	Químicos
Csu Cardsyst	ON	CARD3	Serviços financeiros diversos
Cvc Brasil	ON	CVCB3	Viagens e lazer
Cyrela Realt	ON	CYRE3	Construção civil
Dasa	ON	DASA3	Serviços médico-hospitalares análises e diagnósticos
Dexco	ON	DXCO3	Madeira e papel
Dimed	ON	PNVL3	Comércio e distribuição
Direcional	ON	DIRR3	Construção civil
Dohler	PN	DOHL4	Tecidos vestuário e calçados
Dtcom Direct	ON	DTCY3	Serviços diversos
Ecorodovias	ON	ECOR3	Transporte
Elektro	PN	EKTR4	Energia elétrica
Eletropar	ON	LIPR3	Energia elétrica
Emae	PN	EMAE4	Energia elétrica
Embraer	ON	EMBR3	Material de transporte
Enauta Part	ON	ENAT3	Petróleo gás e biocombustíveis
Energias BR	ON	ENBR3	Energia elétrica
Energisa	UNT N2	ENGI11	Energia elétrica
Energisa Mt	ON	ENMT3	Energia elétrica
Eneva	ON	ENEV3	Energia elétrica
Engie Brasil	ON	EGIE3	Energia elétrica
Eqtl Maranhao	ON	EQMA3B	Energia elétrica
Eqtl Para	ON	EQPA3	Energia elétrica
Equatorial	ON	EQTL3	Energia elétrica
Eucatex	PN	EUCA4	Madeira e papel
Even	ON	EVEN3	Construção civil
Excelsior	PN	BAUH4	Alimentos processados
Eztec	ON	EZTC3	Construção civil
Ferbasa	PN	FESA4	Siderurgia e metalurgia
Fleury	ON	FLRY3	Serviços médico-hospitalares análises e diagnósticos
Fras-Le	ON	FRAS3	Material de transporte
Ger Paranap	PN	GEPA4	Energia elétrica
Gerdau	PN	GGBR4	Siderurgia e metalurgia
Gerdau Met	PN	GOAU4	Siderurgia e metalurgia

Graziotin	PN	CGRA4	Comércio
Grendene	ON	GRND3	Tecidos vestuário e calçados
Grupo Natura	ON	NTCO3	Produtos de uso pessoal e de limpeza
Guararapes	ON	GUAR3	Comércio
Helbor	ON	HBOR3	Construção civil
Hypera	ON	HYPE3	Comércio e distribuição
Iguatemi SA	UNT	IGTI11	Exploração de imóveis
Imc S/A	ON	MEAL3	Hotéis e restaurantes
Iochp-Maxion	ON	MYPK3	Automóveis e motocicletas
Irani	ON	RANI3	Embalagens
JBS	ON	JBSS3	Alimentos processados
JHSF Part	ON	JHSF3	Construção civil
Kepler Weber	ON	KEPL3	Máquinas e equipamentos
Klabin S/A	UNT N2	KLBN11	Madeira e papel
Le Lis Blanc	ON	LLIS3	Comércio
Light S/A	ON	LIGT3	Energia elétrica
Localiza	ON	RENT3	Diversos
Lojas Marisa	ON	AMAR3	Comércio
Lojas Renner	ON	LREN3	Comércio
Lopes Brasil	ON	LPSB3	Exploração de imóveis
M.Diasbranco	ON	MDIA3	Alimentos processados
Magaz Luiza	ON	MGLU3	Comércio
Marcopolo	PN	POMO4	Material de transporte
Marfrig	ON	MRF3	Alimentos processados
Metal Leve	ON	LEVE3	Automóveis e motocicletas
Metisa	PN	MTSA4	Máquinas e equipamentos
MRV	ON	MRVE3	Construção civil
Multiplan	ON	MULT3	Exploração de imóveis
Odontoprev	ON	ODPV3	Serviços médico-hospitalares análises e diagnósticos
Ourofino S/A	ON	OFS3	Medicamentos e outros produtos
Par Al Bahia	PN	PEAB4	Holdings diversificadas
Petrobras	PN	PETR4	Petróleo gás e biocombustíveis
Petrorio	ON	PRIO3	Petróleo gás e biocombustíveis
Pettenati	ON	PTNT3	Tecidos vestuário e calçados
Porto Seguro	ON	PSSA3	Previdência e seguros
Portobello	ON	PTBL3	Construção e engenharia
Positivo Tec	ON	POS3	Computadores e equipamentos
Profarma	ON	PFRM3	Comércio e distribuição
Qualicorp	ON	QUAL3	Serviços médico-hospitalares análises e diagnósticos
RaiaDrogasil	ON	RADL3	Comércio e distribuição
Randon Part	PN	RAPT4	Material de transporte
Rede Energia	ON	REDE3	Energia elétrica
Rni	ON	RDNI3	Construção civil
Romi	ON	ROMI3	Máquinas e equipamentos
Sabesp	ON	SBSP3	Água e saneamento
Sanepar	UNT N2	SAPR11	Água e saneamento

