

UNIVERSIDADE FEDERAL DE OURO PRETO – UFOP
INSTITUTO DE CIÊNCIAS SOCIAIS APLICADAS – ICSA
DEPARTAMENTO DE CIÊNCIAS ECONÔMICAS – DEECO

**ANÁLISE DE MODELOS QUANTITATIVOS E APLICAÇÃO EM CARTEIRA DE
INVESTIMENTO**

THULIO AJANO TAVARES

MARIANA – MG

2025

THULIO AJANO TAVARES

**ANÁLISE DE MODELOS QUANTITATIVOS E APLICAÇÃO EM CARTEIRA DE
INVESTIMENTO**

Trabalho de Conclusão de Curso apresentado ao Curso de Ciências Econômicas da Universidade Federal de Ouro Preto como requisito parcial para a obtenção do título de Bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Chrystian Soares Mendes

MARIANA – MG

DEECO / ICSA / UFOP

2025

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

T231a Tavares, Thulio Ajano.
Análise de modelos quantitativos e aplicação em carteira de investimento. [manuscrito] / Thulio Ajano Tavares. - 2025.
48 f.: il.: gráf., tab.. + Código Python.

Orientador: Prof. Dr. Chrystian Soares Mendes.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Sociais Aplicadas. Graduação em Ciências Econômicas .

1. Otimização de Portfólio. 2. Teoria de Markowitz. 3. Índice Sharpe. I. Mendes, Chrystian Soares. II. Universidade Federal de Ouro Preto. III. Título.

CDU 519.85

Bibliotecário(a) Responsável: Angela Maria Raimundo - SIAPE: 1.644.803



FOLHA DE APROVAÇÃO

Thulio Ajano Tavares

Análise de modelos quantitativos e aplicação em carteira de investimento

Monografia apresentada ao Curso de Ciências Econômicas da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciências Econômicas

Aprovada em 09 de setembro de 2025

Membros da banca

Prof. Dr. Chrystian Soares Mendes - Orientador - (Universidade Federal de Ouro Preto)
Prof. Dr. Getúlio Alves de Souza Matos - (Universidade Federal de Ouro Preto)
Prof. Dr. Thiago de Sousa Barros - (Universidade Federal de Ouro Preto)

Prof. Dr. Chrystian Soares Mendes, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 16/09/2025.



Documento assinado eletronicamente por **Chrystian Soares Mendes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 10/10/2025, às 15:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0994641** e o código CRC **8FBC8156**.

AGRADECIMENTOS

Primeiramente, agradeço a Deus, pela força, sabedoria e pelas oportunidades que me guiaram até aqui. Sem a fé e a confiança de que cada desafio tem um propósito, dificilmente teria chegado a este momento. Aos meus pais, deixo minha eterna gratidão pelo amor incondicional, pela educação e pelos valores que sempre me transmitiram. Foram eles que me ensinaram a importância da disciplina, da dedicação e da honestidade, pilares que sustentaram não apenas este trabalho, mas também toda a minha trajetória. À minha namorada, agradeço por ter sido um ponto constante de apoio, ajuda e perseverança. À minha família, em especial à minha irmã, pelo apoio e paciência nos momentos de maior pressão, e aos meus avós Assis e Torquato, que permanecem vivos em minha memória. A coragem, a simplicidade e a sabedoria deles foram fonte de inspiração e me mostraram, desde cedo, o verdadeiro significado de resiliência. Dedico este trabalho à sua lembrança, com carinho e saudade.

Agradeço à Universidade Federal de Ouro Preto (UFOP), por ter sido um espaço de crescimento acadêmico e pessoal. Aos professores do Departamento de Economia, que foram fundamentais na construção do conhecimento que me trouxe até aqui, deixo minha sincera gratidão. De modo especial, a meu orientador, Professor Chrystian Soares Mendes, pela paciência e pelas críticas construtivas, que foram essenciais para transformar este projeto em realidade.

Não poderia deixar de agradecer aos amigos que estiveram ao meu lado nessa jornada, tornando os dias mais leves e os desafios mais suportáveis. Em especial, à República Marragolo, que se tornou uma segunda família e deixou marcas que levarei para a vida.

"Todos os modelos estão errados, mas alguns são úteis."

(George E. P. Box)

RESUMO

O presente trabalho analisa a eficácia empírica da Teoria Moderna de Portfólios na construção de carteiras de investimento a partir de 20 ações de alta liquidez do Ibovespa. A pesquisa avalia o desempenho em duas conjunturas macroeconômicas distintas: 2017-2019 (de estabilidade e juros em queda) e 2022-2024 (de alta volatilidade e juros elevados). Inicialmente, a metodologia confrontou a otimização clássica de Markowitz, com retornos estimados pelo CAPM, contra benchmarks de diversificação ingênua (pesos iguais 1/N) e de mercado (IBOVESPA). Os resultados empíricos demonstraram uma notável fragilidade no modelo canônico: no cenário adverso de 2022-2024, a otimização padrão gerou uma carteira perigosamente concentrada e ineficiente, sendo consistentemente superada pela robusta estratégia 1/N. Diante desta constatação, o estudo propôs e testou uma abordagem adaptativa, a "Carteira Ideal", que implementa um filtro de qualidade prévio, otimizando apenas os ativos que demonstraram Índice de Sharpe positivo. Esta estratégia híbrida provou ser dominante, mitigando o risco de concentração e superando todas as demais abordagens no cenário de juros altos, alcançando um Índice de Sharpe de 1,1298. Conclui-se que, devido à sensibilidade dos modelos de otimização a erros de estimação, metodologias que integram filtros de seleção à otimização quantitativa representam um caminho mais robusto e eficiente para a gestão de ativos em mercados voláteis.

Palavras-chave: Gestão de Risco; Teoria de Markowitz; Otimização de Portfólio; Índice de Sharpe; CAPM.

ABSTRACT

This study analyzes the empirical effectiveness of Modern Portfolio Theory in constructing investment portfolios based on 20 highly liquid Ibovespa stocks. The research evaluates performance across two distinct macroeconomic contexts: 2017–2019 (a period of stability and declining interest rates) and 2022–2024 (a period of high volatility and rising interest rates). The methodology first compared the classical Markowitz optimization, with returns estimated through CAPM, against two benchmarks: naïve diversification (equal weights $1/N$) and the market portfolio (Ibovespa). Empirical results revealed a remarkable weakness in the canonical model: in the adverse 2022–2024 environment, standard optimization produced a dangerously concentrated and inefficient portfolio, consistently underperforming the more resilient $1/N$ strategy. In light of this, the study proposed and tested an adaptive approach, the "Ideal Portfolio," which applies a prior quality filter by optimizing only assets with positive Sharpe Ratios. This hybrid strategy proved to be dominant, mitigating concentration risk and outperforming all other approaches under high-interest rate conditions, achieving a Sharpe Ratio of 1.1298. The findings suggest that, due to the sensitivity of optimization models to estimation errors, methodologies integrating selection filters into quantitative optimization represent a more robust and efficient path for asset management in volatile markets.

Keywords: Risk Management; Markowitz Theory; Portfolio Optimization; Sharpe Ratio; CAPM.

LISTA DE FIGURAS

Figura 2 - Fronteira eficiente de Markowitz	14
Figura 3.1 - Preparação de dados - Parte 1	51
Figura 3.2 - Preparação de dados - Parte 2	51
Figura 3.3 - Preparação de dados - Parte 3	52
Figura 3.4 - Cálculo Métricas Básicas de Desempenho	52
Figura 3.5 - Cálculo CAPM e Sharpe - Parte 1	53
Figura 3.6 - Cálculo CAPM e Sharpe - Parte 2	53
Figura 3.7 - Otimização de Portfólio (Markowitz) - Parte 1	54
Figura 3.8 - Otimização de Portfólio (Markowitz) - Parte 2	54
Figura 3.9 - Otimização de Portfólio (Ideal) - Parte 1	55
Figura 3.10 - Otimização de Portfólio (Ideal) - Parte 2	55
Figura 3.11 - Construção das Carteiras.....	56
Figura 3.12 - Comparação de Performance das Carteiras - Parte 1.....	57
Figura 3.13 - Comparação de Performance das Carteiras - Parte 2.....	58

LISTA DE TABELAS

Tabela 2.4 - Panorama dos Modelos de Gestão de Risco e Otimização de Portfólio.....	20
Tabela 4.1 - Métricas Básicas dos Ativos (2017-2019).....	36
Tabela 4.2 - Resultados CAPM e Índice de Sharpe por Ativo (2017-2019)	37
Tabela 4.3 - Análise Descritiva dos Ativos (2017-2019).....	38
Tabela 4.4 - Pesos da Carteira Otimizada (Markowitz) para (2017-2019).....	59
Tabela 4.5 - Pesos da Carteira Equilibrada para (2017-2019).....	59
Tabela 4.6 - Métricas do Portfólio Otimizado (2017-2019)	39
Tabela 4.7 - Métricas da Carteira Equilibrada (1/N) para (2017-2019)	39
Tabela 4.8 - Comparativo de Performance Anualizada (2017-2019)	40
Tabela 4.9 - Métricas Básicas dos Ativos (2022-2024).....	41
Tabela 4.10 - Resultados CAPM e Índice de Sharpe por Ativo (2022-2024)	42
Tabela 4.11 - Análise Descritiva dos Ativos (2022-2024).....	43
Tabela 4.12 - Pesos da Carteira Otimizada (Markowitz) para (2022-2024).....	60
Tabela 4.13 - Pesos da Carteira Equilibrada para (2022-2024).....	60
Tabela 4.14 - Pesos da Carteira Otimizada (Ideal) para (2022-2024)	60
Tabela 4.15 - Métricas do Portfólio Otimizado (2022-2024)	44
Tabela 4.16 - Métricas da Carteira Equilibrada (1/N) para (2022-2024)	44
Tabela 4.17 - Métricas do Portfólio Otimizado Ideal (2022-2024)	44
Tabela 4.18 - Comparativo de Performance Anualizada (2022-2024)	45

SUMÁRIO

INTRODUÇÃO.....	10
1.1 Justificativa.....	11
1.2 Objetivos.....	12
1.2.1 Objetivo Geral	12
1.2.2 Objetivos Específicos	12
REFERENCIAL TEÓRICO	13
2.1 Risco e Incerteza.....	14
2.2 Análise de risco.....	14
2.3 Tipos de Risco	15
2.3.1 Riscos Financeiros.....	15
2.3.1.1 Risco de Mercado	16
2.3.1.2 Riscos de Crédito.....	16
2.3.1.3 Risco de Liquidez.....	17
2.3.1.4 Risco Operacional	18
2.3.1.5 Risco Legal.....	19
2.4 Modelos de análise de risco.....	19
2.4.1 Value at Risk (VaR)	21
2.4.2 Índice de Sharpe	22
2.4.3 CAPM.....	24
2.4.4 Teoria de Markowitz.....	27
3 MATERIAIS E MÉTODOS	30
3.1 Coleta e Preparação dos Dados	31

3.2 Cálculo dos Retornos e Métricas de Desempenho	32
3.3 Estimação dos Parâmetros do Modelo (CAPM).....	32
3.4 Otimização de Portfólio (Markowitz).....	33
3.5 Otimização de Portfólio (Ideal)	33
3.6 Construção de Carteiras.....	34
3.7 Análise de Risco e Comparação de Desempenho Final	34
4 ANÁLISES E RESULTADOS	35
4.1 Análise do Período de 2017-2019.....	35
4.1.1 Análise Individual dos Ativos.....	35
4.1.2 Composição das Carteiras e Comparação de Desempenho.....	38
4.2 Análise do Período de 2022-2024.....	40
4.2.1 Análise Individual dos Ativos.....	40
4.2.2 Composição das Carteiras e Comparação de Desempenho.....	44
4.3 Discussão Consolidada dos Resultados.....	45
5 CONCLUSÃO.....	47
REFERÊNCIAS	49
APÊNDICE	51

1 INTRODUÇÃO

A análise de riscos, ressalta que tudo o que oscila não pode ser previsto com precisão (GUNTHER, 1985). A natureza dinâmica e competitiva dos mercados financeiros tornou a gestão de risco uma preocupação crucial para investidores e gestores de ativos (BAGANZI; KIM; SHIN, 2017). O cenário económico e político imprevisível e em rápida evolução, juntamente com a volatilidade inerente aos mercados financeiros, exige uma abordagem abrangente e estruturada à avaliação e mitigação de riscos, a fim de garantir que as decisões de investimento sejam tomadas com uma compreensão clara dos riscos associados.

Neste contexto, a utilização de ferramentas quantitativas, como o Value at Risk (VaR), o Índice de Sharpe e o Capital Asset Pricing Model (CAPM), tornou-se fundamental para auxiliar na análise da relação entre risco e retorno. Essas metodologias oferecem aos gestores uma visão clara sobre a exposição ao risco de mercado, permitindo que decisões de investimento sejam tomadas com maior segurança e precisão (BODIE; KANE; MARCUS, 2018). Adicionalmente, a aplicação da Teoria de Portfólios de Markowitz proporciona uma estratégia eficiente para a diversificação de carteiras, com vistas à maximização do retorno ajustado ao risco.

A presente monografia propõe uma análise integrada dessas três metodologias no contexto do mercado acionário brasileiro, focando especificamente nas 20 maiores ações do índice Bovespa. O Índice Bovespa (Ibovespa) é o principal indicador de desempenho do mercado acionário brasileiro, sendo composto pelas ações mais negociadas na B3 (Brasil, Bolsa, Balcão). Criado em 1968, o índice reflete o comportamento médio dos ativos de maior relevância e liquidez da bolsa, funcionando como um termômetro do mercado e um dos principais referenciais para investidores nacionais e internacionais (B3, 2024). Sua carteira teórica é revisada periodicamente e ponderada pelo valor de mercado das ações, de forma que empresas com maior representatividade e liquidez possuem maior peso no índice. Dessa forma, o Ibovespa não apenas serve como parâmetro de desempenho para fundos e gestores, mas também representa uma proxy do mercado de capitais brasileiro, justificando sua escolha como objeto de análise neste estudo.

O problema de pesquisa desta monografia é como otimizar a composição de uma carteira de investimentos eficiente, considerando as características de risco e retorno das 20 maiores ações do índice Bovespa nos períodos de 2017 a 2019 e de 2022 a 2024. O objetivo

principal é avaliar o risco dessas ações nesses períodos e, com base nessa análise, otimizar a composição de uma carteira de investimentos eficiente, segundo os preceitos da teoria de Markowitz. Essa abordagem busca oferecer uma solução prática para a alocação de ativos no mercado acionário brasileiro.

Ao longo deste estudo, busca-se não apenas aprofundar o conhecimento acadêmico sobre gestão de riscos e retorno, mas também fornecer uma contribuição prática relevante para investidores e gestores que atuam no mercado financeiro brasileiro. A importância deste trabalho está, portanto, na aplicação combinada de diferentes ferramentas de análise de risco, visando à construção de carteiras mais eficientes e seguras.

1.1 Justificativa

A escolha de estudar as 20 maiores ações que compõem o índice Bovespa nos períodos de 2017 a 2019 e 2022 a 2024 fundamenta-se na representatividade dessas empresas no mercado financeiro brasileiro. Estas ações, com participação superior a 1,5% no índice, desempenham um papel crucial na composição e desempenho do Ibovespa, reconhecido como o principal termômetro do mercado de ações no Brasil (BRASIL, 2023).

Essas empresas, que abrangem setores diversos como financeiro, energia, commodities e consumo, refletem a dinâmica da economia nacional e permitem capturar a essência do mercado de capitais. Sua alta liquidez e relevância econômica fazem delas uma escolha estratégica para avaliar riscos e retornos, alinhando-se à perspectiva de Markowitz (1952), que enfatiza a importância da diversificação na gestão de carteiras.

A análise dos períodos selecionados possibilita compreender o comportamento do mercado em momentos distintos, como períodos de crescimento econômico e alta volatilidade. Desse modo, fatores como tamanho das empresas e o valor de mercado são determinantes para explicar os retornos das ações, reforçando a relevância de focar nas maiores empresas do índice Bovespa (FAMA; FRENCH, 1992).

Metodologias como o CAPM, VaR, Índice de Sharpe e Teoria de Portfólios de Markowitz serão aplicadas para mensurar riscos e otimizar retornos. Destarte, destaca-se que o VaR é essencial para entender a exposição ao risco em mercados voláteis (JORION, 2010).

Enquanto o Índice de Sharpe é de suma importância na avaliação da eficiência de carteiras (LIMA, 2007). A combinação dessas ferramentas permite uma análise integrada e robusta, contribuindo para a literatura acadêmica e prática financeira.

Além disso, o estudo se justifica pela necessidade de oferecer subsídios para decisões mais informadas de alocação de ativos no mercado brasileiro, considerando cenários complexos e desafiadores. Enfatiza-se que a medição e gestão eficaz de riscos são fundamentais para o sucesso de qualquer estratégia de investimento (HUBBARD, 2009). Dessa forma, o trabalho utiliza-se rigor acadêmico com aplicabilidade prática, fornecendo recomendações que dialoguem com as necessidades de investidores e gestores de recursos.

Por fim, o estudo pretende analisar sobre a eficiência de carteiras no Brasil, contribuindo para preencher lacunas na literatura e oferecer insights para estratégias de investimento (BERNSTEIN, 1997).

1.2 Objetivos

1.2.1 Objetivo Geral

O principal objetivo deste trabalho é analisar as 20 maiores ações que compõem o índice Bovespa nos períodos de 2017 a 2019 e de 2022 a 2024, avaliando seus retornos históricos e a relação risco-retorno em diferentes contextos econômicos. A partir dessa análise, busca-se construir carteiras de investimento eficientes utilizando metodologias consagradas, como CAPM, VAR, Índice de Sharpe e a Teoria de Portfólios de Markowitz.

