



UNIVERSIDADE FERERAL DA PARAÍBA (UFPB)
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS (CCSA)
DEPARTAMENTO DE FINANÇAS E CONTABILIDADE (DFC)
CURSO DE BACHARELADO EM CIÊNCIAS ATUARIAIS (CCA)

ROODNEY DOUGLAS GONÇALVES COUTINHO

ALOCÇÃO DE ATIVOS FINANCEIROS:
UMA ANÁLISE COMPARATIVA ENTRE OS MÉTODOS DE ALOCAÇÃO
TRADICIONAIS E MODELOS DECORRENTES DE INTELIGÊNCIA ARTIFICIAL

JOÃO PESSOA

2025

ROODNEY DOUGLAS GONÇALVES COUTINHO

**ALOCÇÃO DE ATIVOS FINANCEIROS:
UMA ANÁLISE COMPARATIVA ENTRE OS MÉTODOS DE ALOCAÇÃO
TRADICIONAIS E MODELOS DECORRENTES DE INTELIGÊNCIA ARTIFICIAL.**

Trabalho de Conclusão de Curso para o curso de Ciências Atuariais na UFPB, como requisito parcial à obtenção do título de bacharel em Ciências Atuariais.

Área de concentração: Gestão de Risco.

Orientador: Prof. Dr. Filipe Coelho de Lima Duarte.

JOÃO PESSOA

2025

Catálogo na publicação
Seção de Catalogação e Classificação

C871a Coutinho, Roodney Douglas Goncalves.

Alocação de ativos financeiros: uma análise comparativa entre os métodos de alocação tradicionais e modelos decorrentes de inteligência artificial / Roodney Douglas Goncalves Coutinho. - João Pessoa, 2025.

94 f. : il.

Orientação: Filipe Coelho de Lima Duarte.
TCC (Graduação) - UFPB/CCSA.

1. Alocação de portfólio. 2. Teoria da carteira. 3. Inteligência Artificial. 4. Desempenho de carteira de investimento. 5. Volatilidade de carteira de investimento. I. Duarte, Filipe Coelho de Lima. II. Título.

UFPB/CCSA

CDU 368

**ALOCÇÃO DE ATIVOS FINANCEIROS:
UMA ANÁLISE COMPARATIVA ENTRE OS MÉTODOS DE ALOCAÇÃO
TRADICIONAIS E MODELOS DECORRENTES DE INTELIGÊNCIA ARTIFICIAL.**

Trabalho de Conclusão de Curso para o curso
de Ciências Atuariais na UFPB, como requisito
parcial à obtenção do título de bacharel em
Ciências Atuariais.

Aprovado em: 30/04/2025

BANCA EXAMINADORA



Documento assinado digitalmente

FILIPPE COELHO DE LIMA DUARTE

Data: 07/05/2025 21:42:07-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Filipe Coelho de Lima Duarte (Orientador)
Universidade Federal da Paraíba (UFPB)



Documento assinado digitalmente

LUIZ CARLOS SANTOS JUNIOR

Data: 07/05/2025 21:25:16-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Luiz Carlos Santos Junior
Universidade Federal da Paraíba (UFPB)



Documento assinado digitalmente

HERICK CIDARTA GOMES DE OLIVEIRA

Data: 07/05/2025 21:31:06-0300

Verifique em <https://validar.iti.gov.br>

Prof. Dr. Herick Cidarta Gomes de Oliveira
Universidade Federal do Rio Grande do Norte (UFRN)

AGRADECIMENTOS

Agradeço primeiramente a Deus por todas as oportunidades que me concedeu.

A minha esposa por ter me apoiado e ajudado ao longo desses anos.

As minhas filhas que amo tanto, que são minha fonte de força.

Aos meus pais, pelos incentivos e apoio dados nesses anos.

Aos professores da UFPB, por ter passado seus conhecimentos e dedicado seu tempo a me ensinar na formação acadêmica.

E que Deus abençoe a todos.

RESUMO

Este trabalho tem como objetivo comparar o desempenho e o risco de carteiras de investimentos elaboradas por métodos tradicionais e por técnicas de Inteligência Artificial (IA). A metodologia tradicional foi baseada na análise fundamentalista combinada com o modelo de otimização de carteiras de Markowitz, enquanto a abordagem por IA utilizou critérios como liquidez, diversificação setorial e correlação reduzida, além da aplicação de algoritmos para otimização por média-variância. As carteiras foram montadas com dados históricos de 2022 e avaliadas quanto ao desempenho no ano de 2023 por meio de métricas como retorno anualizado, volatilidade, índice de Sharpe, índice de Sortino e *Value at Risk* (VaR). Os resultados mostraram que a carteira tradicional teve maior rentabilidade, porém com maior exposição ao risco. Por outro lado, a carteira de IA apresentou menor retorno, porém com maior resiliência em cenários adversos, reforçando a importância da diversificação e da análise multidimensional proporcionada pela IA. O estudo conclui que a convergência entre métodos tradicionais e de inteligência artificial pode representar uma estratégia promissora para uma gestão de investimentos mais eficiente e adaptativa.

Palavras-chave: Alocação de portfólio, Teoria da Carteira, Inteligência Artificial, Desempenho, Volatilidade.

ABSTRACT

This study aims to compare the performance and risk of investment portfolios prepared using traditional methods and Artificial Intelligence (AI) techniques. The traditional methodology was based on fundamental analysis combined with the Markowitz portfolio optimization model, while the AI approach used criteria such as liquidity, sector diversification, and reduced correlation, in addition to the application of algorithms for mean-variance optimization. The portfolios were assembled using historical data from 2022 and evaluated for performance in 2023 using metrics such as annualized return, volatility, Sharpe ratio, Sortino ratio, and Value at Risk (VaR). The results showed that the traditional portfolio had higher profitability, but with greater exposure to risk. On the other hand, the AI portfolio presented lower returns, but with greater resilience in adverse scenarios, reinforcing the importance of diversification and multidimensional analysis provided by AI. The study concludes that the convergence between traditional and artificial intelligence methods may represent a promising strategy for more efficient and adaptive investment management.