Santanense	PN	CTSA4	Tecidos vestuário e calçados
Santos Brp	ON	STBP3	Transporte
Sao Carlos	ON	SCAR3	Exploração de imóveis
Sao Martinho	ON	SMT03	Alimentos processados
Schulz	PN	SHUL4	Máquinas e equipamentos
Seg Al Bahia	PN	CSAB4	Previdência e seguros
Ser Educa	ON	SEER3	Diversos
Sid Nacional	ON	CSNA3	Siderurgia e metalurgia
Simpar	ON	SIMH3	Holdings diversificadas
Sinqia	ON	SQIA3	Programas e serviços
SLC Agricola	ON	SLCE3	Agropecuária
Sul America	UNT N2	SULA11	Previdência e seguros
Suzano S.A.	ON	SUZB3	Madeira e papel
Syn Prop Tec	ON	SYNE3	Exploração de imóveis
Taesa	UNT N2	TAEE11	Energia elétrica
Technos	ON	TECN3	Tecidos vestuário e calçados
Tecnisa	ON	TCSA3	Construção civil
Tecnosolo	PN	TCNO4	Construção e engenharia
Tegma	ON	TGMA3	Transporte
Tekno	PN	TKNO4	Siderurgia e metalurgia
Telef Brasil	ON	VIVT3	Telecomunicações
Terrasantapa	ON	LAND3	Agropecuária
Tim	ON	TIMS3	Telecomunicações
Time For Fun	ON	SHOW3	Viagens e lazer
Totvs	ON	TOTS3	Programas e serviços
Tran Paulist	PN	TRPL4	Energia elétrica
Trisul	ON	TRIS3	Construção civil
Triunfo Part	ON	TPIS3	Transporte
Tupy	ON	TUPY3	Material de transporte
Ultrapar	ON	UGPA3	Petróleo gás e biocombustíveis
Unicasa	ON	UCAS3	Utilidades domésticas
Usiminas	PNA	USIM5	Siderurgia e metalurgia
Vale	ON	VALE3	Mineração
Valid	ON	VLID3	Serviços diversos
Via	ON	VIIA3	Comércio
Vulcabras	ON	VULC3	Tecidos vestuário e calçados
Weg	ON	WEGE3	Máquinas e equipamentos
Whirlpool	PN	WHRL4	Utilidades domésticas
Wilson Sons	ON	PORT3	Transporte
Wiz S.A.	ON	WIZS3	Previdência e seguros
Wlm Ind Com	PN	WLMM4	Comércio
Yduqs Part	ON	YDUQ3	Diversos

APÊNDICE B – TESTES DE QUEBRA ESTRUTURAL

Quandt-Andrews unknown breakpoint test
 Null Hypothesis: No breakpoints within 15% trimmed data
 Varying regressors: All equation variables
 Equation Sample: 2007M01 2011M12
 Test Sample: 2007M10 2011M04
 Number of breaks compared: 43

Statistic	Value	Prob.
Maximum LR F-statistic (2007M11)	3.049316	0.5438
Maximum Wald F-statistic (2007M11)	3.049316	0.5438
Exp LR F-statistic	0.601737	0.3691
Exp Wald F-statistic	0.601737	0.3691
Ave LR F-statistic	1.059625	0.3178
Ave Wald F-statistic	1.059625	0.3178

Note: probabilities calculated using Hansen's (1997) method

Quandt-Andrews unknown breakpoint test
 Null Hypothesis: No breakpoints within 15% trimmed data
 Varying regressors: All equation variables
 Equation Sample: 2012M01 2016M12
 Test Sample: 2012M10 2016M04
 Number of breaks compared: 43