1.2.2 Objetivos Específicos

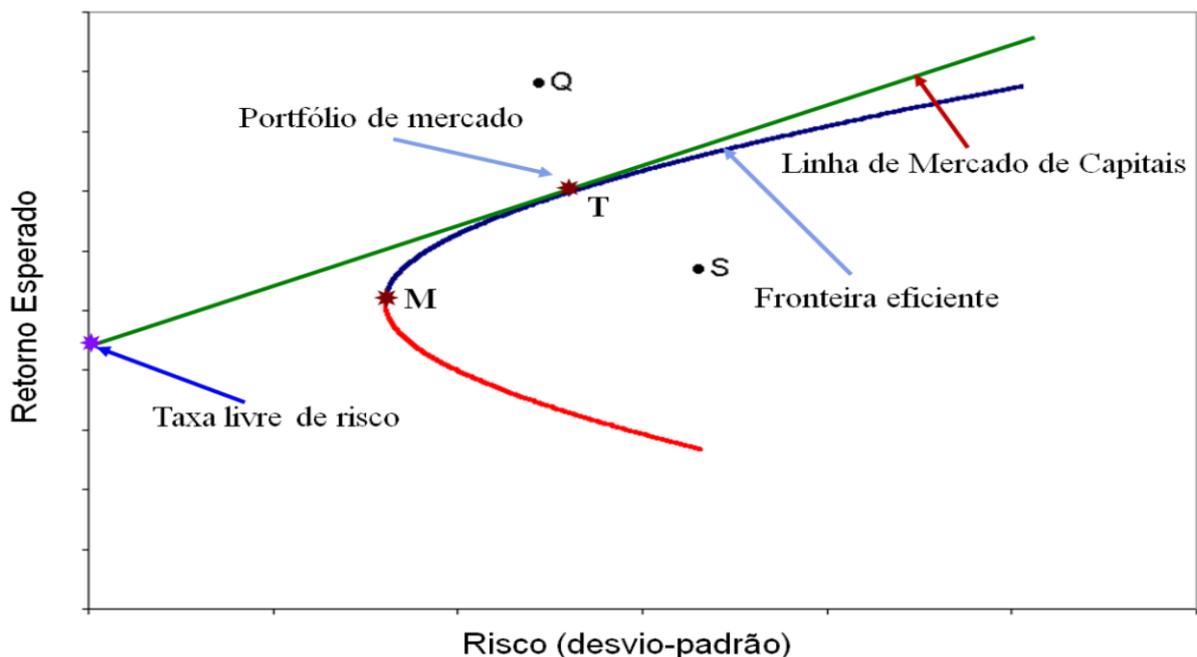
- Analisar os riscos e retornos históricos das 20 maiores ações que compõem o índice Bovespa, com participação superior a 1,5%, nos períodos de 2017 a 2019 e 2022 a 2024, considerando diferentes cenários econômicos e políticos.
- Aplicar o modelo CAPM para calcular o retorno esperado de cada ação e comparar com os retornos históricos, avaliando a aderência do modelo nos períodos estudados.

- Mensurar os riscos das ações por meio da metodologia Value at Risk (VaR), estimando as possíveis perdas em diferentes níveis de confiança.
- Calcular o Índice de Sharpe para as ações e carteiras simuladas, avaliando a eficiência das combinações risco-retorno em relação a um benchmark.
- Utilizar a Teoria de Portfólios de Markowitz para determinar a fronteira eficiente e a alocação ideal de ativos, visando diferentes perfis de risco e a melhor relação entre retorno e volatilidade.
- Comparar a performance da carteira eficiente entre os dois períodos de tempo.
- Propor recomendações práticas para investidores, com base nos resultados obtidos, com o objetivo de otimizar a relação entre risco e retorno em carteiras de investimento.

2 REFERENCIAL TEÓRICO

Este capítulo apresenta os principais conceitos que fundamentam a análise de risco e retorno no mercado financeiro. São abordadas as noções de risco e incerteza, os diferentes tipos de risco e os modelos quantitativos mais utilizados, como VaR, Índice de Sharpe, CAPM e a Teoria de Portfólios de Markowitz, que servirão de base para o desenvolvimento deste estudo.

Figura 2 - Fronteira eficiente de Markowitz



Fonte: Suno Research; Tiago Reis; Teoria de Markowitz: como calcular a relação de risco e retorno; 26 fev. 2021.

2.1 Risco e Incerteza

No gerenciamento de riscos, o risco é definido como a probabilidade de ocorrência de um evento desfavorável, que pode ser quantificado por meio de análise de dados históricos e modelagem estatística (HUBBARD, 2020). Dessa forma, a gestão de riscos abrange o uso de métodos analíticos baseados em informações passadas para identificar a probabilidade de eventos indesejáveis, permitindo uma tomada de decisão mais fundamentada e orientada por dados.

Uma perspectiva instigante sobre a origem do termo "risco", baseia-se no italiano *risicare*, que carrega consigo uma conotação ousada, sugerindo uma essência destemida associada à variabilidade de resultados imprevisíveis (BERNSTEIN, 1997).

O risco pode ser definido como a oscilação nos resultados que não foram antecipados. Em contrapartida, o conceito de incerteza trata das situações nas quais os resultados futuros são imprevisíveis e não podem ser mensurados com exatidão (JORION, 2010).

A incerteza está intrinsecamente relacionada à limitação do conhecimento ou à impossibilidade de atribuir probabilidades concretas a eventos futuros (AVEN, 2016). O autor distingue a incerteza em duas vertentes: a epistemológica, que se refere à insuficiência de conhecimento sobre o sistema, e a ontológica, que envolve fatores inerentes ao sistema que são, por natureza, imprevisíveis. Tal diferenciação sublinha que, enquanto o risco é quantificável, a incerteza frequentemente requer abordagens mais qualitativas e adaptativas para ser tratada de maneira eficaz.

2.2 Análise de risco

A análise de risco constitui uma metodologia fundamental empregada para identificar, quantificar e facilitar o gerenciamento dos riscos inerentes associados a diversas categorias de investimento. Essa metodologia permite o diagnóstico, o cálculo e o exame de exposições variadas a vários riscos. Essas capacidades permitem o estabelecimento de controles que informam a tomada de decisões financeiras em meio a condições incertas (LIMA, 2016).

Ao longo dos anos, metodologias de análise de risco surgiram e passaram por refinamentos no setor financeiro, em resposta à introdução de novos instrumentos financeiros e suas demandas associadas. O objetivo principal é evitar crises financeiras e, conseqüentemente, aliviar as perdas do mercado (LIMA, 2016). Portanto, a análise de risco é de suma importância para as entidades financeiras, que precisam adotar ou cultivar as técnicas mais eficazes adaptadas a seus contextos operacionais específicos.

O gerenciamento de riscos é um aspecto essencial das operações financeiras, sendo amplamente reconhecido como uma prática indispensável para mitigar incidentes que possam impactar negativamente a saúde financeira das instituições e de seus clientes. Segundo Zanini e Figueiredo (2019), o sucesso no gerenciamento de riscos depende da capacidade dos gestores de identificar vulnerabilidades e implementar medidas eficazes, garantindo a proteção e a eficiência das operações.

Os mercados financeiros proporcionam uma ampla variedade de instrumentos financeiros, cada um com diferentes níveis de risco e retorno, possibilitando a adaptação das alternativas aos diversos perfis de risco dos investidores (NETO, 2005). Dessa forma, os investidores têm à disposição uma variedade considerável de opções de investimento, abrangendo desde aquelas de baixo risco até as de alto risco, de acordo com o perfil individual de cada investidor.

2.3 Tipos de Risco

Os riscos são sistematicamente categorizados em grupos financeiros, estratégicos, e não estratégicos (LIMA, 2016), necessitando de identificação específica e técnicas analíticas personalizadas para uma avaliação precisa.

2.3.1 Riscos Financeiros

Os riscos financeiros englobam as principais fontes de incerteza que afetam diretamente o desempenho de ativos e carteiras no mercado. Estão relacionados a fatores como oscilações de preços, inadimplência de contrapartes, liquidez de ativos e falhas operacionais ou legais que

possam impactar transações. Embora este trabalho não se aprofunde na gestão detalhada desses riscos, sua menção é relevante para contextualizar as métricas utilizadas posteriormente na avaliação de retorno e volatilidade das ações.

2.3.1.1 Risco de Mercado

O risco de mercado denota a probabilidade de incorrer em prejuízos financeiros devido a alterações nas avaliações dos ativos e passivos de uma entidade. Essa categoria de risco está intimamente ligada a variações em fatores como taxas de juros, taxas de câmbio, preços de commodities, avaliações de ações, opções e derivativos. Essas flutuações podem influenciar os ativos e passivos de um investidor, afetando diretamente seus resultados financeiros (FREITAS, 2017).

Para mitigar o risco de mercado, entidades financeiras como o Banco Central do Brasil (BC) implementam a metodologia Value at Risk (VaR), que se aproxima da perda máxima concebível dentro de um intervalo de confiança específico, normalmente definido em 95% (BANCO CENTRAL DO BRASIL, 2017).

Destarte, o VaR está sujeito a um escrutínio contínuo e é rotineiramente transmitido ao Conselho de Administração Colegiado, oferecendo informações vitais sobre os principais determinantes de risco que afetam o desempenho da instituição. Além do VaR, o BC utiliza medidas complementares, como testes de estresse e análise de sensibilidade, para avaliar as possíveis repercussões de condições adversas nas avaliações de ativos (BANCO CENTRAL DO BRASIL, 2017). Esses instrumentos auxiliares contribuem para uma compreensão mais completa das flutuações extremas nas variáveis de mercado, garantindo assim uma visão holística dos riscos que a instituição enfrenta.

2.3.1.2 Riscos de Crédito

O risco de crédito diz respeito à probabilidade de não recuperar valores monetários de uma contraparte durante transações financeiras, incluindo a venda de bens ou a emissão de

empréstimos. Em essência, representa a incerteza ligada ao potencial de um indivíduo ou organização falhar em cumprir seus compromissos financeiros (FREITAS, 2017).

Para mitigar esse risco, instituições financeiras e outras entidades empregam uma variedade de técnicas e instrumentos. O Banco Central (BC), por exemplo, supervisiona o risco de crédito examinando exposições a riscos, classificações de crédito e indicadores produzidos a partir de modelos inovadores. Esses modelos facilitam a avaliação do risco associado a cada contraparte, tanto individualmente quanto coletivamente.

Os modelos internos calculam a inadimplência prevista, que é a probabilidade de uma contraparte não cumprir suas responsabilidades financeiras dentro de um prazo especificado, multiplicada pela exposição ao risco e pela porcentagem de perda que ocorreria no caso de uma inadimplência (BANCO CENTRAL DO BRASIL, 2017). A inadimplência total esperada é a agregação desses valores em uma coorte de contrapartes, oferecendo assim uma medida abrangente de risco.

Além disso, o BC examina as informações fornecidas por agências especializadas e emprega modelos para avaliar o risco de crédito de curto e longo prazo. Esse monitoramento engloba tanto aspectos quantitativos, como preços de mercado e indicadores econômicos, quanto fatores qualitativos (BANCO CENTRAL DO BRASIL, 2017). Essa abordagem holística permite ajustes nos limites operacionais, a recomendação de modificações da contraparte e a orientação estratégica da alocação de ativos.

2.3.1.3 Risco de Liquidez

O risco de liquidez refere-se à dificuldade potencial de negociar um ativo no mercado de forma eficiente, o que pode ocorrer quando não se consegue vendê-lo a um preço desejável ou quando há obstáculos para encontrar uma contraparte disposta a adquiri-lo. Esse risco está intrinsecamente associado à capacidade de realizar transações sem impactar significativamente o preço do ativo. O risco de liquidez é amplificado em momentos de crise financeira, quando a volatilidade e a incerteza levam à redução da liquidez no mercado, dificultando a negociação de ativos mesmo em condições normais (JORION, 2007).

Do ponto de vista quantitativo, a avaliação do risco de liquidez engloba indicadores que avaliam a variação entre os preços de compra e venda dos ativos. Uma ilustração pertinente é

o Indicador de Custo de Liquidez Relativo (IRCL), que calcula o custo de liquidez cumulativo associado a vários títulos. Esse indicador representa uma soma ponderada, dependendo do volume de negócios, dos índices entre o diferencial de preço e o preço de fechamento do dia (BANCO CENTRAL DO BRASIL, 2017). Uma escalada no IRCL significa um desafio crescente no mercado para executar negociações envolvendo o ativo, sinalizando assim um declínio na liquidez.

Além disso, no âmbito do investimento de reserva internacional, diretrizes específicas são instituídas para aliviar o risco de liquidez. Essas diretrizes defendem evitar focar as compras em questões específicas de ativos, garantindo que as atividades do Banco Central não influenciem significativamente os preços de mercado e desencorajam o envolvimento excessivo com um número limitado de emissores, promovendo assim diversificação suficiente para mitigar os riscos associados à liquidez (BANCO CENTRAL DO BRASIL, 2017).

2.3.1.4 Risco Operacional

O risco operacional diz respeito ao potencial de prejuízo financeiro decorrente de deficiências ou falhas nos mecanismos internos de uma organização, erros humanos, falhas tecnológicas ou ocorrências externas, como calamidades naturais. Essa categoria de risco pode se originar de uma infinidade de fontes, incluindo erros inadvertidos, atividades enganosas, falhas em infraestruturas tecnológicas ou repercussões negativas de ocorrências externas, como eventos sísmicos (FREITAS, 2017).

Os riscos operacionais podem levar a perdas diretas, tipificadas por danos financeiros imediatos, e perdas indiretas, exemplificadas por efeitos prejudiciais na reputação e eficácia operacional da entidade (BANCO CENTRAL DO BRASIL, 2017). A avaliação e o gerenciamento desses riscos exigem um exame abrangente dos processos da cadeia de valor da organização, identificando áreas vulneráveis onde os riscos podem surgir.

Para identificar e avaliar os riscos operacionais, várias metodologias são empregadas. Uma dessas metodologias é a Autoavaliação de Risco e Controle (RCSA), que permite à organização avaliar e regular de forma independente os riscos vinculados aos seus processos internos (BANCO CENTRAL DO BRASIL, 2017). Além disso, a documentação histórica de

incidentes e os Indicadores de Controle de Risco (ICRs) servem como instrumentos essenciais para rastrear e compreender a frequência e as ramificações dos riscos operacionais.

2.3.1.5 Risco Legal

O risco legal refere-se à possibilidade de prejuízos decorrentes de operações ou transações que não estejam devidamente respaldadas pela legislação vigente. Esse tipo de risco surge quando os aspectos jurídicos de uma operação, como contratos e acordos, são mal elaborados, apresentando lacunas que podem ser contestadas ou interpretadas de maneira desfavorável. O risco legal é especialmente relevante em mercados financeiros complexos, onde regulamentações variáveis e interpretações divergentes podem impactar negativamente a segurança jurídica das transações (HUBBARD, 2009).

O risco legal pode manifestar-se de diversas maneiras, incluindo disputas contratuais, sanções regulatórias ou questões de conformidade que possam comprometer a validade e a execução de um contrato. Por exemplo, contratos mal redigidos podem conter brechas jurídicas que permitem a contestação por parte de uma das partes envolvidas, resultando em litígios e potenciais perdas financeiras.

2.4 Modelos de análise de risco

Esta seção, se propõe a explorar e aplicar metodologias específicas, justificando a escolha do caminho trilhado. Embora o universo de modelos de gestão de risco seja amplo, a seleção recaiu sobre abordagens que permitem uma análise robusta e comparativa, focando na otimização de carteiras de investimento. A decisão de concentrar a análise em modelos como a Teoria de Markowitz, o Capital Asset Pricing Model (CAPM), o Value at Risk (VaR) e o Índice de Sharpe não é arbitrária, mas sim fundamentada na sua relevância histórica, aplicação prática e capacidade de fornecer insights valiosos sobre a relação risco-retorno em diferentes cenários macroeconômicos. Esses modelos, embora com suas próprias premissas e complexidades, formam um arcabouço sólido para a compreensão e a gestão ativa de portfólios.

Para contextualizar a escolha metodológica e oferecer uma visão panorâmica das ferramentas disponíveis, a seção a seguir apresentará um panorama dos principais modelos de gestão de risco e otimização de portfólio, destacando suas características fundamentais, aplicações, aspectos positivos e ressalvas. Esta abordagem visa não apenas aprofundar o entendimento sobre as metodologias empregadas, mas também situá-las no espectro mais amplo da teoria financeira, evidenciando o porquê de sua pertinência para os objetivos.