Keywords: Portfolio Allocation, Portfolio Theory, Artificial Intelligence, Performance, Volatility.

LISTA DE FIGURAS

Figura 1 - Fronteira eficiente – Teoria de Markowitz	20
---	----

LISTA DE TABELAS

Tabela 1 – Ações selecionadas para compor a carteira.	39
Tabela 2 – Ações rankeadas pelo <i>factor investing</i>	44
Tabela 3 - Ranking das ações	46
Tabela 4 - Comparação de desempenho da carteira tradicional - 2022 x 2023	62
Tabela 5 - Comparação de desempenho da carteira IA 2022 x 2023	64
Tabela 6 - Comparação de desempenho carteira IA 2022	67
Tabela 7 - Comparativa: Carteira Tradicional vs. Carteira da IA (2023).....	70

LISTA DE QUADROS

Quadro 1 – Métricas de desempenho e comparação dos anos	43
Quadro 2 – Pesos atribuídos pelo método de Markowitz	48
Quadro 3 - Resultados indicadores carteira tradicional 2022	49
Quadro 4 - Ações selecionadas pela inteligência artificial	52
Quadro 5 - Alocação da carteira otimizada pela IA (2022)	53
Quadro 6 – Resultados indicadores carteira da IA 2022	54
Quadro 7 - Desempenho da carteira tradicional em 2023	56
Quadro 8 - Desempenho da carteira da IA em 2023	59
Quadro 9 - Critérios utilizados pelos dois métodos	66

LISTA DE GRÁFICOS

Gráfico 1 - Retorno acumulado da carteira tradicional em 2022.....	50
Gráfico 2 - Volatilidade acumulada.....	51
Gráfico 3 - Retorno acumulado da carteira pela IA em 2022.....	55
Gráfico 4 - Volatilidade da carteira pela IA em 2022	56
Gráfico 5 - Retorno acumulado da carteira tradicional em 2023.....	57
Gráfico 6 - Volatilidade acumulada da carteira tradicional em 2023	58
Gráfico 7 - Retorno acumulado da carteira da IA em 2023.....	60
Gráfico 8 - Volatilidade acumulada da carteira da IA em 2023	61
Gráfico 9 - Retorno acumulado carteira tradicional 2022 x 2023	62
Gráfico 10 - Volatilidade acumulada da carteira tradicioanl 2022 x 2023.....	63
Gráfico 11 - Retorno acumulado carteira IA 2022 x 2023	65
Gráfico 12 - Volatilidade acumula da carteira IA 2022 x 2023	66
Gráfico 13 - Comparação retorno acumulado das carteiras - 2022	68
Gráfico 14 - Comparação da volatilidade acumulada das carteiras – 2022.....	69
Gráfico 15 – Comparativa: Carteira tradicional vs: Carteira da IA (2023)	71
Gráfico 16 - Comparativa: Carteira tradicional vs: Carteira da IA (2023).....	72

SUMÁRIO

1	INTRODUÇÃO	12
1.1	CONTEXTUALIZAÇÃO	12
1.2	OBJETIVOS.....	14
1.2.1	<i>Objetivo Geral.....</i>	<i>14</i>
1.2.2	<i>Objetivos Específicos.....</i>	<i>14</i>
1.2.3	<i>Justificativa.....</i>	<i>15</i>
2	FUNDAMENTAÇÃO TEÓRICA.....	17
2.1	ANÁLISE DE INVESTIMENTOS FINANCEIROS	17
2.2	MONTAGEM DE CARTEIRAS	18
2.2.1	<i>Teoria moderna das carteiras</i>	<i>18</i>
2.2.2	<i>Factor Investing.....</i>	<i>22</i>
2.2.3	<i>A inteligência artificial.....</i>	<i>25</i>
2.3	MEDIDAS DE DESEMPENHO E DE RISCO NA GESTÃO DE RISCO DE CARTEIRAS	28
2.3.1	<i>Método do Value at Risk (VaR)</i>	<i>30</i>
2.3.2	<i>Índice de Sharpe.....</i>	<i>31</i>
2.3.3	<i>Índice de Sortino.....</i>	<i>32</i>
2.3.4	<i>Retorno acumulado</i>	<i>33</i>
2.3.5	<i>Volatilidade acumulada.....</i>	<i>33</i>
2.4	ESTUDOS CORRELATOS	34
3	METODOLOGIA	37
3.1	TIPOS DE PESQUISA	37
3.2	COLETA DE DADOS	37
3.3	SELEÇÃO DE ATIVOS E MONTAGEM DAS CARTEIRAS	39
3.4	TIPOS DE ANÁLISE	41
3.4.1	<i>Aplicação dos métodos tradicionais na gestão de carteiras</i>	<i>41</i>
3.4.2	<i>Aplicação da IA Generativa</i>	<i>42</i>
4	RESULTADOS.....	44
4.1	CRIAÇÃO E ANÁLISE DE DESEMPENHO DAS CARTEIRAS	44
4.1.1	<i>Método tradicional desempenho em 2022</i>	<i>44</i>
4.1.2	<i>Inteligência artificial desempenho em 2022.....</i>	<i>51</i>
4.1.3	<i>Método tradicional, referente a 2023.....</i>	<i>56</i>