Statistic	Value	Prob.
Maximum LR F-statistic (2014M10)	1.226923	0.9662
Maximum Wald F-statistic (2014M10)	1.226923	0.9662
Exp LR F-statistic	0.271808	0.6816
Exp Wald F-statistic	0.271808	0.6816
Ave LR F-statistic	0.524102	0.6260
Ave Wald F-statistic	0.524102	0.6260

Quandt-Andrews unknown breakpoint test
 Null Hypothesis: No breakpoints within 15% trimmed data
 Varying regressors: All equation variables
 Equation Sample: 2017M01 2021M12
 Test Sample: 2017M10 2021M04
 Number of breaks compared: 43

Statistic	Value	Prob.
Maximum LR F-statistic (2020M01)	1.021532	0.9969
Maximum Wald F-statistic (2020M01)	1.021532	0.9969
Exp LR F-statistic	0.188596	0.8165
Exp Wald F-statistic	0.188596	0.8165
Ave LR F-statistic	0.356807	0.7768
Ave Wald F-statistic	0.356807	0.7768

APÊNDICE C – TESTES DE RAÍZ UNITÁRIA

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
R_P58, R_P59, R_P60, RMRF, SMB, HML, RMW, CMA

Date: 11/20/23 Time: 11:21

Sample: 2007M01 2011M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 1

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections
Null: Unit root (assumes common unit root process)			
Levin, Lin & Chu t*	-39.5371	0.0000	65
Null: Unit root (assumes individual unit root process)			
Im, Pesaran and Shin W-stat	-34.4422	0.0000	65
ADF - Fisher Chi-square	1290.90	0.0000	65
PP - Fisher Chi-square	1289.03	0.0000	65

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
R_P58, R_P59, R_P60, RMRF, PIB, EM, MC, ICC

Date: 11/20/23 Time: 14:53

Sample: 2007M01 2011M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 1

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-34.4040	0.0000	65	3834
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-32.3058	0.0000	65	3834
ADF - Fisher Chi-square	1199.62	0.0000	65	3834
PP - Fisher Chi-square	1192.21	0.0000	65	3835

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
 R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
 R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
 R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
 R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
 R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
 R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
 R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
 R_P58, R_P59, R_P60, RMRF, SMB, HML, RMW, CMA

Date: 11/20/23 Time: 17:12

Sample: 2012M01 2016M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 1

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-52.7072	0.0000	65	3834
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-44.8218	0.0000	65	3834
ADF - Fisher Chi-square	1796.02	0.0000	65	3834
PP - Fisher Chi-square	1786.73	0.0000	65	3835

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
 R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
 R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
 R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
 R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
 R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
 R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
 R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
 R_P58, R_P59, R_P60, RMRF, PIB, BNEPU, ISAESP, PPET

Date: 11/20/23 Time: 17:10

Sample: 2012M01 2016M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 5

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-47.9281	0.0000	65	3829
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-42.8024	0.0000	65	3829
ADF - Fisher Chi-square	1708.55	0.0000	65	3829
PP - Fisher Chi-square	1740.46	0.0000	65	3835

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
 R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
 R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
 R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
 R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
 R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
 R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
 R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
 R_P58, R_P59, R_P60, RMRF, SMB, HML, RMW, CMA

Date: 11/21/23 Time: 08:14

Sample: 2017M01 2021M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 2

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-53.6417	0.0000	65	3829
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-46.7346	0.0000	65	3829
ADF - Fisher Chi-square	1891.47	0.0000	65	3829
PP - Fisher Chi-square	2252.98	0.0000	65	3835

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Pool unit root test: Summary

Series: R_P1, R_P2, R_P3, R_P4, R_P5, R_P6, R_P7, R_P8,
 R_P9, R_P10, R_P11, R_P12, R_P13, R_P14, R_P15,
 R_P16, R_P17, R_P18, R_P19, R_P20, R_P21, R_P22,
 R_P23, R_P24, R_P25, R_P26, R_P27, R_P28, R_P29,
 R_P30, R_P31, R_P32, R_P33, R_P34, R_P35, R_P36,
 R_P37, R_P38, R_P39, R_P40, R_P41, R_P42, R_P43,
 R_P44, R_P45, R_P46, R_P47, R_P48, R_P49, R_P50,
 R_P51, R_P52, R_P53, R_P54, R_P55, R_P56, R_P57,
 R_P58, R_P59, R_P60, RMRF, DINF, IEESP, PPET, PIB