Tabela 2.4 - Panorama dos Modelos de Gestão de Risco e Otimização de Portfólio

Modelo	Aplicação	Aspectos Positivos	Ressalvas
Matriz de Covariância Clássica (Markowitz/Média-Variância)	Otimização de portfólios, construção da fronteira eficiente.	Fácil de implementar, intuição clara da diversificação.	Instabilidade com muitos ativos/poucos dados históricos, mais adequado para portfólios pequenos.
Modelos de Fatores (Ex: Barra, APT, PCA)	Decomposição de risco e retorno, atribuição de risco, construção de portfólios grandes.	Reduz a dimensionalidade, mais estável e robusto que covariância pura, compreensão granular das fontes de risco.	Complexidade na identificação e estimação dos fatores.
Value at Risk (VaR)	Medição da perda máxima esperada em um horizonte de tempo e nível de confiança.	Intuitivo, fácil comunicação, amplamente usado por bancos.	Não captura caudas pesadas e eventos extremos, pode subestimar o risco em crises.
Expected Shortfall (CVaR)	Medição da perda média condicional além do VaR, risco de cauda.	Mais coerente matematicamente, captura melhor o risco de cauda, recomendado por reguladores.	Mais complexo de calcular que o VaR, requer mais dados.
Stress Testing & Cenários	Avaliação do impacto de choques de mercado hipotéticos/históricos, resiliência do portfólio.	Complementa modelos estatísticos, crucial para eventos raros de alto impacto, auxilia em planos de contingência.	Depende da escolha dos cenários, pode ser subjetivo.
Modelos Bayesianos / Shrinkage	Melhoria da estimação de matrizes de covariância instáveis.	Reduz o erro de estimação, melhora a estabilidade da matriz de covariância, útil com dados limitados.	Requer conhecimento de estatística bayesiana, escolha de priors pode ser desafiadora.
Modelos de Volatilidade Condicional (GARCH, EWMA)	Captura da natureza dinâmica e heterocedástica da volatilidade.	Estimativas mais precisas da volatilidade futura, gestão de risco mais ágil e adaptativa.	Complexidade na modelagem, requer dados de alta frequência.

Fonte: Elaboração própria.

A Tabela 2.4 oferece uma visão panorâmica dos principais modelos de gestão de risco e otimização de portfólio. Cada um desses modelos possui características distintas que os tornam adequados para diferentes contextos e objetivos de análise.

2.4.1 Value at Risk (VaR)

O Value at Risk (VaR) é amplamente reconhecido como um dos conceitos centrais na gestão de riscos de investimentos. Ele representa uma medida que quantifica a perda potencial de um ativo ou de uma carteira de investimentos exposta a riscos de mercado, notadamente devido às flutuações nos preços dos ativos (LIMA, 2016). Atualmente, o VaR é também uma das técnicas mais utilizadas para aferição e controle de riscos, consolidando-se como uma ferramenta essencial para gestores na mitigação de incertezas financeiras.

O cálculo do Value at Risk (VaR) pode ser realizado por meio de duas abordagens distintas: o VaR absoluto e o VaR relativo (JORION, 2010). Em períodos de tempo curtos, como um dia, o retorno médio tende a ser insignificante, o que resulta em pouca diferença entre os dois métodos de cálculo. No entanto, em cenários de longo prazo, o VaR relativo se mostra conceitualmente mais adequado, pois considera o risco em relação ao retorno médio esperado no período analisado (JORION, 2010).

O VaR absoluto, também denominado VaR zero, calcula a perda em relação a zero, sem referência ao retorno esperado. Por outro lado, o VaR relativo, ou VaR médio, estima a perda máxima em relação ao retorno médio esperado, oferecendo uma avaliação mais ajustada ao contexto do desempenho projetado. A formulação para o VaR relativo, isto é, do VaR relativo à média é:

$$\text{VaR}_{\text{relativo}} = -(\mu * \text{Investimento} + Z\alpha\% * \sigma_{\text{período}} * \text{Investimento}) \quad (2.1)$$

em que $Z\alpha\%$ é o nível de confiança para o cálculo do VaR, $\sigma_{\text{período}}$ é o risco do ativo e μ é o retorno médio.

O VaR Absoluto representa a perda máxima esperada em unidades monetárias da carteira em um determinado período, com um certo nível de confiança e em condições normais de mercado. A fórmula simplificada para o VaR Absoluto é expressa como:

$$\text{VaR}_{\text{absoluto}} = -(\text{Investimento} * Z\alpha\% * \sigma_{\text{período}}) \quad (2.2)$$

Onde $R_{\text{período}}$ é o retorno médio do período do ativo, $Z\alpha\%$ é o nível de confiança para o cálculo do VaR e $\sigma_{\text{período}}$ é o risco do ativo.

A fim de prevenir a manifestação de valores negativos, sugere-se contemplar os rendimentos como processos persistentemente elaborados, adotando a distribuição lognormal. Dessa forma, descreve-se a computação por meio da fórmula subsequente (JORION, 2010):

$$R = \frac{\ln P}{(P-1)} \quad (2.3)$$

Em síntese, o cálculo do VaR, busca mensurar a perda máxima esperada em determinado horizonte de tempo e nível de confiança, a partir da volatilidade dos retornos do ativo ou da carteira. Assim, as equações apresentadas traduzem de forma quantitativa o risco potencial, oferecendo aos gestores uma ferramenta objetiva para avaliar a exposição ao mercado e embasar decisões de investimento.

2.4.2 Índice de Sharpe

O índice de Sharpe, concebido por William Sharpe, é amplamente reconhecido como uma ferramenta indispensável na análise de desempenho de investimentos. Essa métrica avalia a eficiência da relação entre o retorno obtido e o risco assumido, representado pela volatilidade dos ativos. Sua aplicação é especialmente relevante na comparação de estratégias de investimento, permitindo aos gestores identificar a capacidade de maximizar retornos ajustados ao risco.

O índice de Sharpe não apenas fornece uma perspectiva clara sobre a gestão de risco, mas também facilita decisões fundamentadas, auxiliando investidores na escolha de portfólios mais alinhados com seus objetivos e tolerância ao risco. Essa abordagem quantitativa reforça sua importância no contexto de uma gestão de ativos eficaz e orientada para resultados sustentáveis (BODIE; KANE; MARCUS, 2014).

Sharpe (1994) oferece uma interpretação instigante do Índice de Sharpe (IS), destacando sua utilidade como uma métrica para avaliar estratégias de investimento baseadas em retornos ajustados ao risco. Segundo o autor, o IS pode ser entendido como uma ferramenta para analisar estratégias de arbitragem que exploram a diferença entre o desempenho de um fundo avaliado e um benchmark de referência, ajustado pela taxa de juros livre de risco.

Essa perspectiva sugere que o IS transcende sua aplicação convencional ao fornecer insights sobre oportunidades de arbitragem financeira, evidenciando como a eficiência de um

fundo pode ser comparada ao retorno livre de risco. Além disso, a abordagem de Sharpe sublinha a importância de compreender os componentes subjacentes do índice e a interação entre eles para decisões financeiras mais estratégicas e bem fundamentadas. A adoção dessa visão mais ampla reforça a relevância do IS no aprimoramento da gestão de portfólios e na maximização do retorno ajustado ao risco.

O modelo distintivo do Índice de Sharpe é empregado na formulação de portfólios ótimos, levando em consideração os dados históricos de desempenho e o índice de mercado. A metodologia realiza o cálculo do retorno excedente em relação ao índice beta, priorizando categorias com índices mais elevados para a composição de uma carteira eficiente (MISTRY; KHATWANI, 2023).

É importante destacar que o modelo subjacente ao Índice de Sharpe se baseia em dados históricos, o que pode limitar sua aplicabilidade em cenários de mercado extraordinários ou altamente voláteis. Além disso, a autocorrelação presente nos retornos das séries temporais financeiras pode afetar a precisão das métricas, comprometendo a correlação esperada entre o índice de Sharpe e as decisões de alocação de portfólio.

Apesar dessas limitações, o Índice de Sharpe permanece uma ferramenta amplamente utilizada para avaliar a eficiência de investimentos, ao mensurar a relação entre os riscos assumidos e os retornos obtidos. A teoria financeira sugere que portfólios com maior exposição ao risco possuem, em tese, maior potencial para gerar retornos superiores. Nesse sentido, o Índice de Sharpe contribui para uma análise mais criteriosa, oferecendo aos gestores e investidores um parâmetro relevante na construção de estratégias financeiras informadas e alinhadas aos objetivos de desempenho ajustado ao risco (NETO, 2005).

Ao utilizar o Índice de Sharpe (IS) como ferramenta para selecionar ou categorizar investimentos, é essencial ter em mente alguns cuidados importantes. O principal deles é que o cálculo do IS não leva em consideração a interdependência entre os ativos da carteira. Isso significa que o índice avalia cada ativo de forma isolada, sem refletir como ele pode interagir com outros investimentos, o que pode ser uma limitação importante quando se trata de carteiras compostas por múltiplos ativos de risco (VARGA, 2001).

Quando se busca incluir um novo ativo ou portfólio de risco em uma carteira já composta por ativos similares, a utilidade do IS diminui. Isso ocorre porque o IS, ao desconsiderar a correlação entre os ativos, pode indicar que a adição de um ativo com um bom IS não trará necessariamente benefícios substanciais ao portfólio. No entanto, a relevância do

IS cresce quando a correlação entre o ativo em análise e a carteira existente é alta. Nesse caso, a escolha de ativos com maior IS pode realmente resultar em uma melhoria no desempenho do portfólio, visto que esses ativos agregam valor ao risco total da carteira (VARGA, 2001).

Por outro lado, em situações onde a correlação entre os ativos é baixa ou até negativa, a presença de um ativo com IS baixo pode ser compensada pelo seu potencial de diversificação, podendo até melhorar o IS geral do portfólio. Isso acontece porque ativos com correlação negativa ou baixa tendem a reduzir o risco geral da carteira, equilibrando os retornos de maneira favorável (VARGA, 2001).

Portanto, para investidores que buscam adicionar ativos mais arriscados a uma carteira e desejam simplificar sua análise, a escolha do ativo com maior Índice de Sharpe pode ser uma estratégia eficaz, especialmente quando esse ativo pode aumentar o retorno ajustado ao risco do portfólio. No entanto, a análise deve sempre ser feita levando em consideração as características da carteira como um todo, e não apenas as métricas isoladas de cada ativo (VARGA, 2001).

A fórmula do Índice de Sharpe é expressa por:

$$IS = \frac{E(R_i) - R_f}{\sigma_i} \quad (2.4)$$

Onde $E(R_i)$ representa o retorno esperado do investimento, R_f é o retorno do ativo sem risco adotado como taxa média Selic, e σ_i indica o desvio padrão dos retornos do investimento.

Assim, o Índice de Sharpe fornece um referencial quantitativo para comparar diferentes ativos e carteiras sob a ótica do retorno excedente em relação ao risco assumido. No âmbito desta pesquisa, sua utilização será central na avaliação da eficiência das ações mais representativas do Ibovespa, bem como na verificação da qualidade das carteiras construídas segundo a teoria de Markowitz.

2.4.3 CAPM

O Modelo de Precificação de Ativos de Capital (CAPM, do inglês Capital Asset Pricing Model) é amplamente reconhecido na economia financeira como uma ferramenta essencial para a estimativa do valor de títulos e o cálculo da taxa de retorno requerida com base no risco

associado. Sua relevância está vinculada à capacidade de fornecer previsões robustas sobre a relação complexa entre risco e retorno, consolidando-se como uma abordagem prática para análise de investimentos.

Contudo, o CAPM apresenta limitações significativas, especialmente em mercados onde o impacto do risco não sistemático não pode ser ignorado. A eficácia do modelo é frequentemente questionada devido à sua dependência de premissas simplificadas e às dificuldades inerentes na realização de testes empíricos confiáveis. Essas fragilidades empíricas refletem os desafios de aplicar o modelo em cenários reais, onde a dinâmica de mercado não se alinha perfeitamente com as suposições teóricas subjacentes ao CAPM (FAMA; FRENCH, 2007).

Apesar dessas limitações, o modelo permanece um marco teórico, servindo como base para diversas aplicações e estudos na área de finanças, enquanto continua a estimular debates acadêmicos sobre sua aplicabilidade e alternativas mais adequadas.

Cabe ainda mencionar, que o Modelo de Precificação de Ativos de Capital (CAPM) postula que a avaliação do risco de uma ação deve ser efetuada em relação a um “portfólio de mercado” amplo que, em uma idealização, compreende não somente ativos financeiros transacionados, mas também bens duráveis de consumo, propriedades imobiliárias e capital humano. Mesmo ao adotarmos uma interpretação mais limitada do modelo e restringirmos sua aplicabilidade aos ativos financeiros transacionados, seria justificável limitar ainda mais a composição do portfólio de mercado para abranger exclusivamente ações ordinárias dos Estados Unidos (uma escolha frequente)? Ou seria mais apropriado expandir o mercado para englobar debêntures e outros instrumentos financeiros, eventualmente provenientes de diversas regiões do globo? (FAMA; FRENCH, 2007).

Sharpe (1964) e Lintner (1965) se basearam no modelo de Markowitz incorporando duas premissas adicionais que permitem a identificação de um portfólio eficiente em termos de variância média. A primeira premissa é o conceito de acordo total entre os investidores, segundo o qual eles concordam unanimemente com a distribuição conjunta de renda do período anterior ($t - 1$) para o período atual (t), com base nos preços dos ativos observados no fechamento do mercado em $t - 1$. Essa distribuição conjunta é considerada a distribuição verdadeira, pois reflete os retornos reais usados para avaliar o desempenho do modelo.

Uma das premissas fundamentais apresentadas por Sharpe e Lintner no desenvolvimento do Modelo de Precificação de Ativos de Capital (CAPM) é a hipótese de que

todos os investidores podem realizar empréstimos ou aplicações a uma taxa livre de risco uniforme. Essa taxa, considerada constante e acessível independentemente do montante envolvido, desempenha um papel central na estrutura analítica do modelo.

A taxa livre de risco atua como um parâmetro de referência para mensurar a atratividade de diferentes alternativas de investimento. Ela influencia diretamente a avaliação das características de risco e retorno de um portfólio, servindo como base para determinar o prêmio de risco associado a ativos mais voláteis. Essa abordagem simplificada permite que o CAPM modele a relação entre o risco sistemático de um ativo e seu retorno esperado de forma consistente e acessível para os investidores.

Embora essa premissa seja essencial para a formulação teórica do modelo, sua aplicabilidade no mundo real é limitada pela dificuldade de encontrar ativos verdadeiramente livres de risco. Ainda assim, a suposição oferece uma estrutura conceitual valiosa para análises financeiras e decisões estratégicas de investimento.

Essas duas premissas, juntamente com os conceitos originais do modelo de Markowitz, formam a base da estrutura CAPM, que provou ser altamente influente no campo das finanças. Apesar do passar do tempo, o CAPM continua sendo amplamente empregado por profissionais devido à sua capacidade de fornecer informações valiosas sobre o custo de capital e a avaliação de portfólio.

Logo, a fórmula fornecida a seguir é encarregada pelo cálculo acurado:

$$E(R_i) = R_f + \beta_i [E(R_m) - R_f] \quad (2.5)$$

Onde, $E(R_i)$ se refere ao retorno esperado, R_f refere-se à taxa de juros livre de risco, β representa a sensibilidade do investimento em relação ao mercado e R_m indica a taxa de retorno do mercado.

Assim, o CAPM se destaca como uma estrutura analítica que conecta risco sistemático e retorno esperado, servindo como base para decisões de investimento e precificação de ativos. No contexto desta pesquisa, sua aplicação será essencial para mensurar o retorno requerido das ações mais representativas do Ibovespa e para comparar os resultados obtidos com as demais métricas, como VaR, Índice de Sharpe e a Teoria de Markowitz.c

2.4.4 Teoria de Markowitz

O trabalho pioneiro de Harry Markowitz, publicado em 1952, marcou uma revolução na abordagem utilizada para a análise de carteiras de investimento. Esse estudo desafiou o paradigma econômico vigente, que favorecia a concentração de recursos em ativos com maior retorno esperado como estratégia predominante de alocação de investimentos. Em contraste, Markowitz propôs uma metodologia inovadora, baseada na ideia de que é possível alcançar uma alocação mais eficiente e vantajosa ao equilibrar cuidadosamente o retorno esperado e o risco associado a um portfólio.

Essa abordagem transformadora fundamentou-se em evidências robustas, demonstrando que a diversificação estratégica dos investimentos pode minimizar os riscos sem comprometer os retornos potenciais. Essa visão deu origem à Teoria Moderna do Portfólio (MPT, do inglês Modern Portfolio Theory), que redefiniu as bases conceituais do gerenciamento de investimentos e introduziu uma análise rigorosa da relação entre risco e retorno.

A MPT trouxe uma nova perspectiva à tomada de decisões financeiras, influenciando tanto a prática de investidores quanto o desenvolvimento de modelos econômicos subsequentes. Ao enfatizar a importância da diversificação e da otimização de portfólios, Markowitz estabeleceu um marco teórico que continua a orientar a forma como os mercados financeiros são compreendidos e explorados.

A Teoria Moderna do Portfólio (MPT) fundamenta-se em um conjunto de premissas essenciais que descrevem o comportamento dos investidores e as condições prevalentes nos mercados financeiros (ZANINI; FIGUEIREDO, 2005). A primeira premissa estabelece que os investidores avaliam suas carteiras com base em dois critérios principais: o retorno esperado e o risco associado. O retorno esperado representa a estimativa do ganho futuro de um investimento, enquanto o risco é mensurado pelo desvio padrão dos retornos, uma métrica estatística que reflete a variabilidade dos resultados ao longo de um período determinado.

Adicionalmente, a teoria presume que os investidores possuem aversão ao risco, uma característica que desempenha um papel central na tomada de decisões financeiras. Esse princípio implica que, diante de carteiras com retornos esperados equivalentes, investidores racionais sempre preferirão aquela que apresentar menor exposição ao risco. Essa lógica

subjacente reflete a busca por um equilíbrio ideal entre risco e retorno, um aspecto crucial da alocação eficiente de recursos financeiros.

Ao integrar esses pressupostos em sua estrutura analítica, a MPT oferece uma base teórica sólida para a diversificação e otimização de portfólios, promovendo uma abordagem científica para a gestão de investimentos. Essa contribuição permanece como um dos pilares mais influentes da teoria financeira moderna, moldando práticas e estratégias no mercado global.