4.1.4	<i>Inteligência artificial, referente a 2023</i>	59
4.2	COMPARAÇÃO DO DESEMPENHO DAS CARTEIRAS	61
4.2.1	<i>Comparação do desempenho entre carteiras do método tradicional nos anos de 2022 e 2023</i>	61
4.2.2	<i>Comparação do desempenho entre as carteiras geradas pela inteligência artificial nos anos de 2022 e 2023</i>	64
4.2.3	<i>Comparação do desempenho entre as carteiras geradas pelo método tradicional e gerada pela IA</i>	66
4.3	CONSIDERAÇÕES SOBRE OS RESULTADOS	73
5	CONSIDERAÇÕES FINAIS	75
6	REFERÊNCIAS	77
	APÊNDICE A – SCRIPT DA METODOLOGIA TRADICIONAL	86
	APÊNDICE B – PROMPT DA INTELIGÊNCIA ARTIFICIAL	92

1 INTRODUÇÃO

Nesse capítulo será apresentado uma visão abrangente sobre o cenário dos investimentos, destacando os principais fatores que influenciam as decisões financeiras, como as flutuações do mercado, as políticas econômicas e avanços tecnológicos. Além disso, explora-se a importância da diversificação de carteiras, as estratégias de gestão de risco e a relevância da análise fundamentalista na avaliação de ativos financeiros, além do papel crescente da inteligência artificial na tomada de decisões de investimentos, evidenciando como a tecnologia pode aprimorar a análise de dados e a previsibilidade de riscos, contribuindo para uma gestão mais eficiente e informada.

1.1 CONTEXTUALIZAÇÃO

Investir é uma atividade que requer uma análise abrangente e aprofundada das estratégias de investimento e objetivos financeiros. No mundo dos investimentos, a complexidade e o dinamismo são evidentes, uma vez que uma infinidade de fatores influencia diretamente as decisões financeiras. Tais fatores podem incluir as flutuações do mercado, as mudanças nas condições econômicas, as políticas governamentais, os avanços tecnológicos e os eventos imprevistos (ABDUL KAREEM *et al.*, 2023).

Entre esses elementos, destaca-se a influência da política econômica e institucional, que exerce papel determinante sobre o comportamento dos mercados financeiros. Decisões políticas relacionadas à tributação, regulação, taxa de juros, gastos públicos e estabilidade institucional impactam diretamente o ambiente de negócios e, consequentemente, a atratividade de investimentos. Além disso, períodos de instabilidade política tendem a elevar a incerteza, reduzindo o apetite ao risco por parte dos investidores e afetando negativamente os fluxos de capital e o desempenho das carteiras (VIANA, 2021)

Uma carteira de investimentos bem diversificada é essencial para a mitigação de riscos e a busca por retornos consistentes a longo prazo. Ao distribuir os investimentos por uma variedade de classes de ativos, tais como ações, obrigações, imobiliário e mercadorias, os investidores podem minimizar o impacto dos ativos individuais, de modo a melhorar o risco e o retorno (ZHU *et al.*, 2022). A teoria da carteira desenvolvida por Markowitz (1952) fundamenta essa estratégia, investir em muitos ativos que não são muito correlacionados,

reduzindo o risco da carteira e permitindo identificar um equilíbrio ótimo da carteira entre risco e retorno.

Nessa perspectiva, Markowitz (1999) revolucionou a análise de carteiras de investimentos ao demonstrar que o retorno esperado de uma carteira não é simplesmente a média dos retornos esperados dos ativos individuais que a compõem. O modelo de Markowitz prevê que o retorno esperado de uma carteira é uma função da alocação de ativos na carteira, e que é possível obter combinações de ativos que oferecem um retorno esperado maior do que o retorno esperado de qualquer ativo individual, desde que os ativos estejam correlacionados negativamente (ZANINI; FIGUEIREDO, 2005).

A diversificação pode assumir muitas formas, incluindo a diversificação entre e dentro das classes de ativos com base em fatores como a idade do investidor e a maturidade de um fundo de pensões. Diante de constante transformação do ambiente econômico e financeiro, torna-se imprescindível ressaltar a importância de previsões de risco precisas para a tomada de decisões estratégicas (REHMAN et al., 2018).

Por meio da atualização constante do portfólio de ativos, é possível maximizar as oportunidades de obter rendimentos favoráveis, independentemente das flutuações e incertezas do mercado (TA; LIU; TADESSE, 2020). Manter um olhar vigilante sobre os investimentos e adaptar-se às mudanças de cenário pode fazer a diferença entre o sucesso e o fracasso no mundo dos investimentos (TA; LIU; TADESSE, 2020). Aqueles que são diligentes em suas análises financeiras e tomam decisões informadas têm maior probabilidade de otimizar seus retornos, minimizando os efeitos adversos de eventos imprevistos e incertezas econômicas (SOUZA; SANTOS; ANDRADE, 2017). Estratégias como alocação de ativos, análise de volatilidade e consideração de fatores macoeconômicos são fundamentais para mitigar riscos e proteger o capital investido (LORD, 2020).

Uma abordagem amplamente utilizada para avaliar o valor intrínseco de ativos financeiros é a análise fundamentalista. Essa análise concentra-se em examinar os fundamentos subjacentes de um ativo, que incluem a avaliação financeira de uma empresa, as demonstrações financeiras, a governança corporativa e outros fatores que podem afetar o desempenho financeiro (SEGAL, 2023). Investidores de longo prazo frequentemente recorrem a esta análise para tomar decisões de investimento baseadas em projeções de crescimento e avaliações de valor. Outra abordagem é a análise de fatores de risco, que é particularmente relevante para investidores que buscam uma forma de investimento ativa e sistemática. Essa estratégia tem se destacado por sua capacidade de gerar retornos sólidos e por ajudar a proteger o capital durante diferentes condições de mercado (GRUBER; BROWN; GOETZMANN, 2012). Esses fatores

são identificados como tendo uma influência significativa sobre o desempenho dos ativos, independentemente do setor ou estilo da empresa emissora.