Date: 11/21/23 Time: 08:12

Sample: 2017M01 2021M12

Exogenous variables: Individual effects

Automatic selection of maximum lags

Automatic lag length selection based on SIC: 0 to 2

Newey-West automatic bandwidth selection and Bartlett kernel

Method	Statistic	Prob.**	Cross- sections	Obs
Null: Unit root (assumes common unit root process)				
Levin, Lin & Chu t*	-52.7296	0.0000	65	3829
Null: Unit root (assumes individual unit root process)				
Im, Pesaran and Shin W-stat	-47.4039	0.0000	65	3829
ADF - Fisher Chi-square	1908.95	0.0000	65	3829
PP - Fisher Chi-square	2256.00	0.0000	65	3835

** Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

APÊNDICE D – RESULTADOS DAS REGRESSÕES

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/20/23 Time: 09:39
 Sample: 2007M01 2011M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004447	0.003530	-1.259834	0.2078
RMRF	0.702181	0.068195	10.29660	0.0000
SMB	0.340139	0.089223	3.812236	0.0001
HML	0.181781	0.078442	2.317397	0.0205
RMW	0.233636	0.090793	2.573269	0.0101
CMA	0.148844	0.068588	2.170119	0.0301
Root MSE	0.030303	R-squared		0.803959
Mean dependent var	-0.007703	Adjusted R-squared		0.803686
S.D. dependent var	0.068449	S.E. of regression		0.030328
Akaike info criterion	-4.151829	Sum squared resid		3.305705
Schwarz criterion	-4.141514	Log likelihood		7479.292
Hannan-Quinn criter.	-4.148153	F-statistic		2947.783
Durbin-Watson stat	1.924716	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/17/23 Time: 15:19
 Sample: 2007M01 2011M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.013792	0.009216	1.496554	0.1346
RMRF	0.697408	0.065760	10.60532	0.0000
SMB	0.324145	0.086314	3.755405	0.0002
HML	0.175081	0.075662	2.313988	0.0207
CMA	0.128924	0.066759	1.931190	0.0535
RMW	0.220224	0.087727	2.510340	0.0121
DCRISE	-0.021188	0.009950	-2.129468	0.0333
Root MSE	0.029473	R-squared		0.814547
Mean dependent var	-0.007703	Adjusted R-squared		0.814237
S.D. dependent var	0.068449	S.E. of regression		0.029502
Akaike info criterion	-4.206794	Sum squared resid		3.127174
Schwarz criterion	-4.194760	Log likelihood		7579.228
Hannan-Quinn criter.	-4.202505	F-statistic		2630.193
Durbin-Watson stat	2.023692	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
Method: Pooled Least Squares
Date: 11/20/23 Time: 09:52
Sample: 2012M01 2016M12
Included observations: 60
Cross-sections included: 60
Total pool (balanced) observations: 3600
Cross-section SUR (PCSE) standard errors & covariance (d.f.
corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002163	0.002311	0.935691	0.3495
RMRF	0.893110	0.053754	16.61467	0.0000
SMB	0.228569	0.059543	3.838695	0.0001
HML	0.128818	0.059601	2.161329	0.0307
RMW	0.024815	0.032222	0.770133	0.4413
CMA	0.056574	0.033730	1.677240	0.0936
Root MSE	0.022612	R-squared		0.825292
Mean dependent var	-0.017548	Adjusted R-squared		0.825048
S.D. dependent var	0.054105	S.E. of regression		0.022631
Akaike info criterion	-4.737349	Sum squared resid		1.840670
Schwarz criterion	-4.727035	Log likelihood		8533.229
Hannan-Quinn criter.	-4.733673	F-statistic		3395.483
Durbin-Watson stat	2.149032	Prob(F-statistic)		0.000000