Outra premissa essencial da Teoria Moderna do Portfólio (MPT) é o princípio de que os investidores buscam maximizar seus retornos, alinhando suas decisões a uma lógica de eficiência econômica. Quando apresentados a duas carteiras com níveis de risco equivalentes, investidores racionais optarão por aquela que oferece o maior retorno potencial. Essa abordagem reflete a natureza estratégica da alocação de recursos, que visa otimizar o desempenho dos investimentos em um cenário competitivo.

Além disso, a teoria assume a divisibilidade contínua dos ativos financeiros, o que significa que os investidores podem adquirir frações de ativos, como ações. Essa característica permite uma flexibilidade significativa na composição das carteiras, viabilizando estratégias de diversificação mais detalhadas e ajustadas às necessidades e objetivos individuais. A capacidade de negociar participações fracionárias contribui para a eficiência do mercado, promovendo maior acessibilidade e personalização nos investimentos.

Essas premissas complementam o arcabouço teórico da MPT, reforçando sua relevância como uma abordagem sistemática e rigorosa para a gestão de portfólios. A integração de maximização de retorno, gestão de risco e flexibilidade na alocação de ativos continua a influenciar práticas financeiras contemporâneas e o desenvolvimento de novos modelos no campo das finanças.

O referencial teórico de Markowitz também postula a existência de uma taxa de retorno livre de risco, uma construção teórica na qual os investidores são capazes de emprestar e emprestar fundos; no entanto, é importante observar que essa suposição específica não é aplicada em estudos que se concentram exclusivamente em ações, como é o caso da presente análise, que também exclui deliberadamente a possibilidade de realizar vendas a descoberto de títulos (MARKOWITZ, 1952). Outro aspecto significativo desse arcabouço teórico é a afirmação de que as considerações relacionadas a impostos e custos de transação se tornam

irrelevantes quando se trata de tomar decisões de investimento, simplificando assim o processo analítico para investidores.

Finalmente, uma premissa fundamental da Teoria Moderna do Portfólio é a afirmação de que todos os investidores possuem uma perspectiva compartilhada em relação à distribuição de probabilidade das taxas de retorno de vários ativos, o que implica que existe um conjunto singular de portfólios eficientes com os quais todos os investidores racionais concordariam.

Com base nessas suposições fundamentais, Markowitz (1952) articulou que os dois principais atributos que caracterizam qualquer portfólio são seu retorno esperado e sua variância; o último servindo como uma medida quantificável do risco envolvido (MARKOWITZ, 1952). O retorno esperado de uma carteira é calculado como a média ponderada dos retornos gerados pelos ativos individuais que constituem a carteira:

$$\bar{R}_p = \sum_{i=1}^N X_i E(R_i) \quad (2.6)$$

Onde X_i é o percentual investido no ativo i e (R_i) é o retorno esperado do ativo i .

A segunda característica fundamental de uma carteira é o seu risco, medido pela sua variância:

$$\sigma_p^2 = \sum_{i=1}^N \sum_{j=1}^N X_i X_j \text{Cov}(R_i, R_j) \quad (2.7)$$

Onde X_i e X_j representam os pesos dos ativos i e j na carteira, R_i e R_j são os retornos dos ativos i e j , e $\text{Cov}(R_i, R_j)$ corresponde à covariância entre os retornos desses ativos.

Dessa forma, a equação (2.6) evidencia que o retorno esperado de uma carteira é obtido pela soma ponderada dos retornos esperados de cada ativo, sendo os pesos determinados pela proporção de capital investido em cada um deles. Já a variância da carteira, representada pela equação (2.7), expressa o risco associado à sua composição, mensurando a dispersão dos resultados em torno do retorno esperado e considerando as covariâncias entre os ativos. Em conjunto, essas expressões formalizam a essência da Teoria de Markowitz: a busca por combinações de ativos que maximizem o retorno esperado, ao mesmo tempo em que minimizem o risco, estabelecendo as bases para a construção da fronteira eficiente de portfólios.

3 MATERIAIS E MÉTODOS

Este trabalho caracteriza-se como uma pesquisa quantitativa, descritiva e aplicada, fundamentada em teorias financeiras e estatísticas consolidadas. A metodologia foi estruturada em três etapas principais: coleta de dados, análise quantitativa e interpretação dos resultados, com o objetivo de avaliar os riscos e retornos das 20 maiores ações do Ibovespa nos períodos de 2017 a 2019 e 2022 a 2024, além de propor carteiras eficientes.

A coleta de dados foi realizada a partir de fontes secundárias confiáveis, como o site da B3 e plataformas de mercado, incluindo Economática e Bloomberg, além de relatórios do Banco Central do Brasil. Os dados coletados compreendem os preços diários de fechamento das 20 maiores ações do Ibovespa, a taxa livre de risco (Selic) e os retornos históricos do índice. A seleção das ações considerou aquelas com participação superior a 1,5% no Ibovespa, devido à sua relevância e representatividade no mercado.

As ações selecionadas para análise foram: VALE3, PETR4, ITUB4, PETR3, BBAS3, ELET3, WEGE3, SBSP3, BBDC4, ABEV3, ITSA4, EMBR3, JBSS3, EQTL3, PRIO3, RENT3, RADL3, BBSE3, GGBR4 e RAIL3.

Cabe destacar que algumas ações que figuraram entre as 20 maiores participações no período analisado foram excluídas da amostra por motivos de elegibilidade, em função de não possuírem histórico suficiente para a análise desde 2017. Foram descartadas: B3SA3 (listada em novembro de 2017), SUZB3 (listada em novembro de 2017), BPAC11 (listada em fevereiro de 2017) e RDOR3 (listada em 2020).

A metodologia quantitativa partiu da análise individual dos ativos, na qual se avaliou os retornos históricos e se aplicou o modelo CAPM para calcular os respectivos retornos esperados. Estes dados, juntamente com a matriz de covariância dos ativos, serviram de base para a etapa seguinte: a construção de portfólios eficientes por meio da Teoria de Markowitz, com o objetivo de identificar a alocação ótima na fronteira eficiente. No entanto, considerando o período de 2022-2024, marcado por juros altos que impactaram negativamente o Índice de Sharpe da maioria dos ativos, optou-se por uma abordagem distinta: montar uma carteira ideal utilizando apenas os ativos com Sharpe positivo, em vez de buscar a maximização do índice como propõe a teoria clássica de Markowitz. Uma vez definida a carteira, sua performance e risco foram mensurados e comparados aos do Ibovespa.

Essa análise final foi conduzida por duas métricas principais: o Índice de Sharpe, para avaliar a eficiência do retorno ajustado ao risco, e o Value at Risk (VaR), para estimar a perda potencial em cenários adversos (com 99% de confiança). O tratamento dos dados envolve a coleta dos preços históricos ajustados, o cálculo dos retornos diários, a estimativa da volatilidade dos ativos e a análise de correlação entre eles. A partir desses cálculos, os modelos financeiros são aplicados para determinar o desempenho da carteira e sua eficiência ao longo dos períodos analisados.

Todo o processamento e a modelagem estatística foram realizados com o auxílio de ferramentas computacionais como o Microsoft Excel, para organização de dados, Visual Studio e a linguagem de programação Python, que permitiu a execução dos cálculos e simulações.

O código utilizado para tratamento e modelagem está disponível no Apêndice A.

3.1 Coleta e Preparação dos Dados

A etapa inicial do estudo consistiu na obtenção e organização dos dados necessários à análise. A base de dados foi composta por cotações históricas de um portfólio de 20 ações de elevada liquidez do mercado brasileiro, utilizando-se o índice IBOVESPA como benchmark para o comportamento do mercado e a taxa SELIC como proxy para a taxa de juros livre de risco (R_f).

Com o objetivo de avaliar o desempenho dos modelos em diferentes conjunturas econômicas, a análise foi replicada em dois períodos distintos e não sobrepostos:

- Período 1 (2017-2019): Caracterizado por um ciclo de queda da taxa de juros e relativa estabilidade econômica pré-pandemia.
- Período 2 (2022-2024): Marcado por um ciclo de forte alta da taxa de juros para controle inflacionário e maior volatilidade global.

Para cada período, os dados foram extraídos de uma planilha de origem (.xlsx) e submetidos a um processo de tratamento, conforme ilustrado nas Figuras 3.1, 3.2 e 3.3, que incluiu:

- Limpeza de Dados: Remoção de valores ausentes ou não numéricos.

- Conversão Temporal: A taxa SELIC, originalmente anual, foi convertida para sua equivalência diária para consistência com os retornos dos ativos.

Os detalhes da implementação computacional para a preparação dos dados podem ser consultados na figura 3.1, 3.2 e 3.3 no Apêndice A.

3.2 Cálculo dos Retornos e Métricas de Desempenho

Com os preços históricos devidamente tratados, procedeu-se ao cálculo dos retornos diários dos ativos, utilizando a variação percentual.

A partir da série de retornos diários, foram calculadas as métricas básicas de desempenho para cada ativo individualmente: o retorno médio histórico e a volatilidade, representada pelo desvio padrão dos retornos, conforme o código apresentado na Figura 3.4. Estas métricas foram então anualizadas para facilitar a interpretação, multiplicando o retorno médio por 252 (número aproximado de dias úteis em um ano) e a volatilidade pela raiz quadrada de 252. Os scripts em Python para o cálculo das métricas básicas de desempenho podem ser consultados no Apêndice A, na figura 3.4.

3.3 Estimação dos Parâmetros do Modelo (CAPM)

Com o objetivo de adotar uma abordagem mais robusta do que a simples utilização de médias históricas, este estudo emprega o Modelo de Precificação de Ativos de Capital (CAPM) para estimar o retorno esperado de cada ativo. O CAPM postula que o retorno esperado de um ativo é uma função de seu risco não diversificável (sistêmico), medido pelo coeficiente Beta (β). A implementação computacional do cálculo do Beta e do retorno esperado pelo CAPM, de acordo com a equação 2.6 apresentada na seção anterior, encontra-se detalhada nas Figuras 3.5 e 3.6, e pode ser consultada no Apêndice A.

3.4 Otimização de Portfólio (Markowitz)

Utilizando a Teoria Moderna de Portfólios de Markowitz, buscou-se a alocação de pesos que maximizasse o retorno ajustado ao risco do portfólio. O objetivo da otimização foi encontrar a carteira com o maior Índice de Sharpe possível, a partir da equação 2.5

A otimização foi realizada através do solver numérico SLSQP (Sequential Least Squares Programming), disponível na biblioteca `scipy`, e submetida às seguintes restrições:

- A soma dos pesos de todos os ativos deve ser igual a 1 (100%).
- Foi imposta uma restrição de peso mínimo de 1% para cada ativo, garantindo que a carteira final seja sempre plenamente diversificada entre os 20 ativos selecionados, evitando soluções concentradas.

As Figuras 3.7 e 3.8 (ver Apêndice A) detalham a configuração do problema de otimização, incluindo a função objetivo (maximizar o Sharpe, ou minimizar seu negativo) e as restrições impostas.

3.5 Otimização de Portfólio (Ideal)

Para além das abordagens clássicas, este estudo propõe a construção de uma "Carteira Ideal", concebida como uma estratégia adaptativa e focada no cenário macroeconômico adverso de 2022-2024, caracterizado por taxas de juros elevadas. O objetivo desta carteira não é a otimização irrestrita de Markowitz, mas sim a seleção de um subconjunto de ativos que demonstraram maior resiliência ao contexto de aperto monetário.

A construção dessa carteira consistiu em um processo de filtragem. Foram analisados os Índices de Sharpe individuais de todos os 20 ativos da amostra para o período de 2022-2024. Apenas os ativos que apresentaram um Índice de Sharpe positivo ($IS > 0$) foram selecionados para compor a Carteira Ideal. Em seguida, o mesmo processo de otimização de Markowitz para maximização do Índice de Sharpe (com peso mínimo de 1% para os ativos restantes) é aplicado, porém, apenas sobre este subconjunto de ativos de maior qualidade.

As Figuras 3.9 e 3.10, apresentadas no Apêndice A, ilustram a implementação computacional desta estratégia de duas etapas, ilustrando o processo de filtragem dos ativos com base no Índice de Sharpe.

3.6 Construção de Carteiras

Para permitir uma análise comparativa robusta, foram construídas duas carteiras de benchmark, conforme mostra o código da Figura 3.11:

- Carteira Equilibrada (1/N): Uma estratégia de diversificação ingênua onde o capital é dividido igualmente entre os 20 ativos, com cada um recebendo um peso de 5
- IBOVESPA: Representa uma estratégia de investimento passiva, que busca replicar o desempenho do principal índice do mercado de ações brasileiro.
- Carteira Eficiente (Markowitz): Carteira Markowitz visando maximizar o Índice de Sharpe.
- Carteira Ideal: Uma carteira, montada como uma adaptação ao cenário de juros altos do período de 2022-2024. Em vez de maximizar o Índice de Sharpe global, conforme a Teoria de Markowitz, esta carteira foi composta apenas pelos ativos que apresentaram um Índice de Sharpe positivo (Índice de Sharpe > 0).

A Figura 3.11, disponível no Apêndice A, apresenta em detalhe o código utilizado para a construção das carteiras.

3.7 Análise de Risco e Comparação de Desempenho Final

A etapa final do processo computacional consiste na consolidação e comparação das métricas de desempenho para as três carteiras em cada um dos períodos analisados, conforme ilustrado nas Figuras 3.12 e 3.13. As métricas utilizadas para a avaliação final foram:

- Retorno Anualizado: Medida de performance bruta.
- Volatilidade Anualizada: Medida de risco total.
- Índice de Sharpe Anualizado: Principal medida de retorno ajustado ao risco.

•Value at Risk (VaR) Histórico (99%): Medida do risco de perda, estimando a perda diária máxima esperada para a carteira com 99% de confiança.

As Figuras 3.12 e 3.13, incluídas no Apêndice A, sintetizam a comparação de performance das diferentes carteiras avaliadas.

4 ANÁLISES E RESULTADOS

Este capítulo apresenta os resultados obtidos a partir da aplicação da metodologia quantitativa descrita anteriormente. Para cada período, são detalhados os resultados individuais dos ativos, a composição das carteiras e, por fim, a análise comparativa de sua performance.

A amostra é composta por empresas de setores estratégicos e de grande representatividade na economia brasileira. Entre elas estão companhias de bens de consumo (Ambev), instituições financeiras (Banco do Brasil, Itaú, Bradesco, BB Seguridade, Itaúsa), energia elétrica (Eletrobras, Equatorial), siderurgia e mineração (Gerdau, Vale), petróleo e gás (Petrobras, PRIO), transportes e logística (Rumo), varejo e serviços (Raia Drogasil, Localiza), alimentos (JBS), saneamento (Sabesp) e indústria e tecnologia (WEG, Embraer). Essa diversidade setorial garante uma visão abrangente da dinâmica do mercado acionário brasileiro, permitindo avaliar como diferentes segmentos se comportam em termos de risco e retorno.

4.1 Análise do Período de 2017-2019

O primeiro período analisado, de janeiro de 2017 a dezembro de 2019, foi caracterizado por um ambiente de recuperação econômica e juros em queda no Brasil. A análise processou 739 dias de dados de preços para cada um dos 20 ativos da amostra e para o Ibovespa.

4.1.1 Análise Individual dos Ativos

A análise inicial dos ativos envolveu o cálculo de suas métricas de retorno e risco históricos, detalhadas na Tabela 4.1.

Tabela 4.1 – Métricas Básicas dos Ativos (2017-2019)

Ativo	Retorno Diário Médio	Volatilidade Diária	Retorno Anual Estimado	Volatilidade Anual Estimada
ABEV3	0,000398	0,014027	10,03%	22,27%
BBAS3	0,001325	0,023286	33,39%	36,96%
BBDC4	0,001153	0,018129	29,06%	28,78%
BBSE3	0,000833	0,015553	20,98%	24,69%
ELET3	0,001387	0,039588	34,95%	62,84%
EMBR3	0,000500	0,020952	12,59%	33,26%
EQTL3	0,001127	0,013956	28,39%	22,15%
GGBR4	0,001177	0,023739	29,67%	37,68%
ITSA4	0,001289	0,016971	32,48%	26,94%
ITUB4	0,001072	0,016786	27,02%	26,65%
JBSS3	0,001605	0,030480	40,45%	48,38%
PETR3	0,001184	0,023869	29,83%	37,89%
PETR4	0,001367	0,025597	34,44%	40,63%
PRIO3	0,004106	0,032421	103,47%	51,47%
RADL3	0,001027	0,018215	25,87%	28,92%
RAIL3	0,002208	0,021980	55,65%	34,89%
RENT3	0,002216	0,021109	55,85%	33,51%
SBSP3	0,001222	0,021898	30,81%	34,76%
VALE3	0,001453	0,023418	36,62%	37,17%
WEGE3	0,001696	0,016863	42,74%	26,77%
IBOV	0,000977	0,012479	24,62%	19,81%

Fonte: Elaboração própria.

Os resultados da Tabela 4.1 mostram que, no período de 2017 a 2019, as empresas apresentaram retornos positivos, ainda que acompanhados de diferentes níveis de volatilidade. Destaca-se que companhias ligadas a setores cíclicos, como mineração e petróleo, exibiram retornos mais expressivos, mas também maior risco, o que reflete a sensibilidade desses segmentos a variações externas.

Posteriormente, aplicou-se o modelo CAPM para estimar o retorno esperado e o Índice de Sharpe de cada ativo, conforme apresentado na Tabela 4.2.