Na atualidade, se fala muito sobre a Inteligência Artificial (IA) e como o uso dela pode ajudar a ter uma percepção melhor de análise e avaliação na tomada de decisão na gestão de risco em investimentos. A utilização da IA é valiosa para identificar padrões por meio de classificação de dados, especialmente em contextos em que a capacidade humana de classificar ativos é limitada pela complexidade ou pelo volume de informações (PAVÃO, 2024). Isso pode resultar na perda de oportunidades ideais de investimento. A inteligência artificial está se tornando cada vez mais integrada em nossa vida cotidiana, ajudando a lidar com tarefas complexas e, em muitos casos, até mesmo realizando essas tarefas de forma autônoma (PAVÃO, 2024).

Essa capacidade de processamento de dados permite a identificação de padrões e a obtenção de insights valiosos que podem ser aplicados na tomada de decisões de investimento. Essa abordagem orientada por dados complementares as estratégias de investimento tradicionais e, ao fazê-lo, introduz novas oportunidades para maximizar retornos e gerenciar riscos de forma ainda mais eficaz (MATHEUS, 2024).

Portanto, o problema de pesquisa é: De que maneira o desempenho financeiro e o risco de carteiras de investimentos elaboradas com o uso de técnicas de Inteligência Artificial, se comparam a aquelas carteiras baseadas por meio de métodos tradicionais?

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Analisar e comparar o desempenho de carteiras de investimentos alocadas com base em técnicas tradicionais e de Inteligência Artificial, considerando seus níveis de rentabilidade e risco.

1.2.2 Objetivos Específicos

- Elencar as principais técnicas tradicionais e de Inteligência Artificial (IA) utilizadas no processo de alocação de carteiras de investimentos;

- Realizar alocação de portfólio utilizando técnicas tradicionais e de Inteligência Artificial;
- Comparar as carteiras de investimentos alocadas, a partir de técnicas tradicionais e de Inteligência Artificial.

1.2.3 Justificativa

A inteligência artificial tem demonstrado grande potencial no setor financeiro, especialmente na previsão de riscos de investimentos. Com os avanços em aprendizado de máquina e processamento de dados, sua aplicação na gestão de risco pode proporcionar maior eficiência, precisão e adaptação às constantes mudanças do mercado (BOREIKO; MASSAROTTI, 2020). E estudos indicam que a adoção de Inteligência Artificial pode aumentar a eficiência operacional em até 40%, reduzir custos e melhorar a precisão na análise de dados financeiros (YTecnologia, 2023).

No Brasil, uma pesquisa da PwC (PricewaterhouseCoopers) (2023) revelou que 74% dos líderes do setor de serviços financeiros acreditam que a IA generativa melhorará a qualidade dos produtos ou serviços das empresas nos próximos 12 meses. Além disso, 71% esperam um aumento na lucratividade com a implementação da tecnologia (ABE, 2025).

Em comparação, os métodos tradicionais de análise financeira, como os modelos de séries temporais como ARIMA e GARCH, apresentam limitações ao lidar com a crescente complexidade, não linearidade e volatilidade dos mercados contemporâneos (QIAN, 2017). Por outro lado, as técnicas baseadas em aprendizado de máquina, como redes neurais artificiais e algoritmos de ensemble, têm se destacado por sua capacidade de modelar padrões complexos e não lineares, oferecendo maior acurácia na previsão de variáveis financeiras e superando, em diversos estudos empíricos, os modelos estatísticos convencionais (QIAN, 2017).

Nesse contexto, a inteligência artificial se destaca como uma ferramenta estratégica na identificação e quantificação de riscos, possibilitando decisões mais embasadas e estratégias de investimento mais robustas. Sua capacidade de processar grandes volumes de dados e detectar padrões ocultos contribui significativamente para a mitigação de incertezas e para uma maior adaptabilidade diante de fatores econômicos e políticos em constante transformação (CHOPRA; SHARMA, 2021).

Este estudo busca analisar o impacto da IA sobre a previsão de riscos, fornecendo *insights* sobre seus benefícios, limitações e aplicações no mercado financeiro. A pesquisa

pretende contribuir para o avanço do conhecimento na área, oferecendo recomendações práticas para profissionais, acadêmicos e tomadores de decisão.

2 FUNDAMENTAÇÃO TEÓRICA

Esse capítulo oferece uma visão abrangente da gestão de risco em carteiras de investimentos, fundamental para proteger o capital investido e otimizar os retornos financeiros. Apresentam-se conceitos abordando investimentos financeiros, gestão de risco de carteiras de investimentos formação de carteiras com métodos tradicionais e abordagens com inteligência artificial, com o objetivo de otimizar os retornos financeiros e de reduzir a exposição a riscos no cenário financeiro.

2.1 ANÁLISE DE INVESTIMENTOS FINANCEIROS

Uma análise prévia de investimentos desempenha um papel fundamental na otimização da alocação de recursos financeiros. Nos desafios da atualidade, é essencial possuir profundo entendimento das metodologias específicas de investimentos, pois permite uma análise criteriosa sobre o risco e o retorno esperado e uma avaliação precisa de desempenho sobre seus ativos (LORD, 2020).

A análise é essencial para a tomada de decisões de investimentos e ajudam a compreender o risco potencial de retorno e alocação eficaz de recursos, bem como o desempenho dos investimentos individuais dentro de uma carteira (LORD, 2020). Na etapa de tomada de decisão, é fundamental a escolha do tipo de análise, sendo utilizadas duas abordagens principais a análise fundamentalista e o investimento em fatores de risco.