Dependent Variable: R4?-CDI
Method: Pooled Least Squares
Date: 11/20/23 Time: 10:04
Sample: 2012M01 2016M12
Included observations: 60
Cross-sections included: 60
Total pool (balanced) observations: 3600
Cross-section SUR (PCSE) standard errors & covariance (d.f.
corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002243	0.002342	0.957539	0.3384
RMRF	0.892296	0.053882	16.56023	0.0000
SMB	0.229347	0.059645	3.845190	0.0001
HML	0.129356	0.059643	2.168850	0.0302
RMW	0.025311	0.032301	0.783585	0.4333
CMA	0.056522	0.033723	1.676051	0.0938
DCRISE	-0.002177	0.010388	-0.209538	0.8340
Root MSE	0.022609	R-squared		0.825343
Mean dependent var	-0.017548	Adjusted R-squared		0.825051
S.D. dependent var	0.054105	S.E. of regression		0.022631
Akaike info criterion	-4.737088	Sum squared resid		1.840128
Schwarz criterion	-4.725055	Log likelihood		8533.759
Hannan-Quinn criter.	-4.732800	F-statistic		2829.791
Durbin-Watson stat	2.147797	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
Method: Pooled Least Squares
Date: 11/20/23 Time: 10:22
Sample: 2017M01 2021M12
Included observations: 60
Cross-sections included: 60
Total pool (balanced) observations: 3600
Cross-section SUR (PCSE) standard errors & covariance (d.f.
corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000501	0.002432	-0.205810	0.8370
RMRF	0.893074	0.041343	21.60179	0.0000
SMB	0.542623	0.077558	6.996396	0.0000
HML	-0.251450	0.119322	-2.107329	0.0352
RMW	-0.130153	0.110295	-1.180052	0.2381
CMA	0.253224	0.102140	2.479173	0.0132
Root MSE	0.027126	R-squared		0.889842
Mean dependent var	0.003924	Adjusted R-squared		0.889689
S.D. dependent var	0.081741	S.E. of regression		0.027149
Akaike info criterion	-4.373317	Sum squared resid		2.648945
Schwarz criterion	-4.363003	Log likelihood		7877.971
Hannan-Quinn criter.	-4.369641	F-statistic		5806.388
Durbin-Watson stat	1.721292	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
Method: Pooled Least Squares
Date: 11/20/23 Time: 10:45
Sample: 2017M01 2021M12
Included observations: 60
Cross-sections included: 60
Total pool (balanced) observations: 3600
Cross-section SUR (PCSE) standard errors & covariance (d.f.
corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004278	0.002696	1.586685	0.1127
RMRF	0.891367	0.038168	23.35394	0.0000
SMB	0.552716	0.071664	7.712610	0.0000
HML	-0.251502	0.110148	-2.283311	0.0225
RMW	-0.101530	0.102207	-0.993381	0.3206
CMA	0.236775	0.094427	2.507483	0.0122
DCRISE	-0.013575	0.004242	-3.199917	0.0014
Root MSE	0.026339	R-squared		0.896142
Mean dependent var	0.003924	Adjusted R-squared		0.895968
S.D. dependent var	0.081741	S.E. of regression		0.026365
Akaike info criterion	-4.431646	Sum squared resid		2.497466
Schwarz criterion	-4.419613	Log likelihood		7983.964
Hannan-Quinn criter.	-4.427358	F-statistic		5167.030
Durbin-Watson stat	1.805820	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/20/23 Time: 14:36
 Sample: 2007M01 2011M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.035251	0.090071	0.391367	0.6955
RMRF	0.676951	0.058928	11.48771	0.0000
PIB	-0.238953	0.090904	-2.628624	0.0086
EM	-0.041601	0.008960	-4.642925	0.0000
MC	0.098423	0.050920	1.932896	0.0533
ICC	-0.130345	0.062057	-2.100412	0.0358
Root MSE	0.031245	R-squared		0.791575
Mean dependent var	-0.007703	Adjusted R-squared		0.791285
S.D. dependent var	0.068449	S.E. of regression		0.031271
Akaike info criterion	-4.090574	Sum squared resid		3.514525
Schwarz criterion	-4.080260	Log likelihood		7369.034
Hannan-Quinn criter.	-4.086898	F-statistic		2729.928
Durbin-Watson stat	1.852133	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/29/23 Time: 18:41
 Sample: 2007M01 2011M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.029086	0.094802	0.306808	0.7590
RMRF	0.680093	0.060820	11.18200	0.0000