Tabela 4.2 – Resultados CAPM e Índice de Sharpe por Ativo (2017-2019)

Ativo	Beta (β)	Retorno Esperado CAPM Anual.	Índice de Sharpe Anual.
ABEV3	0,5295	17,91%	0,1219
BBAS3	1,5097	39,68%	0,7055
BBDC4	1,2310	33,11%	0,7556
BBSE3	0,7053	21,54%	0,5536
ELET3	1,7209	44,87%	0,4398
EMBR3	0,5331	17,98%	0,1589
EQTL3	0,5845	19,03%	0,9515
GGBR4	1,1757	31,84%	0,5933
ITSA4	1,1216	30,61%	0,9344
ITUB4	1,1267	30,73%	0,7394
JBSS3	0,8131	23,83%	0,6850
PETR3	1,3681	36,30%	0,5943
PETR4	1,5273	40,10%	0,6677
PRI03	0,6248	19,86%	1,8683
RADL3	0,6073	19,50%	0,6418
RAIL3	1,0346	28,66%	1,3853
RENT3	1,0229	28,41%	1,4486
SBSP3	0,9376	26,53%	0,6759
VALE3	0,9055	25,83%	0,7883
WEGE3	0,6865	21,15%	1,3234

Fonte: Elaboração própria.

Na Tabela 4.2, observa-se que o índice de Sharpe e CAPM revelam diferenças relevantes no desempenho relativo das ações. Ativos que combinaram retornos acima da média com volatilidade controlada obtiveram melhor desempenho em termos relativos, evidenciando que não basta apenas analisar a rentabilidade isolada. Nesse contexto, empresas do setor financeiro e de utilidade pública mostraram resultados consistentes, sugerindo que sua menor exposição a choques externos permitiu gerar retornos proporcionais ao risco assumido.

Dessa forma, para resumir as principais métricas de desempenho e risco para cada um dos 20 ativos selecionados, procedeu-se a criação da Tabela 4.3. Foram calculados o retorno e a volatilidade anualizados a partir dos dados históricos, bem como o Beta e o Índice de Sharpe, utilizando o CAPM.

Tabela 4.3 – Análise Descritiva dos Ativos (2017-2019)

Ativo	Retorno Anual. Hist.	Volatilidade Anual.	Beta (β)	Índice de Sharpe Anual.
ABEV3	10,03%	22,27%	0,53	0,1219
BBAS3	33,39%	36,96%	1,51	0,7055
BBDC4	29,06%	28,78%	1,23	0,7556
BBSE3	20,98%	24,69%	0,71	0,5536
ELET3	34,95%	62,84%	1,72	0,4398
EMBR3	12,59%	33,26%	0,53	0,1589
EQTL3	28,39%	22,15%	0,58	0,9515
GGBR4	29,67%	37,68%	1,18	0,5933
ITSA4	32,48%	26,94%	1,12	0,9344
ITUB4	27,02%	26,65%	1,13	0,7394
JBSS3	40,45%	48,38%	0,81	0,6850
PETR3	29,83%	37,89%	1,37	0,5943
PETR4	34,44%	40,63%	1,53	0,6677
PRI03	103,47%	51,47%	0,62	1,8683
RADL3	25,87%	28,92%	0,61	0,6418
RAIL3	55,65%	34,89%	1,03	1,3853
RENT3	55,85%	33,51%	1,02	1,4486
SBSP3	30,81%	34,76%	0,94	0,6759
VALE3	36,62%	37,17%	0,91	0,7883
WEGE3	42,74%	26,77%	0,69	1,3234

Fonte: Elaboração própria.

Destarte, conforme a Tabela 4.3, o ativo PRI03 apresentou um desempenho excepcional, com retorno de 103,47% e o maior Índice de Sharpe (1,8683), indicando altíssima eficiência. O desempenho excepcional da PRI03 está relacionado ao setor de petróleo e gás, que no período de 2017 a 2019 foi favorecido pela recuperação dos preços internacionais do barril de petróleo, além do aumento de produção e expansão das operações da companhia, fatores que ampliaram a atratividade de suas ações. Em contrapartida, em termos de risco sistêmico, ELET3 foi o ativo mais agressivo (Beta de 1,72), enquanto ABEV3 foi o mais defensivo (Beta de 0,53) apresentando crescimento mais modesto, mas mantendo estabilidade diante das oscilações de mercado.

4.1.2 Composição das Carteiras e Comparação de Desempenho

Com os parâmetros definidos, foram construídas as carteiras. A Tabela 4.4, apresentada no Apêndice A, detalha a alocação da Carteira Otimizada (Markowitz), que se mostrou

diversificada. Já a Tabela 4.5, também no Apêndice A, apresenta a alocação da Carteira Equilibrada.

Tabela 4.6 – Métricas do Portfólio Otimizado (2017-2019)

Métrica	Valor
Retorno Diário	0,000988
Volatilidade Diária	0,012835
Sharpe Diário	0,054375
Retorno Anualizado	28,26%
Volatilidade Anualizada	20,38%
Sharpe Anualizado	0,8632

Os resultados da Tabela 4.6 evidenciam o desempenho da carteira com o retorno anualizado de 28,26%, acompanhado de uma volatilidade anualizada de 20,38%, resultando em um índice de Sharpe de 0,8632. Isso significa que, para cada unidade de risco assumido, o investidor obteve aproximadamente 0,86 unidades de retorno em excesso sobre o ativo livre de risco. Na prática, trata-se de uma relação risco-retorno satisfatória, embora moderada, indicando que o portfólio otimizado conseguiu reduzir parte da exposição ao risco, mas ao custo de uma rentabilidade mais contida.

Tabela 4.7 – Métricas da Carteira Equilibrada (1/N) para 2017-2019

Métrica	Valor
Retorno Diário	0,001417
Volatilidade Diária	0,012816
Sharpe Diário	0,087943
Retorno Anualizado	42,89%
Volatilidade Anualizada	20,35%
Sharpe Anualizado	1,3961

A carteira equilibrada, apresentada na Tabela 4.7, obteve um retorno anualizado de 42,89%, com uma volatilidade anualizada de 20,35%. O índice de Sharpe resultante, 1,3961, mostra que, neste período, a diversificação simples superou a carteira otimizada em termos de eficiência de risco-retorno. Esse desempenho pode estar associado ao fato de que algumas ações apresentaram desempenhos excepcionais no intervalo analisado, o que favoreceu a carteira de pesos iguais.

A comparação de performance das carteiras é consolidada na Tabela 4.8

Tabela 4.8 – Comparativo de Performance Anualizada (2017-2019)

Métrica	Markowitz	Equilibrada	IBOVESPA
Retorno Anualizado	28,26%	42,89%	24,62%
Volatilidade Anualizada	20,38%	20,35%	19,81%
Índice de Sharpe Anual.	0,8632	1,3961	0,8599
VaR Histórico (99%)	-3,09%	-3,11%	-2,94%

A partir dos parâmetros individuais, foram construídas duas carteiras. A Carteira Otimizada, baseada na Teoria de Markowitz, resultou em um portfólio diversificado, com maiores alocações em BBDC4 (11,70%) e VALE3 (11,47%). A Carteira Equilibrada simplesmente alocou 5% do capital em cada ativo. Portanto, para este período, a composição da carteira otimizada é a mesma, apresentando uma ampla diversificação, com pesos distribuídos ativamente entre todos os 20 ativos e destaques para setores como financeiro e commodities.

Os resultados demonstram que, neste período, a estratégia de diversificação simples da Carteira Equilibrada foi superior, alcançando o maior retorno bruto (42.89%) e o maior retorno ajustado ao risco (Sharpe de 1.3961), com níveis de risco (Volatilidade e VaR) muito similares aos das outras estratégias. Assim, ainda que a alocação igualitária seja menos sofisticada, ela capturou de maneira mais intensa os ganhos de empresas em ascensão, sem aumentar significativamente o risco global.

4.2 Análise do Período de 2022-2024

O segundo período foi marcado por maior volatilidade e juros elevados, testando as estratégias em um ambiente adverso. A análise utilizou cerca de 750 dias de dados.

4.2.1 Análise Individual dos Ativos

A análise inicial dos ativos envolveu o cálculo de suas métricas de retorno e risco históricos, detalhadas na Tabela 4.9.

Tabela 4.9 – Métricas Básicas dos Ativos (2022-2024)

Ativo	Retorno Diário Médio	Volatilidade Diária	Retorno Anual.	Volatilidade Anual.
ABEV3	-0,000095	0,015849	-2,38%	25,16%
BBAS3	0,001137	0,016306	28,65%	25,88%
BBDC4	-0,000400	0,019464	-10,08%	30,90%
BBSE3	0,001122	0,013045	28,28%	20,71%
ELET3	0,000262	0,018878	6,60%	29,97%
EMBR3	0,001389	0,025209	35,00%	40,02%
EQTL3	0,000439	0,015253	11,06%	24,21%
GGBR4	0,000238	0,020426	6,01%	32,43%
ITSA4	0,000580	0,013568	14,60%	21,54%
ITUB4	0,000790	0,014500	19,90%	23,02%
JBSS3	0,000249	0,020744	6,28%	32,93%
PETR3	0,001090	0,023991	27,47%	38,08%
PETR4	0,001156	0,024723	29,14%	39,25%
PRI03	0,001210	0,024405	30,50%	38,74%
RADL3	0,000090	0,016931	2,26%	26,88%
RAIL3	0,000216	0,018969	5,43%	30,11%
RENT3	-0,000289	0,023578	-7,28%	37,43%
SBSP3	0,001263	0,018695	31,84%	29,68%
VALE3	-0,000167	0,019654	-4,22%	31,20%
WEGE3	0,000866	0,018925	21,82%	30,04%
IBOV	0,000255	0,010937	6,43%	17,36%

Na Tabela 4.9 pode observar-se uma grande heterogeneidade entre os resultados, refletindo tanto diferenças setoriais quanto os impactos do cenário macroeconômico. Enquanto ativos como EMBR3 (35,00%) e SBSP3 (31,84%) se destacaram positivamente em termos de retorno anual, outros, como BBDC4 (-10,08%) e RENT3 (-7,28%), apresentaram desempenhos negativos, sinalizando dificuldades em seus respectivos setores.

No que se refere à volatilidade, ativos como EMBR3 (40,02%) e PRI03 (38,74%) evidenciam elevado risco, enquanto outros, como BBSE3 (20,71%) e ITUB4 (23,02%), mostraram-se mais estáveis. Comparando com o IBOV (17,36%), percebe-se que a maioria dos ativos apresentou volatilidade superior, o que reforça a relevância da diversificação na mitigação de riscos.

Posteriormente, aplicou-se o modelo CAPM para estimar o retorno esperado e o Índice de Sharpe de cada ativo, conforme apresentado na Tabela 4.10.

Tabela 4.10 – Resultados CAPM e Índice de Sharpe por Ativo (2022-2024)

Ativo	Beta (β)	Retorno Esperado CAPM Anual.	Índice de Sharpe Anual.
ABEV3	0,5093	9,36%	-0,5540
BBAS3	0,9447	6,94%	0,6605
BBDC4	1,0807	6,20%	-0,7003
BBSE3	0,4246	9,83%	0,8075
ELET3	1,0620	6,30%	-0,1653
EMBR3	0,5454	9,15%	0,5857
EQTL3	0,7810	7,84%	-0,0207
GGBR4	0,9714	6,80%	-0,1711
ITSA4	0,9393	6,97%	0,1415
ITUB4	0,9284	7,03%	0,3623
JBSS3	0,6181	8,75%	-0,1603
PETR3	1,0927	6,14%	0,4179
PETR4	1,0628	6,30%	0,4480
PRI03	1,0162	6,55%	0,4891
RADL3	0,7275	8,14%	-0,3460
RAIL3	0,8874	7,26%	-0,2033
RENT3	1,3785	4,59%	-0,5034
SBSP3	0,8838	7,28%	0,6833
VALE3	0,8986	7,20%	-0,5057
WEGE3	0,6471	8,59%	0,3415

A Tabela 4.10 demonstra um aspecto relevante, que ativos com maior Beta nem sempre apresentaram retornos compensatórios. Por exemplo, PRI03 (Beta 1,02) teve retorno esperado de apenas 6,55%, enquanto BBSE3 (Beta 0,42) apresentou um retorno esperado de 9,83%, mostrando uma relação risco-retorno mais atrativa. O Índice de Sharpe destaca a eficiência de cada ativo. BBSE3 (0,8075) e SBSP3 (0,6833) apresentaram os melhores desempenhos ajustados ao risco, enquanto BBDC4 (-0,7003) e VALE3 (-0,5057) tiveram índices negativos, sinalizando que o risco incorrido não foi compensado pelo retorno obtido.

Dessa forma, para resumir as principais métricas de desempenho e risco para cada um dos 20 ativos selecionados, procedeu-se a criação da Tabela 4.11. Foram calculados o retorno e a volatilidade anualizados a partir dos dados históricos, bem como o Beta e o Índice de Sharpe, utilizando o CAPM.

Tabela 4.11 – Análise Descritiva dos Ativos (2022-2024)

Ativo	Retorno Anual. Hist.	Volatilidade Anual.	Beta (β)	Índice de Sharpe Anual.
ABEV3	-2,38%	25,16%	0,51	-0,5540
BBAS3	28,65%	25,88%	0,94	0,6605
BBDC4	-10,08%	30,90%	1,08	-0,7003
BBSE3	28,28%	20,71%	0,42	0,8075
ELET3	6,60%	29,97%	1,06	-0,1653
EMBR3	35,00%	40,02%	0,55	0,5857
EQTL3	11,06%	24,21%	0,78	-0,0207
GGBR4	6,01%	32,43%	0,97	-0,1711
ITSA4	14,60%	21,54%	0,94	0,1415
ITUB4	19,90%	23,02%	0,93	0,3623
JBSS3	6,28%	32,93%	0,62	-0,1603
PETR3	27,47%	38,08%	1,09	0,4179
PETR4	29,14%	39,25%	1,06	0,4480
PRI03	30,50%	38,74%	1,02	0,4891
RADL3	2,26%	26,88%	0,73	-0,3460
RAIL3	5,43%	30,11%	0,89	-0,2033
RENT3	-7,28%	37,43%	1,38	-0,5034
SBSP3	31,84%	29,68%	0,88	0,6833
VALE3	-4,22%	31,20%	0,90	-0,5057
WEGE3	21,82%	30,04%	0,65	0,3415

A Tabela 4.11 consolida os resultados históricos e projetados, incluindo retorno, volatilidade, Beta e Sharpe. Essa visão integrada permite identificar ativos com forte valorização, mas elevado risco (como EMBR3 e PRI03) e, em contrapartida, ativos estáveis e consistentes (como ITUB4 e BBSE3).

Outro ponto importante é a influência do cenário macroeconômico. A taxa Selic média elevada no período reduziu a atratividade de alguns ativos e pressionou os índices de Sharpe, resultando em valores próximos ou até negativos para vários papéis.

Em síntese, os resultados reforçam a necessidade de diversificação, visto que ativos isolados apresentaram desempenhos bastante discrepantes, mas em conjunto permitem compor carteiras mais equilibradas. Conforme os resultados, ativos como BBDC4 (-10,08%) e RENT3 (-7,28%) tiveram retornos anualizados negativos. Em contrapartida, EMBR3 (35,00%) e SBSP3 (31,84%) apresentaram forte valorização. A taxa SELIC média mais alta (0,0459% ao dia) impactou negativamente os Índices de Sharpe, com muitos ativos apresentando valores negativos.

4.2.2 Composição das Carteiras e Comparação de Desempenho

A aplicação da Teoria de Markowitz neste período levou a um resultado notável: a Carteira Otimizada alocou 81% de seu capital em EMBR3, criando um portfólio de altíssima concentração. Este resultado evidencia a sensibilidade do modelo de otimização aos parâmetros de retorno esperados do CAPM.

Com os parâmetros definidos, foram construídas as carteiras. A Tabela 4.12, apresentada no Apêndice A, detalha a alocação da Carteira Otimizada, que se mostrou diversificada. A Tabela 4.13, também no Apêndice A, apresenta a alocação da Carteira Equilibrada. Por fim, a Tabela 4.14, igualmente no Apêndice A, detalha a alocação da Carteira Otimizada Ideal.

Tabela 4.15 – Métricas do Portfólio Otimizado (2022-2024)

Métrica	Valor
Retorno Diário	0,000334
Volatilidade Diária	0,020936
Sharpe Diário	-0,005930
Retorno Anualizado	8,79%
Volatilidade Anualizada	33,24%
Sharpe Anualizado	-0,0941

Tabela 4.16 – Métricas da Carteira Equilibrada (1/N) para 2022-2024

Métrica	Valor
Retorno Diário	0,000557
Volatilidade Diária	0,009997
Sharpe Diário	0,009869
Retorno Anualizado	15,07%
Volatilidade Anualizada	15,87%
Sharpe Anualizado	0,1567

Tabela 4.17 – Métricas do Portfólio Otimizado Ideal (2022-2024)

Métrica	Valor
Retorno Anualizado	34,89%
Volatilidade Anualizada	16,28%
Sharpe Anualizado	1,1297

Destarte, com o fito de realizar um comparativo de performance, criou-se a Tabela 4.18.