Métodos tradicionais de gestão de investimentos utilizam o modelo fundamentalista, que se concentra em avaliar ativos com base em critérios fundamentais, como as demonstrações financeiras, os indicadores econômicos e a análise do setor. Este método tradicional muitas vezes requer um profundo conhecimento do negócio e da economia e os gestores de investimentos utilizam análises qualitativas e quantitativas para tomar decisões (SEGAL, 2023). A diversificação de portfólio e a análise técnica também são abordagens comuns nos métodos tradicionais.

Por outro lado, os métodos que utilizam a inteligência artificial, representam uma abordagem mais contemporânea na gestão de riscos e investimentos. A IA utiliza algoritmos e modelos matemáticos para analisar grandes volumes de dados financeiros e identificar padrões e correlações, muitas vezes difíceis de serem percebidos por análises tradicionais (MA; HAN; WANG, 2021). O aprendizado de máquina permite que os sistemas aprendam com dados

passados e aprimorem continuamente suas capacidades de previsão, resultando em uma tomada de decisão mais automatizada e orientada por dados (AHMED et al., 2022). Essa abordagem é bastante eficaz na detecção de oportunidades de investimentos e na gestão proativa de riscos em tempo real (PESSANHA; VIEIRA; BRANDÃO, 2024).

2.2 MONTAGEM DE CARTEIRAS

A análise fundamentalista é utilizada para avaliar o valor intrínseco de um ativo financeiro com base na análise de uma ampla gama de fatores econômicos e financeiros que afetam a empresa emissora e as condições do mercado. O valor intrínseco representa o valor subjacente de um investimento determinado pela situação financeira da empresa e pelas condições econômicas e de mercado atuais (SEGAL, 2023).

O investimento em fatores ou *factor investing*, por sua vez, envolve uma estratégia de identificar e investir em ativos que exibem características específicas, como o valor, o tamanho, o momento ou a baixa volatilidade. A premissa é que esses fatores estão associados a retornos superiores à média do mercado, independentemente do setor ou modelo de negócio da empresa (GRUBER; BROWN; GOETZMANN, 2012). Por exemplo, ações de empresas com valor, isto é, aquelas que são negociadas a preços inferiores ao seu valor intrínseco, geram retornos acima da média do mercado (GRUBER; BROWN; GOETZMANN, 2012). Os investidores que adotam essa abordagem acreditam que podem identificar fatores que estão subavaliados pelo mercado e, portanto, oferecem o potencial de retornos superiores (ANG, 2013).

Assim, tendo uma compreensão básica dos princípios da análise de investimentos, pode-se tomar decisões mais informadas e aumentar a chance de sucesso sobre os investimentos.

2.2.1 Teoria moderna das carteiras

A Teoria Moderna das carteiras é uma estrutura financeira que ajuda os investidores a otimizar suas carteiras de investimentos considerando a relação entre risco e retorno. Segundo essa teoria, ao estabelecer uma fronteira eficiente de carteiras ótimas, é possível alcançar o retorno esperado em um determinado nível de risco (MWANGI; IRUNGU; MUTWIRI, 2022). Esta teoria foi proposta por Harry Markowitz em 1952 e desde então se tornou referência em gestão de carteiras. A Teoria Moderna das carteiras de Markowitz começa assumindo que os investidores são avessos ao risco, o que significa que preferem investimentos menos arriscados

(MWANGI; IRUNGU; MUTWIRI, 2022). Para construir um portfólio otimizado, a metodologia envolve várias etapas principais:

1. A definição do universo de ativos disponíveis: esta etapa envolve a identificação das diversas classes de ativos que um investidor pode potencialmente incluir em sua carteira, como ações, títulos, *commodities* e imóveis.

2. A avaliação de ativos individuais: Nesta etapa são avaliados o retorno esperado e o nível de risco (desvio padrão) de cada ativo.

3. Distribuição de pesos: Os pesos dos ativos desempenham um papel crucial na construção de portfólios eficientes. Esses pesos representam a proporção do capital total investido em cada ativo da carteira e são fundamentais para determinar tanto o retorno esperado quanto o risco do portfólio .


4. O cálculo do retorno esperado e da variância do portfólio: Nesta etapa, calcula-se o retorno esperado do portfólio como uma média ponderada dos retornos esperados dos ativos, sendo os pesos determinados pela proporção de cada ativo na carteira. Da mesma forma, a variância do portfólio, que representa o risco, é calculada considerando não apenas os riscos individuais dos ativos, mas também a correlação entre eles, ponderada pelos pesos atribuídos a cada par de ativos. Essa abordagem permite entender como a diversificação afeta o risco total e é essencial para a construção da fronteira eficiente.

5. A aplicação da Teoria Moderna do Portfólio: Uma vez calculado o retorno esperado e a variância do portfólio, o investidor pode traçar diferentes combinações de ativos em uma relação risco-retorno denominado fronteira eficiente.

A Figura 1 demonstra um exemplo da fronteira eficiente da teoria de Markowitz.

A fronteira eficiente é composta por carteiras que oferecem o melhor retorno possível para um dado nível de risco, ou, de forma equivalente, o menor risco possível para um dado nível de retorno. No eixo horizontal está representado o risco da carteira, medido pelo desvio padrão dos retornos. No eixo vertical, observa-se o retorno esperado da carteira, estimado com base nas médias ponderadas dos ativos.

Figura 1 - Fronteira eficiente – Teoria de Markowitz



Fonte: ASSAF NETO (2014).

Conforme a curva demonstra, à medida que o risco aumenta, também é possível alcançar retornos mais elevados, evidenciando a clássica relação risco-retorno. As carteiras que se encontram abaixo da curva são consideradas ineficientes, pois há outras combinações que oferecem maior retorno para o mesmo risco. Já as carteiras localizadas sobre a curva são ótimas do ponto de vista da eficiência de Markowitz. Ao analisar a fronteira eficiente, o investidor pode determinar a alocação ótima da carteira que maximiza o retorno para um determinado nível de risco ou minimiza o risco para um determinado nível de retorno (MWANGI; IRUNGU; MUTWIRI, 2022).