PIB	-0.238192	0.090957	-2.618729	0.0089
EM	-0.040520	0.010355	-3.913083	0.0001
MC	0.099492	0.051167	1.944452	0.0519
ICC	-0.122942	0.071527	-1.718822	0.0857
DCRISE	-0.002857	0.013734	-0.208004	0.8352
Root MSE	0.031236	R-squared		0.791693
Mean dependent var	-0.007703	Adjusted R-squared		0.791345
S.D. dependent var	0.068449	S.E. of regression		0.031267
Akaike info criterion	-4.090584	Sum squared resid		3.512539
Schwarz criterion	-4.078550	Log likelihood		7370.051
Hannan-Quinn criter.	-4.086296	F-statistic		2275.932
Durbin-Watson stat	1.856146	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/20/23 Time: 17:06
 Sample: 2012M01 2016M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.021146	0.017924	-1.179751	0.2382
RMRF	0.962615	0.039632	24.28879	0.0000
PIB	0.103941	0.052725	1.971394	0.0488
BNEPU	-0.005746	0.002242	-2.563477	0.0104
ISAESP	0.308823	0.124919	2.472194	0.0135
PPET	0.029750	0.019456	1.529122	0.1263
Root MSE	0.022611	R-squared		0.825298
Mean dependent var	-0.017548	Adjusted R-squared		0.825055
S.D. dependent var	0.054105	S.E. of regression		0.022630
Akaike info criterion	-4.737388	Sum squared resid		1.840598
Schwarz criterion	-4.727074	Log likelihood		8533.299
Hannan-Quinn criter.	-4.733712	F-statistic		3395.643
Durbin-Watson stat	2.155401	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/20/23 Time: 18:35
 Sample: 2012M01 2016M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.021412	0.018020	-1.188228	0.2348
RMRF	0.961967	0.039890	24.11570	0.0000
PIB	0.103949	0.052723	1.971617	0.0487
BNEPU	-0.005710	0.002255	-2.532005	0.0114
ISAESP	0.310870	0.125735	2.472416	0.0135
PPET	0.030001	0.019534	1.535810	0.1247
DCRISE	-0.001523	0.010675	-0.142698	0.8865
Root MSE	0.022610	R-squared		0.825322
Mean dependent var	-0.017548	Adjusted R-squared		0.825031
S.D. dependent var	0.054105	S.E. of regression		0.022632
Akaike info criterion	-4.736969	Sum squared resid		1.840347
Schwarz criterion	-4.724936	Log likelihood		8533.545
Hannan-Quinn criter.	-4.732681	F-statistic		2829.384
Durbin-Watson stat	2.155891	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/21/23 Time: 08:06
 Sample: 2017M01 2021M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.004899	0.003826	1.280560	0.2004
RMRF	1.006452	0.044911	22.40975	0.0000
DINF	-2.24E-05	9.63E-06	-2.329071	0.0199
IEESP	0.069479	0.043021	1.614998	0.1064
PPET	0.105447	0.054232	1.944366	0.0519
PIB	-0.163503	0.095375	-1.714323	0.0866
Root MSE	0.031639	R-squared		0.850142
Mean dependent var	0.003924	Adjusted R-squared		0.849934
S.D. dependent var	0.081741	S.E. of regression		0.031665
Akaike info criterion	-4.065543	Sum squared resid		3.603609
Schwarz criterion	-4.055228	Log likelihood		7323.977
Hannan-Quinn criter.	-4.061867	F-statistic		4077.743
Durbin-Watson stat	1.905183	Prob(F-statistic)		0.000000

Dependent Variable: R?-CDI
 Method: Pooled Least Squares
 Date: 11/29/23 Time: 18:49
 Sample: 2017M01 2021M12
 Included observations: 60
 Cross-sections included: 60
 Total pool (balanced) observations: 3600
 Cross-section SUR (PCSE) standard errors & covariance (d.f.
 corrected)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.003932	0.003694	1.064608	0.2871
RMRF	0.922702	0.056710	16.27041	0.0000
DINF	-1.02E-05	1.07E-05	-0.959122	0.3376
IEESP	0.057092	0.041619	1.371786	0.1702
PPET	0.126052	0.052798	2.387453	0.0170
PIB	-0.169329	0.091506	-1.850474	0.0643
DCRISE	-0.082961	0.036542	-2.270311	0.0232
Root MSE	0.030932	R-squared		0.856759
Mean dependent var	0.003924	Adjusted R-squared		0.856520
S.D. dependent var	0.081741	S.E. of regression		0.030962
Akaike info criterion	-4.110148	Sum squared resid		3.444487
Schwarz criterion	-4.098115	Log likelihood		7405.267
Hannan-Quinn criter.	-4.105860	F-statistic		3581.774
Durbin-Watson stat	1.794808	Prob(F-statistic)		0.000000