Tabela 4.18 – Comparativo de Performance Anualizada (2022-2024)

Métrica	Markowitz	Equilibrada	Ideal	IBOVESPA
Retorno Anualizado	8,79%	15,07%	34,89%	6,43%
Volatilidade Anualizada	33,24%	15,87%	16,28%	17,36%
Índice de Sharpe Anual.	-0,0941	0,1567	1,1298	-0,3351
VaR Histórico (99%)	-5,61%	-2,71%	-2,58%	-2,74%

A comparação entre as carteiras evidencia diferenças relevantes em termos de risco e retorno. O filtro de qualidade da "Carteira Ideal" selecionou apenas 10 dos 20 ativos para a otimização (BBAS3, BBSE3, EMBR3, ITSA4, ITUB4, PETR3, PETR4, PRIO3, SBSP3, WEGE3). O resultado é uma drástica diferença na composição final,

A carteira de Markowitz, mostrou uma concentração excessiva em EMBR3 (81%) e desempenho inferior, refletido em Sharpe negativo (-0,0941) e maior VaR (-5,61%). Já a Carteira Ideal destacou-se de forma expressiva, alcançando retorno anualizado de 34,89% e Sharpe de 1,1298, muito acima do IBOVESPA (6,43% e -0,3351, respectivamente), sem aumento proporcional do risco, o que confirma a relevância da filtragem prévia de ativos para potencializar a eficiência da otimização de carteiras.

A Carteira Equilibrada apresentou um melhor equilíbrio frente ao IBOVESPA e a carteira eficiente, com retorno anualizado de 15,07%, baixa volatilidade (15,87%) e maior Índice de Sharpe (0,1567).

4.3 Discussão Consolidada dos Resultados

A análise dos dois períodos distintos revela que a estratégia de diversificação simples (1/N) foi consistentemente superior à otimização de Markowitz com insumos do CAPM. A Fronteira Eficiente, onde a carteira otimizada deveria se situar no ponto de tangência da Reta do Mercado de Capitais, representando o maior Sharpe possível. No entanto, os resultados empíricos das Tabelas 4.3 e 4.11 mostram que a carteira 1/N alcançou um ponto superior no gráfico risco-retorno em ambos os cenários.

Contudo, os resultados também demonstram diferenças relevantes entre os dois períodos. No intervalo de 2017–2019, a economia brasileira enfrentava os efeitos da recessão anterior, o processo de recuperação fiscal, além das incertezas geradas pelo ciclo eleitoral de 2018. Nesse cenário, a volatilidade dos ativos foi elevada, e o desempenho médio das carteiras refletiu maior sensibilidade ao risco político e econômico. Já no período de 2022–2024, o contexto macroeconômico foi distinto: o país enfrentava os desdobramentos da pandemia da Covid-19, com impactos significativos na inflação, nas cadeias de produção e nas taxas de juros. A taxa Selic, por exemplo, atingiu patamares historicamente elevados, chegando a 13.75% em 2022, afetando diretamente a precificação dos ativos de renda variável.

Esses fatores ajudam a explicar por que, no período mais recente, a “Carteira Ideal”, construída somente com ativos de Índice de Sharpe positivo apresentou desempenho expressivamente superior, com retorno anualizado acima de 30% e risco relativamente controlado. Essa filtragem evitou ativos com performance fraca ou demasiadamente arriscada, favorecendo uma carteira mais eficiente. Em contrapartida, a carteira otimizada por Markowitz apresentou excessiva concentração em poucos ativos, como o caso de 81% alocados em EMBR3, tornando-se frágil diante de choques específicos.

Do ponto de vista estatístico, os indicadores reforçam esse diagnóstico: enquanto a carteira equilibrada e a ideal apresentaram Índice de Sharpe positivo no segundo período, a carteira de Markowitz e o próprio Ibovespa mantiveram valores negativos ou próximos de zero. Isso demonstra que a diversificação ampla (equilibrada) ou a filtragem de ativos (ideal) foram estratégias mais eficazes para equilibrar risco e retorno no contexto de elevada incerteza macroeconômica.

Portanto, pode-se afirmar que os resultados reforçam duas conclusões principais. Primeiro, a alocação $1/N$, embora simples, mostrou-se resiliente em ambos os períodos, validando a robustez dessa estratégia em ambientes de incerteza. Segundo, o pós pandemia trouxe um cenário de juros altos, inflação e reestruturação de setores, o que tornou as abordagens que evitam concentração extrema e selecionam ativos com melhor relação risco-retorno ainda mais vantajosas. Assim, a análise evidencia que a eficácia de cada modelo depende não apenas da teoria, mas também das condições específicas do ambiente econômico de cada período analisado.

5 CONCLUSÃO

O presente estudo teve por escopo a análise comparativa de metodologias para a construção de carteiras de investimento, a partir de um conjunto de 20 ativos de elevada capitalização listados no Ibovespa. A pesquisa avaliou o desempenho de portfólios em dois regimes macroeconômicos distintos: um período de relativa estabilidade e juros declinantes (2017-2019) e outro caracterizado por instabilidade e elevação da taxa livre de risco (2022-2024). A análise metodológica confrontou a otimização clássica da Teoria Moderna de Portfólios de Markowitz, utilizando o Modelo de Precificação de Ativos de Capital (CAPM) para a estimação de retornos e seu desempenho ajustado ao risco (Índice de Sharpe) como etapa precedente à otimização. Adicionalmente, foi proposta e testada uma abordagem adaptativa para o segundo período, denominada "Carteira Ideal", que incorpora um processo de filtro do Índice Sharpe positivo. Além disso, foi comparada com a estratégia de diversificação heurística de pesos iguais (1/N) e o Índice Bovespa, sendo o Valor em Risco (VaR) também utilizado como métrica para avaliação de risco.

Os resultados empíricos demonstraram, de maneira inequívoca, a sensibilidade da otimização de Markowitz aos seus parâmetros de entrada, um fenômeno alinhado ao que a literatura denomina "viés de maximização de erro" (error-maximization bias). A fonte deste viés no presente estudo foi majoritariamente o vetor de retornos esperados derivado do modelo CAPM. No período de juros baixos (2017-2019), a estratégia de diversificação simples (1/N) já se mostrou superior, questionando a eficácia prática da otimização frente à incerteza dos parâmetros.

A fragilidade do modelo clássico foi, contudo, exacerbada no cenário adverso de 2022-2024. Neste ínterim, o prêmio de risco de mercado negativo distorceu as premissas do CAPM, levando a "Carteira Eficiente Padrão" a uma alocação de capital extremamente concentrada e de alto risco, resultando em um Índice de Sharpe negativo. É neste ponto que a contribuição primordial desta investigação reside: a performance da "Carteira Ideal". A introdução de um filtro de qualidade (Sharpe positivo) prévio à otimização provou ser uma estratégia dominante. O sucesso desta abordagem híbrida não se deu apenas pela obtenção de um retorno superior, mas primordialmente pela drástica mitigação do risco, reduzindo a volatilidade e o Value at Risk a patamares similares aos dos benchmarks diversificados, o que culminou em um Índice de Sharpe de 1,1298.

Depreende-se destes achados que a mesma metodologia de otimização pode gerar estruturas de portfólio radicalmente opostas – diversificada em cenários benignos e concentrada em cenários adversos – como resposta direta ao ambiente macroeconômico. A metodologia da "Carteira Ideal" logrou êxito ao mitigar o viés do modelo, condicionando o universo de otimização a ativos que já demonstravam mérito intrínseco e evitando que o otimizador fosse "contaminado" por previsões de retorno teoricamente problemáticas.

A execução deste estudo não foi trivial. Foi necessário desenvolver rotinas de programação para coleta, tratamento e análise de séries temporais extensas, cobrindo dois períodos de grande relevância histórica para a economia brasileira. A aplicação integrada de diferentes modelos quantitativos exigiu atenção metodológica e validações constantes. Além disso, as oscilações econômicas e os desafios de replicar cenários reais a partir de modelos teóricos representaram limitações importantes, mas que também enriqueceram a análise ao evidenciar a distância entre teoria e prática.

Conclui-se, portanto, que a eficácia empírica dos modelos de otimização de portfólio é indissociável da acurácia de seus insumos. Embora a heurística $1/N$ se apresente como uma alternativa resiliente à incerteza dos parâmetros, este estudo evidencia que metodologias adaptativas, que integram critérios de seleção qualitativa a processos de otimização quantitativa, representam um caminho mais promissor para a construção de carteiras eficientes, especialmente em mercados voláteis como o brasileiro. Tal constatação possui implicação prática para gestores e investidores, e que a superioridade na gestão de ativos pode não residir na escolha entre complexidade teórica e simplicidade prática, mas na síntese criteriosa de ambas: utilizando a otimização como ferramenta, mas condicionando-a a critérios de seleção que reflitam a realidade empírica do mercado.

Como sugestão para trabalhos futuros, destaca-se a possibilidade de ampliar a análise para mais setores da economia ou incluir ativos de renda fixa e fundos de investimento, permitindo uma avaliação mais próxima da realidade de portfólios diversificados. Além disso, o uso de técnicas mais recentes, como modelos multifatoriais (ex.: Fama-French) ou algoritmos de otimização via inteligência artificial, pode oferecer novas perspectivas sobre a eficiência das carteiras. Por fim, seria relevante aprofundar a análise qualitativa dos eventos econômicos e políticos, integrando-os de forma mais direta à modelagem quantitativa, para compreender de maneira ainda mais robusta a dinâmica entre risco, retorno e conjuntura de mercado.

REFERÊNCIAS

- AVEN, T. **Risk assessment and risk management: Review of recent advances on their foundation.** European Journal of Operational Research, v. 253, n. 1, p. 1–13, aug 2016.
- BAGANZI, R.; KIM, B. G.; SHIN, G. C. **Modelagem de otimização de portfólio com r para melhorar a tomada de decisão e a previsão no caso da bolsa de valores de uganda.** Revista de Gestão de Riscos Financeiros, v. 6, n. 4, p. 1–27, 2017.
- BANCO CENTRAL DO BRASIL. **Gestão integrada de riscos.** Brasília: Banco Central do Brasil, 2017. Acesso em: 16 set. 2024. Disponível em: <https://www.bcb.gov.br/content/publicacoes/outras_pub_alfa/Gestao-Integrada-de-Riscos.pdf>.
- BANCO DO BRASIL. **Análise de Perfil do Investidor.** BANCO DO BRASIL, 2024. Acesso em: 16 set. 2024. Disponível em: <[https://www.bb.com.br/pbb/pagina-inicial/empresas/produtos-e-servicos/investimentos/analise-de-perfil-do-investidor#/>](https://www.bb.com.br/pbb/pagina-inicial/empresas/produtos-e-servicos/investimentos/analise-de-perfil-do-investidor#/).
- BERNSTEIN, P. L. **Desafio aos Deuses: A Fascinante História do Risco.** 6. ed. Rio de Janeiro: Editora Campus, 1997.
- BODIE, Z.; KANE, A.; MARCUS, A. J. **Investimentos.** 10. ed. [s.l.]: AMGH Editora, 2014.
- BRASIL, B. C. do. **Relatório de Estabilidade Financeira.** 2023. Disponível em: <<https://www.bcb.gov.br>>.
- DRUCKER, P. F. **Management Challenges for the 21st Century.** New York: HarperBusiness, 1999.
- FAMA, E. F.; FRENCH, K. R. **The cross-section of expected stock returns.** The Journal of Finance, v. 47, n. 2, p. 427–465, 1992.
- FAMA, E. F.; FRENCH, K. R. **O modelo de precificação de ativos de capital: teoria e evidências.** Revista de Administração de Empresas, v. 47, n. 2, p. 103–118, abr 2007.
- FREITAS, T. A. d. **Risco de Mercado - A importância do gerenciamento de risco de mercado para uma instituição financeira de corretora de câmbio e valores mobiliários.** Dissertação (Trabalho de Conclusão de Curso (Especialização em Contabilidade em IFRS e Controladoria)) — Universidade Federal de Minas Gerais, Belo Horizonte, 2017.

HUBBARD, D. W. **How to Measure Anything: Finding the Value of Intangibles in Business**. Hoboken: John Wiley & Sons, 2009.

HUBBARD, D. W. **The failure of risk management: Why it's broken and how to fix it**. 2. ed. New Jersey: John Wiley & Sons, 2020.

JORION, P. **Value at Risk: The New Benchmark for Managing Financial Risk**. 3rd. ed. New York: McGraw-Hill, 2007.

JORION, P. **Value at risk: a nova fonte de referência para a gestão de risco financeiro**. 2. ed. São Paulo: BM&FBovespa, 2010.

LIMA, F. G. **Análise de Investimentos: Teoria e Aplicações Práticas**. São Paulo: Saraiva, 2007.

LIMA, F. G. **Análise de riscos**. São Paulo: Atlas, 2016.

MARKOWITZ, H. **Portfolio selection**. The Journal of Finance, VII, n. 1, March 1952.

MISTRY, J.; KHATWANI, R. A. **Examinando a superioridade do modelo de índice único sharpe de seleção de portfólio: Um estudo do setor de média capitalização indiano**. Humanit Soc Sci Commun, v. 10, p. 178, 2023. Disponível em: <<https://doi.org/10.1057/s41599-023-01686-y>>.

NETO, A. A. **Mercado financeiro**. 6. ed. São Paulo: Atlas, 2005.

VARGA, G. **Índice de sharpe e outros indicadores de performance aplicados a fundos de ações brasileiros**. Revista de Administração Contemporânea, v. 5, n. 3, p. 215–245, set 2001.

ZANINI, F. A. M.; FIGUEIREDO, A. C. **As teorias de carteira de markowitz e de sharpe: Uma aplicação no mercado brasileiro de ações entre julho/95 e junho/2000**. RAM. Revista de Administração Mackenzie, v. 6, n. 2, p. 38–65, abr 2005.

REIS, Tiago. **Teoria de Markowitz: como calcular a relação de risco e retorno**. Suno Research, 26 fev. 2021. Disponível em: <https://www.suno.com.br/artigos/teoria-de-markowitz/>

APÊNDICE A

Figura 3.1 – Preparação de dados - Parte 1

```
def carregar_e_preparar_dados_individuais(file_path, sheet_name_completa, coluna_valor, periodo_dados_tuple, nome_ativo_saida, is_selic=False):
    """Carrega dados de uma aba, seleciona colunas, converte data, filtra período e define índice."""
    try:
        df = pd.read_excel(file_path, sheet_name=sheet_name_completa)

        coluna_data_original = df.columns[0]
        nome_coluna_valor_final = "Preco"

        df = df.rename(columns={coluna_data_original: "Data", coluna_valor: nome_coluna_valor_final})
        df = df[["Data", nome_coluna_valor_final]]
        df["Data"] = pd.to_datetime(df["Data"], errors='coerce', dayfirst=True)
        df = df.dropna(subset=["Data"])
        df = df.sort_values(by="Data", ascending=True)
        df = df.set_index("Data")
        df = df.loc[periodo_dados_tuple[0]:periodo_dados_tuple[1]]
        df = df.dropna(subset=[nome_coluna_valor_final])
```

Fonte: Elaboração própria.

Figura 3.2 – Preparação de dados - Parte 2

```
def agrupar_e_salvar_dados_periodo(dados_dict, periodo_str_label, output_dir):
    """Agrupa os DataFrames de preços e SELIC, alinha e salva em CSV."""
    lista_dfs_precos = []
    ativos_incluidos = []
    for ativo, df_ativo in dados_dict.items():
        if ativo != "SELIC" and df_ativo is not None:
            lista_dfs_precos.append(df_ativo[["Preco"]].rename(columns={"Preco": ativo}))
            ativos_incluidos.append(ativo)

    if not lista_dfs_precos:
        print(f" Nenhum dado de preço (exceto SELIC) para agrupar no período {periodo_str_label}.")
        df_selic_final = dados_dict.get("SELIC", pd.DataFrame())
        if df_selic_final is None: df_selic_final = pd.DataFrame()
        return pd.DataFrame(), df_selic_final

    df_precos_agrupados = pd.concat(lista_dfs_precos, axis=1, join='inner')
    df_precos_agrupados = df_precos_agrupados.sort_index(ascending=True)
    df_precos_agrupados.dropna(inplace=True)

    print(f" DataFrame de preços agrupados para {periodo_str_label} (ativos: {', '.join(ativos_incluidos)}). Shape: {df_precos_agrupados.shape}")

    df_selic_original = dados_dict.get("SELIC")
    df_selic_alinhada = pd.DataFrame()

    if df_precos_agrupados.empty:
        print(f" Preços agrupados estão vazios para {periodo_str_label}, não é possível alinhar SELIC.")
        df_selic_final = df_selic_original if df_selic_original is not None else pd.DataFrame()
    elif df_selic_original is not None and not df_selic_original.empty:
        df_selic_original_diaria = df_selic_original.copy()
        # A coluna "Preco" da SELIC na planilha é % a.a. Convertendo para taxa diária.
        df_selic_original_diaria["Preco"] = (1 + df_selic_original_diaria["Preco"] / 100)**(1/252) - 1
        selic_reindexed = df_selic_original_diaria.reindex(df_precos_agrupados.index, method='ffill')
        selic_reindexed.dropna(inplace=True)
        if not selic_reindexed.empty:
            df_selic_alinhada = selic_reindexed
            common_index = df_precos_agrupados.index.intersection(df_selic_alinhada.index)
            df_precos_agrupados = df_precos_agrupados.loc[common_index]
            df_selic_alinhada = df_selic_alinhada.loc[common_index]
```

Fonte: Elaboração própria.