O método de Markovitz é uma abordagem financeira que se vale da teoria das probabilidades para encontrar a combinação ideal de ativos em uma carteira de investimentos (ZANINI; FRANCISCO; FIGUEIREDO, 2005). Essa técnica parte do princípio de que o potencial retorno de um investimento está relacionado ao nível de risco associado a ele. Partindo dessas premissas, Markowitz (1952) determina duas características fundamentais de uma carteira: o retorno esperado e a variância. A primeira característica se dá pelo retorno esperado, que é a média ponderada dos retornos, dada pela equação (1):

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

Onde:

R_p = é o retorno esperado da carteira;

X_i = é o peso da carteira;

$E(R_i)$ = é o retorno esperado do ativo;

n = número de ativos na carteira.

A segunda característica do método é o risco, medido pela variância, conforme a expressão (2):

$$Var(R_p) = \sum_{i=1}^N \sum_{j=1}^N W_i \times W_j \times P_{ij} \times \delta_i \times \delta_j \quad (2)$$

Onde:

$Var(R_p)$ = é a variância da carteira;

W_i e w_j = são os pesos dos ativos j e k na carteira;

p_{ij} = é a correlação entre os ativos de i e j ;

δ_i e δ_j = são os desvios padrão dos retornos dos ativos i e j .

A expressão (2) evidencia um dos aspectos mais importantes da Teoria Moderna das Carteiras, a correlação entre os ativos. A correlação (p_{ij}) mede o grau de associação linear entre os retornos de dois ativos e varia entre -1 e +1.

Quando dois ativos têm correlação positiva alta, tendem a se mover na mesma direção, o que limita os benefícios da diversificação. Por outro lado, quando possuem correlação negativa ou baixa, a combinação dos dois pode reduzir a variabilidade dos retornos totais da carteira (ZANINI; FIGUEIREDO, 2005).

Essa característica é fundamental para o princípio da diversificação eficiente, pois é a correlação entre os ativos que determina o risco total do portfólio. Ao combinar ativos com baixa ou negativa correlação, é possível construir carteiras que mantêm um nível desejado de retorno, mas com menor risco agregado, uma vez que as flutuações de um ativo tendem a ser compensadas pelas de outro (ZANINI; FIGUEIREDO, 2005). Portanto, a correlação é uma variável crítica no processo de alocação de ativos e um elemento central na construção da fronteira eficiente, sendo amplamente utilizada por gestores de portfólio para otimizar a relação risco-retorno das carteiras.

Dessa forma, a integração entre o retorno esperado, a variância dos ativos e a correlação entre eles proporciona uma estrutura analítica robusta e fundamentada para a construção de carteiras de investimento eficientes, permitindo decisões mais racionais quanto à alocação de ativos sob diferentes níveis de risco e retorno esperados.

2.2.2 Factor Investing

O *factor investing* se baseia na ideia de que determinados fatores sistemáticos explicam os retornos esperados das ações. Diferente da abordagem tradicional de alocação de ativos, que organiza os investimentos por classes como ações, títulos e *commodities*, essa estratégia busca capturar prêmios associados a fatores como tamanho, valor, *momentum*, qualidade e baixa volatilidade (BLITZ; VIDOJEVIC, 2019).

O fator tamanho sugere que ações de empresas de menor capitalização tendem a superar as de grande capitalização no longo prazo. Essa superioridade é geralmente medida em termos de retorno ajustado ao risco, conforme evidenciado por estudos de Fama e French, (1992), que demonstram que empresas com menor capitalização, apresentam retornos superiores, mesmo quando controladas pelo risco do mercado. A métrica tradicional para esse fator é o valor de mercado da empresa, dada pela expressão (3).

$$MCAP = P \times N \quad (3)$$

Onde:

$MCAP$ = fator tamanho;

P = preço da ação.;

N = números de ações emitidas.

O fator valor se baseia na ideia de que ações negociadas a múltiplos baixos, como alto *book-to-market* (razão entre valor contábil e valor de mercado), tendem a superar ações mais caras ao longo do tempo. Esse efeito é observado em métricas como o retorno superior das ações de valor em relação às de crescimento, conforme demonstrado por Lakonishok, Shleifer e Vishny (1994). Na prática, o fator valor é comumente relacionado por indicadores como o P/L (Preço sobre Lucro) e o P/VPA (Preço sobre Valor Patrimonial por Ação). Quando menores esses múltiplos, maior é o valor relativo da ação, ou seja, maior o desconto em relação aos fundamentos de uma empresa (LAKONISHOK; SHLEIFER; VISHNY, 1994).

O fator *Momentum* reflete a tendência de que ações com retornos positivos recentes tendem a continuar subindo, enquanto ações com retornos negativos recentes continuam caindo. O *momentum* é tipicamente medido pelo retorno acumulado em períodos de 3 a 12 meses, conforme definido por Jegadeesh e Titman (1993), e é amplamente utilizado em estratégias quantitativas.

A qualidade é um fator baseado em métricas financeiras, como alta lucratividade, baixo endividamento e eficiência operacional. Estudos como Asness, Frazzini e Pedersen (2013) mostram que empresas com alto retorno sobre o patrimônio (ROE), margens e baixa alavancagem tendem a apresentar retornos ajustados ao risco superiores.

A baixa volatilidade sugere que maior risco deve gerar maior retorno, o fator de baixa volatilidade demonstra que ações com menor oscilação tendem a ter um desempenho ajustado ao risco superior. Esse fenômeno é descrito em estudos como Baker e Haugen (2012), que demonstram que ações de baixa volatilidade apresentam índice de Sharpe superiores em relação às ações mais voláteis.