Figura 3.3 – Preparação de dados - Parte 3

```

print("--- INICIANDO ETAPA 1: PREPARAÇÃO DOS DADOS ---")
dados_preparados_todos_periodos = {}
for periodo_label, config_perodo in PERIODOS_ANALISE.items():
    print(f"\nProcessando Período: {periodo_label}")
    dados_perodo_atual = {}
    periodo_datas = (config_perodo["inicio"], config_perodo["fim"])
    sufixo_aba = config_perodo["sufixo_aba"]

    for ticker in TICKERS_DISPONIVEIS:
        sheet_name = f"{ticker} {sufixo_aba}"
        dados_perodo_atual[ticker] = carregar_e_preparar_dados_individuais(EXCEL_FILE_PATH, sheet_name, "Último", periodo_datas, ticker)

    dados_perodo_atual["IBOV"] = carregar_e_preparar_dados_individuais(EXCEL_FILE_PATH, f"IBOVSPA {sufixo_aba}", "Último", periodo_datas, "IBOV")
    dados_perodo_atual["SELIC"] = carregar_e_preparar_dados_individuais(EXCEL_FILE_PATH, f"SELIC {sufixo_aba}", "Taxa de juros - % a.a.", periodo_datas, "SELIC", is_selic=True)

    precos_agrupados, selic_alinhada = agrupar_e_salvar_dados_perodo(dados_perodo_atual, periodo_label, OUTPUT_DIR)
    dados_preparados_todos_periodos[periodo_label] = {"precos": precos_agrupados, "selic": selic_alinhada}
print("--- FIM DA ETAPA 1: PREPARAÇÃO DOS DADOS ---")

```

Fonte: Elaboração própria.

Figura 3.4 – Cálculo das métricas básicas de desempenho

```

def calcular_retornos_e_metricas_basicas(precos_df, selic_df, periodo_label, output_dir):
    print(f"\n--- ETAPA 2: Calculando retornos e métricas para o período: {periodo_label} ---")
    if precos_df.empty:
        print(f" DataFrame de preços vazio para {periodo_label}. Pulando cálculo de retornos.")
        return pd.DataFrame(), np.nan

    retornos_df = precos_df.pct_change().dropna()
    print(f" Retornos diários calculados para {periodo_label}. Shape: {retornos_df.shape}")

    media_retornos_diaros = retornos_df.mean()
    volatilidade_diaria = retornos_df.std()
    media_retornos_anualizada = media_retornos_diaros * 252
    volatilidade_anualizada = volatilidade_diaria * np.sqrt(252)

    rf_diaria_media_perodo = np.nan
    if selic_df is not None and not selic_df.empty:
        rf_diaria_media_perodo = selic_df["Preco"].mean()
        print(f" Média da taxa SELIC diária (Rf) para {periodo_label}: {rf_diaria_media_perodo:.6f}")
    else:
        print(f" Dados da SELIC não disponíveis para {periodo_label} para cálculo da Rf média.")

    metricas_df = pd.DataFrame({
        "Retorno Diário Médio": media_retornos_diaros,
        "Volatilidade Diária": volatilidade_diaria,
        "Retorno Anualizado Estimado": media_retornos_anualizada,
        "Volatilidade Anualizada Estimada": volatilidade_anualizada
    })
    print(f" Métricas básicas calculadas para {periodo_label}:")
    print(metricas_df)

    periodo_sufixo_arquivo = periodo_label.replace("-", "_")
    path_retornos = os.path.join(output_dir, f"retornos_diaros_{periodo_sufixo_arquivo}.csv")
    path_metricas = os.path.join(output_dir, f"metricas_basicas_{periodo_sufixo_arquivo}.csv")
    retornos_df.to_csv(path_retornos)
    metricas_df.to_csv(path_metricas)
    print(f" Salvo: {path_retornos}")
    print(f" Salvo: {path_metricas}")

    return retornos_df, metricas_df, rf_diaria_media_perodo

print("\n--- INICIANDO ETAPA 2: CÁLCULO DE RETORNOS E MÉTRICAS BÁSICAS ---")
dados_com_retornos = {}
for periodo_label, dados in dados_preparados_todos_periodos.items():
    retornos, metricas, rf_media = calcular_retornos_e_metricas_basicas(dados["precos"], dados["selic"], periodo_label, OUTPUT_DIR)
    dados_com_retornos[periodo_label] = {"retornos": retornos, "metricas_basicas": metricas, "rf_media": rf_media, "selic_original_alinhada": dados["selic"]}
print("--- FIM DA ETAPA 2: CÁLCULO DE RETORNOS E MÉTRICAS BÁSICAS ---")

```

Fonte: Elaboração própria.

Figura 3.5 – Cálculo CAPM e Sharpe - Parte 1

```

def calcular_capm_e_sharpe_individual(retornos_ativos_df, rf_diaria_media, periodo_label, output_dir):
    print(f"\n--- ETAPA 3.1: Calculando CAPM e Sharpe para o período: {periodo_label} ---")

    if "IBOV" not in retornos_ativos_df.columns:
        print(f" Coluna IBOV não encontrada nos retornos para {periodo_label}. Pulando CAPM/Sharpe.")
        return pd.DataFrame()

    retornos_mercado = retornos_ativos_df["IBOV"]
    retornos_apenasacoes = retornos_ativos_df.drop(columns=["IBOV"])

    if retornos_apenasacoes.empty:
        print(f" Não há outros ativos além do IBOV para calcular CAPM/Sharpe no período {periodo_label}.")
        return pd.DataFrame()

    covariancias = retornos_apenasacoes.apply(lambda x: x.cov(retornos_mercado))
    variancia_mercado = retornos_mercado.var()

    betas = pd.Series(np.nan, index=retornos_apenasacoes.columns)
    if variancia_mercado != 0:
        betas = covariancias / variancia_mercado
    else:
        print(f" ALERTA: Variância do mercado é zero para {periodo_label}. Betas serão NaN.")

    retorno_medio_mercado_diario = retornos_mercado.mean()
    premio_risco_mercado_diario = retorno_medio_mercado_diario - rf_diaria_media
    retornos_esperados_capm_diario = rf_diaria_media + (betas * premio_risco_mercado_diario)
    retornos_esperados_capm_anualizado = (1 + retornos_esperados_capm_diario)**252 - 1

    retornos_mediosacoes_diarios = retornos_apenasacoes.mean()
    excesso_retorno_diarioacoes = retornos_mediosacoes_diarios - rf_diaria_media
    volatilidades_diariasacoes = retornos_apenasacoes.std()

    indice_sharpe_diarioacoes = excesso_retorno_diarioacoes / volatilidades_diariasacoes.replace(0, np.nan)
    indice_sharpe_anualizadoacoes = indice_sharpe_diarioacoes * np.sqrt(252)

    resultados_df = pd.DataFrame({
        "Beta": betas,
        "Retorno Esperado CAPM (Diário)": retornos_esperados_capm_diario,
        "Retorno Esperado CAPM (Anualizado)": retornos_esperados_capm_anualizado,
        "Índice de Sharpe (Diário)": indice_sharpe_diarioacoes,
        "Índice de Sharpe (Anualizado)": indice_sharpe_anualizadoacoes
    })
    print(f" Resultados CAPM e Sharpe para {periodo_label}:")
    print(resultados_df)

    periodo_sufixo_arquivo = periodo_label.replace("-", "_")
    path_capm_sharpe = os.path.join(output_dir, f"capm_sharpe_individual_{periodo_sufixo_arquivo}.csv")
    resultados_df.to_csv(path_capm_sharpe)
    print(f" Salvo: {path_capm_sharpe}")
    return resultados_df

```

Fonte: Elaboração própria.

Figura 3.6 – Cálculo CAPM e Sharpe - Parte 2

```

print("\n--- INICIANDO ETAPA 3: APLICAÇÃO DE MODELOS FINANCEIROS (APENAS CAPM) ---")
dados_com_modelos = {}
for periodo_label, dados in dados_com_retornos.items():
    if dados["retornos"].empty or pd.isna(dados["rf_media"]):
        print(f"Pulando modelos para {periodo_label} devido a dados de retorno ou Rf ausentes.")
        dados_com_modelos[periodo_label] = {"capm_sharpe": pd.DataFrame()}
        continue

    capm_sharpe_df = calcular_capm_e_sharpe_individual(dados["retornos"], dados["rf_media"], periodo_label, OUTPUT_DIR)
    dados_com_modelos[periodo_label] = {"capm_sharpe": capm_sharpe_df}
print("--- FIM DA ETAPA 3: APLICAÇÃO DE MODELOS FINANCEIROS ---")

```

Fonte: Elaboração própria.

Figura 3.7 – Otimização de Portfólio (Markowitz) - Parte 1

```

# --- ETAPA 4: OTIMIZAÇÃO DE PORTFÓLIO (MARKOWITZ) ---
def calcular_performance_portfolio(pesos, retornos_medios_diarios, matriz_cov_diaria, rf_diaria_media):
    retorno_portfolio_diario = np.sum(retornos_medios_diarios * pesos)
    volatilidade_portfolio_diaria = np.sqrt(np.dot(pesos.T, np.dot(matriz_cov_diaria, pesos)))
    sharpe_ratio_diario = (retorno_portfolio_diario - rf_diaria_media) / volatilidade_portfolio_diaria if volatilidade_portfolio_diaria != 0 else 0
    return retorno_portfolio_diario, volatilidade_portfolio_diaria, sharpe_ratio_diario
def otimizar_portfolio_markowitz(retornos_df, retornos_esperados_capm, rf_diaria_media, periodo_label, output_dir):
    print(f"\n--- ETAPA 4: Otimizando Portfólio (Markowitz) para o período: {periodo_label} ---")
    retornos_apanas_acoes = retornos_df.drop(columns=["IBOV"], errors='ignore')
    if retornos_apanas_acoes.empty:
        print(f" Não há ativos para otimizar no período {periodo_label}.")
        return None, None

    num_ativos = len(retornos_apanas_acoes.columns)
    retornos_medios_diarios_acoes = retornos_esperados_capm
    matriz_cov_diaria_acoes = retornos_apanas_acoes.cov()

    def neg_sharpe_ratio(pesos):
        _, sharpe_p = calcular_performance_portfolio(pesos, retornos_medios_diarios_acoes, matriz_cov_diaria_acoes, rf_diaria_media)
        return -sharpe_p

    constraints = ({'type': 'eq', 'fun': lambda x: np.sum(x) - 1})
    peso_minimo = 0.01
    bounds = tuple((peso_minimo, 1) for _ in range(num_ativos))
    pesos_iniciais = np.array(num_ativos * [1. / num_ativos])
    otimizacao_resultado = sco.minimize(neg_sharpe_ratio, pesos_iniciais, method='SLSQP', bounds=bounds, constraints=constraints)
    if not otimizacao_resultado.success:
        print(f" Otimização Markowitz falhou para {periodo_label}: {otimizacao_resultado.message}")
        return None, None

    pesos_otimos = otimizacao_resultado.x
    ret_otimo_d, vol_otima_d, sharpe_otimo_d = calcular_performance_portfolio(pesos_otimos, retornos_medios_diarios_acoes, matriz_cov_diaria_acoes, rf_diaria_media)
    ret_otimo_a = (1 + ret_otimo_d)**252 - 1
    vol_otima_a = vol_otima_d * np.sqrt(252)
    sharpe_otimo_a = sharpe_otimo_d * np.sqrt(252)

    pesos_otimos_df = pd.DataFrame(pesos_otimos, index=retornos_apanas_acoes.columns, columns=["Peso Ótimo"])
    print(f" Pesos Ótimos (Formatado) para {periodo_label}:")
    pesos_formatados = pesos_otimos_df['Peso Ótimo'].map(lambda p: f'{p:.2%}' if p > 0.0001 else '0.00%')
    print(pesos_formatados)

    metricas_otimas_dict = {
        "Retorno Diário": ret_otimo_d, "Volatilidade Diária": vol_otima_d, "Sharpe Diário": sharpe_otimo_d,
        "Retorno Anualizado": ret_otimo_a, "Volatilidade Anualizada": vol_otima_a, "Sharpe Anualizado": sharpe_otimo_a
    }
    metricas_otimas_df = pd.Series(metricas_otimas_dict, name=f"Portfólio Otimizado {periodo_label}")
    print(f" Métricas do Portfólio Ótimo para {periodo_label}:")
    print(metricas_otimas_df)

    path_pesos = os.path.join(output_dir, f"pesos_otimos_markowitz_{periodo_label.replace('-', '_')}.csv")
    path_metricas = os.path.join(output_dir, f"metricas_portfolio_otimizado_{periodo_label.replace('-', '_')}.csv")
    pesos_otimos_df.to_csv(path_pesos)
    metricas_otimas_df.to_csv(path_metricas)
    print(f" Salvo: {path_pesos}")
    print(f" Salvo: {path_metricas}")
    return pesos_otimos_df, metricas_otimas_df

```

Fonte: Elaboração própria.

Figura 3.8 – Otimização de Portfólio (Markowitz) - Parte 2

```

print("\n--- INICIANDO ETAPA 4: OTIMIZAÇÃO DE PORTFÓLIO (MARKOWITZ) ---")
dados_com_otimizacao = {}

for periodo_label, dados_retorno in dados_com_retornos.items():
    if periodo_label not in dados_com_modelos or dados_com_modelos[periodo_label]["capm_sharpe"].empty:
        print(f"Pulando otimização Markowitz para {periodo_label} devido a dados ausentes do CAPM.")
        dados_com_otimizacao[periodo_label] = {"pesos_otimos": pd.DataFrame(), "metricas_otimas": pd.Series(dtype=float)}
        continue

    retornos_df = dados_retorno["retornos"]
    rf_media = dados_retorno["rf_media"]
    resultados_capm_df = dados_com_modelos[periodo_label]["capm_sharpe"]
    retornos_esperados_capm = resultados_capm_df["Retorno Esperado CAPM (Diário)"]
    pesos_opt, metricas_opt = otimizar_portfolio_markowitz(
        retornos_df,
        retornos_esperados_capm,
        rf_media,
        periodo_label,
        OUTPUT_DIR
    )
    dados_com_otimizacao[periodo_label] = {"pesos_otimos": pesos_opt, "metricas_otimas": metricas_opt}

```

Fonte: Elaboração própria.

Figura 3.9 - Otimização de Portfólio (Ideal) - Parte 1

```

# --- ETAPA 4.B: OTIMIZAÇÃO DA CARTEIRA "IDEAL" (FILTRADA POR SHARPE POSITIVO) ---
def otimizar_portfolio_ideal(retornos_df, resultados_capm_df, rf_diaria_media, periodo_label, output_dir):
    """
    Primeiro filtra os ativos com Sharpe positivo e depois otimiza o portfólio.
    """
    print(f'\n--- ETAPA 4.B: Otimizando Portfólio "Ideal" (Sharpe > 0) para o período: {periodo_label} ---')

    # 1. FILTRAR ATIVOS COM SHARPE ANUALIZADO POSITIVO
    ativos_filtrados_df = resultados_capm_df[resultados_capm_df['Índice de Sharpe (Anualizado)'] > 0]

    if ativos_filtrados_df.empty:
        print(f" Nenhum ativo com Sharpe positivo encontrado para o período {periodo_label}. Pulando otimização ideal.")
        return None, None

    tickers_bons = ativos_filtrados_df.index
    print(f" Ativos selecionados com Sharpe positivo: {list(tickers_bons)}")

    retornos_apanas_acoes = retornos_df[tickers_bons]

    # 2. RODAR A OTIMIZAÇÃO DE MARKOWITZ NO UNIVERSO FILTRADO
    num_ativos = len(retornos_apanas_acoes.columns)
    retornos_medios_diarios_acoes = retornos_apanas_acoes.mean()
    matriz_cov_diaria_acoes = retornos_apanas_acoes.cov()

    def neg_sharpe_ratio(pesos):
        _, sharpe_p = calcular_performance_portfolio(pesos, retornos_medios_diarios_acoes, matriz_cov_diaria_acoes, rf_diaria_media)
        return -sharpe_p

    constraints = ({'type': 'eq', 'fun': lambda x: np.sum(x) - 1})
    peso_minimo = 0.01
    bounds = tuple((peso_minimo, 1) for _ in range(num_ativos))

    pesos_iniciais = np.array(num_ativos * [1. / num_ativos])
    otimizacao_resultado = sco.minimize(neg_sharpe_ratio, pesos_iniciais, method='SLSQP', bounds=bounds, constraints=constraints)

    if not otimizacao_resultado.success:
        print(f" Otimização Ideal falhou para {periodo_label}: {otimizacao_resultado.message}")
        return None, None

    pesos_otimos = otimizacao_resultado.x
    ret_otimo_d, vol_otima_d, sharpe_otimo_d = calcular_performance_portfolio(pesos_otimos, retornos_medios_diarios_acoes, matriz_cov_diaria_acoes, rf_diaria_media)

    ret_otimo_a = (1 + ret_otimo_d)**252 - 1
    vol_otima_a = vol_otima_d * np.sqrt(252)
    sharpe_otimo_a = sharpe_otimo_d * np.sqrt(252)

    pesos_otimos_df = pd.DataFrame(pesos_otimos, index=retornos_apanas_acoes.columns, columns=["Peso Ideal"])
    metricas_otimas_dict = {
        "Retorno Anualizado": ret_otimo_a, "Volatilidade Anualizada": vol_otima_a, "Sharpe Anualizado": sharpe_otimo_a
    }
    metricas_otimas_df = pd.Series(metricas_otimas_dict, name=f'Portfólio Ideal {periodo_label}')

    # --- LINHAS ADICIONADAS PARA EXIBIR OS RESULTADOS NO TERMINAL ---
    print(f" Pesos Ótimos da Carteira Ideal (Formatado) para {periodo_label}:")
    pesos_formatados = pesos_otimos_df['Peso Ideal'].map(lambda p: f'{p:.2%}' if p > 0.0001 else '0.00%')
    print(pesos_formatados)

    print(f" Métricas do Portfólio Ideal para {periodo_label}:")
    print(metricas_otimas_df)
    # --- FIM DAS LINHAS ADICIONADAS ---

    # Salva os resultados em arquivos com nomes distintos
    path_pesos = os.path.join(output_dir, f'pesos_ideal_{periodo_label.replace('-', '_')}.csv')
    path_metricas = os.path.join(output_dir, f'metricas_portfolio_ideal_{periodo_label.replace('-', '_')}.csv')
    pesos_otimos_df.to_csv(path_pesos)
    metricas_otimas_df.to_csv(path_metricas)
    print(f" Salvo: {path_pesos}")
    print(f" Salvo: {path_metricas}")

```

Fonte: Elaboração própria.