Esses fatores são amplamente utilizados em modelos de precificação de ativos e na construção de portfólios, sendo aplicados tanto individualmente quanto em estratégias multifatoriais que combinam diferentes características para otimizar os retornos ajustados ao risco. Para calcular os investimentos em fatores, utiliza-se a expressão (4):

$$E(R_c) = E(R_m) + \beta \cdot (E(F) - E(R_m)) \quad (4)$$

Onde:

$E(R_c)$ = é o retorno esperado da carteira de investimentos;

$E(R_m)$ = é o retorno esperado do mercado;

β = é o beta da carteira de investimentos;

$E(F)$ = é o retorno esperado do fator de investimento.

Além dos fatores, é comum a atribuição de pesos específicos a cada fator, refletindo sua importância relativa na composição do portfólio. Esses pesos podem ser definidos de forma igualitária ou por meio de abordagens quantitativas, como regressões multifatoriais ou otimização por média-variância. Em estratégias multifatoriais, cada fator recebe um escore padronizado com base em sua métrica específica (como P/L, ROE ou retorno de 12 meses), e os escores finais das ações são calculados por meio da média ponderada desses escores

individuais. Assim, ações com maiores escores compostos são priorizadas na seleção do portfólio. Essa abordagem permite integrar múltiplos sinais em um único modelo de decisão, promovendo maior robustez e diversificação no processo de investimento (CLARKE; DE SILVA; THORLEY, 2006)

Na prática, a construção de uma carteira multifatorial envolve a normalização das métricas financeiras, o ranqueamento das ações dentro de cada fator e, posteriormente, a combinação desses rankings ponderados. Neste estudo, foi utilizado o seguinte modelo de score final para seleção das ações, dado pela expressão (5):

$$Score\ Final_i = P \times R_{Valor,i} + P \times R_{Qualidade,i} + P \times R_{Momentum,i} \quad (5)$$

Onde:

$Score\ Final_i$ = é o score final da ação;

P = é o peso de cada ação;

$R_{Momentum,i}$ = é o ranking do retorno acumulado;

$R_{Qualidade,i}$ = é o ranking do ROE;

$R_{Valor,i}$ = é a média do ranking da ação i para os múltiplos P/L e P/VPA.

O $R_{Valor,i}$ é dada pela expressão (6):

$$R_{Valor,i} = \frac{\frac{Rank\ P}{L_i} + \frac{Rank\ P}{VPA_i}}{2} \quad (6)$$

Essa estrutura permite a criação de um *score final* que prioriza ações com múltiplos baixos (valor), alta rentabilidade (qualidade) e desempenho recente positivo (momentum), permitindo uma seleção sistemática e objetiva dos ativos com maior potencial de retorno ajustado ao risco.

É importante observar que o *factor investing* é uma estratégia de investimento de longo prazo, que costuma ser definido por investimentos com período superior a 5 anos, pois é nesse horizonte que fatores de investimentos tendem a se manifestar de maneira mais consistente, conforme estudo de Fama e French, (1992). E curto prazo que geralmente caracterizado por períodos de 12 meses, nos quais o desempenho das estratégias baseadas em fatores pode ser mais volátil e influenciado por choques temporários no mercado, mudanças no sentimento dos investidores e eventos macroeconômicos. Estudos como Lo e Craig (1999) demonstram que, em

horizontes de curto prazo, os retornos do mercado podem ser fortemente impactados por movimentos aleatórios e ineficiências temporárias, tornando mais difícil capturar os prêmios esperados de fatores de forma consistente.

Dessa forma, os investidores que adotam a abordagem de *factor investing* devem ter um horizonte de investimento mais estendido, pois a efetividade da estratégia depende da persistência dos fatores ao longo do tempo. Diversos estudos empíricos demonstram que, apesar das flutuações no curto prazo, os fatores tendem a apresentar retornos ajustados ao risco positivos quando analisados em períodos mais longos (ABDUL KAREEM et al., 2023).

2.2.3 A inteligência artificial

A inteligência artificial (IA) tem evoluído significativamente ao longo das últimas décadas, impulsionando inovações em diversas áreas, desde a automação industrial até a análise preditiva de dados. Segundo Russell e Norving (2020), a IA pode ser definida como o estudo de agentes inteligentes capazes de perceber o ambiente e tomar decisões para atingir determinados objetivos. Seu desenvolvimento tem passado por diversas fases, desde os primeiros sistemas baseados em regras até os atuais modelos de aprendizado profundo, que utilizam grandes volumes de dados para aprimorar sua capacidade de raciocínio e tomada de decisão.

A evolução da IA pode ser dividida em diferentes ondas. A primeira, na década de 1950, era centrada na chamada IA simbólica, baseada em regras lógicas e raciocínio dedutivo. Essa abordagem tentou simular o raciocínio humano por meio de algoritmos que seguiam estruturas “se-então”. Embora eficiente para tarefas bem definidas, a IA simbólica mostrou-se limitada diante da complexidade e ambiguidade do mundo real. A segunda onda, que ganhou força nos anos 1980 e 1990, foi dominada pela IA conexionista, baseada em redes neurais artificiais, que procuram replicar o funcionamento do cérebro humano. Com o avanço do poder computacional e a disponibilidade de grandes volumes de dados, surgiram os modelos de aprendizado profundo (deep learning), que impulsionaram a atual era da IA (RUSSELL; NORVIG, 2020).

Nos anos 2000, observou-se a ascensão de abordagens baseadas em aprendizado de máquina (machine learning), com técnicas como árvores de decisão, florestas aleatórias, máquinas de vetor de suporte (SVM) e k-vizinhos mais próximos (KNN). Essas técnicas permitiram a modelagem de relações complexas entre variáveis, e passaram a ser amplamente utilizadas em áreas como detecção de fraudes, classificação de risco de crédito e previsão de preços de ativos (CLARKE; DE SILVA; THORLEY, 2006). Mais recentemente, a IA entrou

em uma nova fase com o avanço dos modelos generativos e de linguagem, como os Large Language Models (LLMs), capazes de compreender e gerar texto com alto grau de coerência e contextualização (ALIPOUR; PENDAR; ROY, 2024).