Figura 3.10 - Otimização de Portfólio (Ideal) - Parte 2

```

    return pesos_otimos_df, metricas_otimas_df

# --- LOOP PARA EXECUTAR A NOVA OTIMIZAÇÃO "IDEAL" ---
print('\n--- INICIANDO ETAPA 4.B: CONSTRUÇÃO DA CARTEIRA "IDEAL" ---')
dados_com_carteira_ideal = {}
for periodo_label, dados in dados_com_retornos.items():
    if dados["retornos"].empty or periodo_label not in dados_com_modelos:
        print(f"Pulando carteira ideal para {periodo_label} devido a dados ausentes.")
        dados_com_carteira_ideal[periodo_label] = {"pesos_ideal": pd.DataFrame(), "metricas_ideal": pd.Series(dtype=float)}
        continue

    pesos_ideal, metricas_ideal = otimizar_portfolio_ideal(
        dados["retornos"],
        dados_com_modelos[periodo_label]["capm_sharpe"],
        dados["rf_media"],
        periodo_label,
        OUTPUT_DIR
    )
    dados_com_carteira_ideal[periodo_label] = {"pesos_ideal": pesos_ideal, "metricas_ideal": metricas_ideal}
print("--- FIM DA ETAPA 4.B: CONSTRUÇÃO DA CARTEIRA 'IDEAL' ---")

```

Fonte: Elaboração própria.

Figura 3.11– Construção das Carteiras

```

# --- ETAPA 5: CONSTRUÇÃO DE CARTEIRA EQUILIBRADA (PESOS IGUAIS) ---
def construir_carreira_equilibrada(retornos_df, rf_diaria_media, periodo_label, output_dir):
    print(f"\n--- ETAPA 5: Construindo Carteira de Pesos Iguais para o período: {periodo_label} ---")
    retornos_apanas_acoes = retornos_df.drop(columns=["IBOV"], errors='ignore')
    if retornos_apanas_acoes.empty:
        print(f" Não há ativos para a carteira de pesos iguais no período {periodo_label}.")
        return None, None

    num_ativos = len(retornos_apanas_acoes.columns)
    pesos_iguais = np.array(num_ativos * [1. / num_ativos])
    retornos_medios_diarios_acoes = retornos_apanas_acoes.mean()
    matriz_cov_diaria_acoes = retornos_apanas_acoes.cov()

    ret_eq_d, vol_eq_d, sharpe_eq_d = calcular_performance_portfolio(pesos_iguais, retornos_medios_diarios_acoes, matriz_cov_diaria_acoes, rf_diaria_media)
    ret_eq_a = (1 + ret_eq_d)**252 - 1
    vol_eq_a = vol_eq_d * np.sqrt(252)
    sharpe_eq_a = sharpe_eq_d * np.sqrt(252)

    pesos_eq_df = pd.DataFrame(pesos_iguais, index=retornos_apanas_acoes.columns, columns=["Peso Equilibrado"])
    print(f" Pesos da Carteira Equilibrada para {periodo_label}:")
    print(pesos_eq_df)

    metricas_eq_dict = {
        "Retorno Diário": ret_eq_d, "Volatilidade Diária": vol_eq_d, "Sharpe Diário": sharpe_eq_d,
        "Retorno Anualizado": ret_eq_a, "Volatilidade Anualizada": vol_eq_a, "Sharpe Anualizado": sharpe_eq_a
    }
    metricas_eq_df = pd.Series(metricas_eq_dict, name=f"Portfolio Pesos Iguais {periodo_label}")
    print(f" Métricas da Carteira Equilibrada para {periodo_label}:")
    print(metricas_eq_df)
    path_pesos_eq = os.path.join(output_dir, f"pesos_carreira_equilibrada_{periodo_label.replace('-', '_')}.csv")
    path_metricas_eq = os.path.join(output_dir, f"metricas_carreira_equilibrada_{periodo_label.replace('-', '_')}.csv")
    pesos_eq_df.to_csv(path_pesos_eq)
    metricas_eq_df.to_csv(path_metricas_eq)
    print(f" Salvo: {path_pesos_eq}")
    print(f" Salvo: {path_metricas_eq}")
    return pesos_eq_df, metricas_eq_df

print("\n--- INICIANDO ETAPA 5: CONSTRUÇÃO DE CARTEIRA EQUILIBRADA ---")
dados_com_carreira_eq = {}
for periodo_label, dados in dados_com_retornos.items(): # Usa dados_com_retornos pois precisa dos retornos e rf_media
    if dados["retornos"].empty or pd.isna(dados["rf_media"]):
        print(f"Pulando carteira equilibrada para {periodo_label} devido a dados ausentes.")
        dados_com_carreira_eq[periodo_label] = {"pesos_eq": pd.DataFrame(), "metricas_eq": pd.Series(dtype=float)}
        continue
    pesos_eq, metricas_eq = construir_carreira_equilibrada(dados["retornos"], dados["rf_media"], periodo_label, OUTPUT_DIR)
    dados_com_carreira_eq[periodo_label] = {"pesos_eq": pesos_eq, "metricas_eq": metricas_eq}
print("--- FIM DA ETAPA 5: CONSTRUÇÃO DE CARTEIRA EQUILIBRADA ---")

```

Fonte: Elaboração própria.

Figura 3.12 – Comparação de Performance das Carteiras - Parte 1

```

# --- ETAPA 6: COMPARAÇÃO DE PERFORMANCE DAS CARTEIRAS E IBOVESPA ---
def calcular_var_portfolio(retornos_historicos_ativos, pesos, confianca=0.99):
    """Calcula o VaR histórico de uma carteira com base nos pesos."""
    retornos_portfolio = retornos_historicos_ativos.dot(pesos)
    var_historico = retornos_portfolio.quantile(1 - confianca)
    return var_historico

def comparar_performance_final(periodeo_label, output_dir):
    print(f"\n--- ETAPA 6: Comparando Performance das Carteiras e IBOVESPA para o periodo: {periodeo_label} ---")

    # Define todos os caminhos para os arquivos
    path_metricas_otim = os.path.join(output_dir, f"metricas_portfolio_otimizado_{periodeo_label.replace('-', '_')}.csv")
    path_metricas_ideal = os.path.join(output_dir, f"metricas_portfolio_ideal_{periodeo_label.replace('-', '_')}.csv") # NOVO
    path_metricas_eq = os.path.join(output_dir, f"metricas_carteira_equilibrada_{periodeo_label.replace('-', '_')}.csv")
    path_metricas_basicas = os.path.join(output_dir, f"metricas_basicas_{periodeo_label.replace('-', '_')}.csv")
    path_selic = os.path.join(output_dir, f"selic_diaria_{periodeo_label.replace('-', '_')}.csv")
    path_pesos_otim = os.path.join(output_dir, f"pesos_otimos_markowitz_{periodeo_label.replace('-', '_')}.csv")
    path_pesos_ideal = os.path.join(output_dir, f"pesos_ideal_{periodeo_label.replace('-', '_')}.csv") # NOVO
    path_pesos_eq = os.path.join(output_dir, f"pesos_carteira_equilibrada_{periodeo_label.replace('-', '_')}.csv")
    path_retornos_historicos = os.path.join(output_dir, f"retornos_diarios_{periodeo_label.replace('-', '_')}.csv")

    try:
        # Carrega as métricas de todas as carteiras
        metricas_otim_series = pd.read_csv(path_metricas_otim, index_col=0, header=None).squeeze("columns")
        metricas_otim_series.name = "Carteira Eficiente (Padrão)"

        # CARREGA DADOS DA CARTEIRA IDEAL
        metricas_ideal_series = pd.read_csv(path_metricas_ideal, index_col=0, header=None).squeeze("columns")
        metricas_ideal_series.name = "Carteira Ideal (Filtro Sharpe)"

        metricas_eq_series = pd.read_csv(path_metricas_eq, index_col=0, header=None).squeeze("columns")
        metricas_eq_series.name = "Carteira Equilibrada (1/N)"

        metricas_basicas_df = pd.read_csv(path_metricas_basicas, index_col=0)

        selic_df = pd.read_csv(path_selic, index_col="Data", parse_dates=True)
        rf_diaria_media = selic_df["Preco"].mean()
        rf_anual_media = (1 + rf_diaria_media)**252 - 1

        # Prepara a série de métricas do IBOVESPA
        ret_anual_ibov = metricas_basicas_df.loc["IBOV", "Retorno Anualizado Estimado"]
        vol_anual_ibov = metricas_basicas_df.loc["IBOV", "Volatilidade Anualizada Estimada"]
        sharpe_anual_ibov = (ret_anual_ibov - rf_anual_media) / vol_anual_ibov if vol_anual_ibov != 0 and pd.notnull(vol_anual_ibov) else np.nan
        metricas_ibov_series = pd.Series({"Retorno Anualizado": ret_anual_ibov, "Volatilidade Anualizada": vol_anual_ibov, "Sharpe Anualizado": sharpe_anual_ibov}, name="IBOVESPA")

        # 1. CONCATENA O DATAFRAME PRIMEIRO
        comparacao_df = pd.concat([metricas_otim_series, metricas_ideal_series, metricas_eq_series, metricas_ibov_series], axis=1)

        # 2. CALCULA E ADICIONA O VAR PARA TODAS AS CARTEIRAS
        retornos_df = pd.read_csv(path_retornos_historicos, index_col=0, parse_dates=True)

        # VaR da Carteira Eficiente (Padrão)
        pesos_otim = pd.read_csv(path_pesos_otim, index_col=0).squeeze("columns")
        retornos_acoes_otim = retornos_df[pesos_otim.index] # Garante que estamos usando os ativos certos
        var_otim = calcular_var_portfolio(retornos_acoes_otim, pesos_otim)

        # VaR da Carteira Ideal
        pesos_ideal = pd.read_csv(path_pesos_ideal, index_col=0).squeeze("columns")
        retornos_acoes_ideal = retornos_df[pesos_ideal.index] # Garante que estamos usando os ativos certos
        var_ideal = calcular_var_portfolio(retornos_acoes_ideal, pesos_ideal)

        # VaR da Carteira Equilibrada
        pesos_eq = pd.read_csv(path_pesos_eq, index_col=0).squeeze("columns")
        retornos_acoes_eq = retornos_df[pesos_eq.index]
        var_eq = calcular_var_portfolio(retornos_acoes_eq, pesos_eq)

        var_ibov = retornos_df["IBOV"].quantile(0.01)

        comparacao_df.loc[f"VaR Histórico (99%)"] = [var_otim, var_ideal, var_eq, var_ibov]
    
```

Fonte: Elaboração própria.

Figura 3.13 – Comparação de Performance das Carteiras - Parte 2

```

# Filtra apenas as linhas desejadas na ordem correta
comparacao_df = comparacao_df.loc[["Retorno Anualizado", "Volatilidade Anualizada", "Sharpe Anualizado", "VaR Histórico (99%)"]]

# ---> INÍCIO DO BLOCO DE FORMATAÇÃO CORRIGIDO <---
print(f" Comparativo de Performance Anualizada para {periodo_label}:")

comparacao_df = comparacao_df.apply(pd.to_numeric, errors='coerce')
formatted_df = comparacao_df.copy().astype(object)

for idx in comparacao_df.index:
    for col in comparacao_df.columns:
        value = comparacao_df.loc[idx, col]
        if pd.isna(value):
            # ESTA LINHA PRECISA DE INDENTAÇÃO
            formatted_df.loc[idx, col] = "N/A"
        else:
            # ESTAS LINHAS PRECISAM DE INDENTAÇÃO
            if idx in ["Retorno Anualizado", "Volatilidade Anualizada", "VaR Histórico (99%)"]:
                formatted_df.loc[idx, col] = f'{value:.2%}'
            elif idx == "Sharpe Anualizado":
                formatted_df.loc[idx, col] = f'{value:.4f}'

print(formatted_df)
# ---> FIM DO BLOCO DE FORMATAÇÃO CORRIGIDO <---

path_comparacao = os.path.join(output_dir, f"comparativo_performance_final_{periodo_label.replace('-', '_')}.csv")
formatted_df.to_csv(path_comparacao.replace('.csv', '_formatado.csv'))
comparacao_df.to_csv(path_comparacao)
print(f" Salvo: {path_comparacao} (numérico) e _formatado.csv (para visualização)")

return comparacao_df

except FileNotFoundError as e:
    print(f"ERRO ao comparar performance para {periodo_label}: Um ou mais arquivos de métricas não encontrados. {e}")
    return pd.DataFrame()
except Exception as e:
    print(f"ERRO inesperado ao comparar performance para {periodo_label}: {e}")
    import traceback
    traceback.print_exc()
    return pd.DataFrame()

print("\n--- INICIANDO ETAPA 6: COMPARAÇÃO DE PERFORMANCE FINAL ---")
resultados_comparativos_finais = {}
for periodo_label, _ in PERIODOS_ANALISE.items(): # Usar PERIODOS_ANALISE para iterar
    # Verificar se os dados necessários existem (dos passos anteriores)
    # Esta verificação pode ser mais robusta, checando a existência dos arquivos CSV de entrada para esta etapa
    if periodo_label in dados_com_otimizacao and periodo_label in dados_com_carteira_eq and periodo_label in dados_com_retornos:
        if (dados_com_otimizacao[periodo_label].get("metricas_otimas") is not None and
            dados_com_carteira_eq[periodo_label].get("metricas_eq") is not None and
            dados_com_retornos[periodo_label].get("metricas_basicas") is not None):
            resultados_comparativos_finais[periodo_label] = comparar_performance_final(periodo_label, OUTPUT_DIR)
        else:
            print(f"Dados de métricas ausentes para {periodo_label}. Pulando comparação final.")
            resultados_comparativos_finais[periodo_label] = pd.DataFrame()
    else:
        print(f"Dados de etapas anteriores ausentes para {periodo_label}. Pulando comparação final.")
        resultados_comparativos_finais[periodo_label] = pd.DataFrame()
print("--- FIM DA ETAPA 6: COMPARAÇÃO DE PERFORMANCE FINAL ---")
print("\n\n--- ANÁLISE DE CARTEIRA CONCLUÍDA ---")
print(f"Todos os resultados foram salvos no diretório: {OUTPUT_DIR}")
print("O script 'analise_carteira_completa.py' contém todo o passo a passo executado.")
print("Por favor, verifique os arquivos CSV gerados para os resultados detalhados de cada etapa.")

```

Fonte: Elaboração própria.

Tabela 4.4

Ativo	Peso Ótimo
ABEV3	9,27%
BBAS3	6,04%
BBDC4	11,70%
BBSE3	4,95%
ELET3	1,17%
EMBR3	2,09%
EQTL3	3,19%
GGBR4	2,38%
ITSA4	7,62%
ITUB4	9,09%
JBSS3	2,31%
PETR3	6,23%
PETR4	5,30%
PRI03	1,00%
RADL3	3,64%
RAIL3	2,40%
RENT3	3,85%
SBSP3	2,60%
VALE3	11,47%
WEGE3	3,69%

Tabela 4.5

Ativo	Peso Ótimo
ABEV3	5,00%
BBAS3	5,00%
BBDC4	5,00%
BBSE3	5,00%
ELET3	5,00%
EMBR3	5,00%
EQTL3	5,00%
GGBR4	5,00%
ITSA4	5,00%
ITUB4	5,00%
JBSS3	5,00%
PETR3	5,00%
PETR4	5,00%
PRI03	5,00%
RADL3	5,00%
RAIL3	5,00%
RENT3	5,00%
SBSP3	5,00%
VALE3	5,00%
WEGE3	5,00%

Tabela 4.12

Tabela 4.13

Ativo	Peso Ótimo	Ativo	Peso Ótimo
ABEV3	1,00%	ABEV3	5,00%
BBAS3	1,00%	BBAS3	5,00%
BBDC4	1,00%	BBDC4	5,00%
BBSE3	1,00%	BBSE3	5,00%
ELET3	1,00%	ELET3	5,00%
EMBR3	81,00%	EMBR3	5,00%
EQTL3	1,00%	EQTL3	5,00%
GGBR4	1,00%	GGBR4	5,00%
ITSA4	1,00%	ITSA4	5,00%
ITUB4	1,00%	ITUB4	5,00%
JBSS3	1,00%	JBSS3	5,00%
PETR3	1,00%	PETR3	5,00%
PETR4	1,00%	PETR4	5,00%
PRI03	1,00%	PRI03	5,00%
RADL3	1,00%	RADL3	5,00%
RAIL3	1,00%	RAIL3	5,00%
RENT3	1,00%	RENT3	5,00%
SBSP3	1,00%	SBSP3	5,00%
VALE3	1,00%	VALE3	5,00%
WEGE3	1,00%	WEGE3	5,00%

Tabela 4.14

Ativo	Peso Ótimo
BBAS3	8,60%
BBSE3	40,36%
EMBR3	16,22%
ITSA4	1,00%
ITUB4	1,00%
PETR3	1,00%
PETR4	6,02%
PRI03	6,91%
SBSP3	17,89%
WEGE3	1,00%