Na atualidade, podemos classificar os tipos de IA em diferentes categorias com base em sua abordagem e funcionalidade:

1. IA simbólica (ou baseada em regras) – Utiliza lógica formal para representar conhecimento e tomar decisões. Embora poderosa para tarefas estruturadas, é limitada em ambientes incertos e com dados ambíguos (RUSSELL; NORVIG, 2020).
2. IA conexionista – Inclui redes neurais artificiais, que processam dados por meio de camadas de neurônios interconectados. É a base do aprendizado profundo (deep learning), usado em reconhecimento de voz, imagem e linguagem (SINGH, 2022).
3. IA evolutiva – Baseada em algoritmos genéticos e evolução computacional, busca soluções ótimas por meio de processos inspirados na seleção natural (HOLLAND, 1992).
4. IA híbrida – Combina duas ou mais abordagens, como redes neurais com regras simbólicas ou lógica fuzzy com aprendizado supervisionado, buscando aproveitar o melhor de cada paradigma (KHURANA et al., 2023).
5. IA fraca vs. IA forte – A IA fraca é projetada para tarefas específicas (como prever o preço de uma ação), enquanto a IA forte seria capaz de realizar qualquer tarefa cognitiva humana, algo ainda hipotético (GLOVER, 2024).

Dentre as principais técnicas de aprendizado de máquina aplicadas no mercado financeiro, destacam-se:

1. Redes neurais profundas (DNNs): excelentes para detectar padrões complexos e não lineares em grandes volumes de dados financeiros. O uso de deep learning para previsão de séries temporais financeiras destaca modelos como LSTM e CNN como ferramentas promissoras para previsão de preços de ativos e volatilidade (SEZER; GUDELEK; OZBAYOGLU, 2019).
2. Árvores de decisão e Florestas Aleatórias: úteis para classificação de crédito e seleção de ativos. Esses modelos são amplamente utilizados para avaliar o risco de crédito e auxiliar na tomada de decisões de investimento, devido à sua capacidade de lidar com

dados categóricos e contínuos, além de fornecer interpretações claras dos critérios de decisão (AUGUSTO, 2020).

3. Máquinas de vetores de suporte (SVMs): SVMs são eficazes na separação de classes de ativos ou estados de mercado (KIM, 2003).
4. Aprendizado por reforço O aprendizado por reforço tem sido utilizado na alocação dinâmica de portfólios. Modelos como Deep Reinforcement Learning (DRL) demonstraram desempenho superior em comparação com abordagens tradicionais de alocação de ativos, adaptando-se a diferentes condições de mercado (ALONSO; SRIVASTAVA, 2020)
5. Modelos generativos (LLMs e GANs): LLMs e GANs, são úteis na criação de cenários simulados de mercado, análise de sentimento e geração de insights. Estudos recentes destacam o uso de GANs para gerar dados sintéticos de séries temporais financeiras e a aplicação de LLMs, como FinGPT, para análise de sentimentos em textos financeiros (LEE *et al.*, 2024).

Dentro desse avanço, os *Large Language Models* (LLMs) emergiram como uma das inovações mais impactantes, redefinindo a interação entre humanos e máquinas. Esses modelos representam um marco fundamental na IA, permitindo a criação de conteúdos sofisticados e versáteis, com aplicações que vão desde a comunicação automatizada até a síntese de informações complexas (JIANG *et al.*, 2024). Esses modelos, treinados em vastos conjuntos de dados textuais, demonstram uma notável capacidade de gerar textos coerentes e contextualmente relevantes. Eles conseguem captar com maior precisão as nuances e complexidades da linguagem humana, permitindo uma interação mais natural e sofisticada entre usuários e máquinas (ALIPOUR; PENDAR; ROY, 2024).

Segundo Deng *et al.* (2022), a utilização de LLMs em tarefas como análise de mercado tem mostrado resultados bastante promissores, com esses modelos conseguindo capturar padrões e tendências que seriam difíceis de identificar manualmente. Além disso, a personalização das recomendações de investimentos tem se beneficiado significativamente da capacidade dos LLMs de adaptar as respostas de acordo com as preferências e perfis dos investidores (DOLPHIN *et al.*, 2024). Sinha, Agarwal e Malo (2025) destacam que a automação no setor financeiro, impulsionada pelos LLMs, não apenas melhora a velocidade de execução das transações, mas também proporciona um atendimento ao cliente mais ágil e assertivo, com recomendações baseadas em análise profunda de dados.

No entanto, essa evolução também apresenta desafios críticos que não podem ser negligenciados. Um dos principais riscos está na interpretação equivocada dos dados. Uma vez que os LLMs, podem gerar respostas plausíveis e convincentes, mas, ao mesmo tempo, podem produzir respostas incorretas ou imprecisas (FERREIRA, 2024). Esse fenômeno é conhecido como o "efeito de alucinação de modelos", onde os LLMs podem gerar respostas que, embora pareçam corretas em termos de fluência e estrutura, carecem da precisão e profundidade necessárias para decisões financeiras adequadas (FARNESCHLÄDER, 2025). Um exemplo disso seria o uso de um LLM para fornecer recomendações de investimento baseadas em dados não verificados ou em análises que não consideram variáveis econômicas cruciais. Como destacado por Bender et al. (2021), mesmo com todo o treinamento em grandes volumes de dados, os LLMs podem gerar respostas que, embora soem plausíveis, podem carecer de contextualização crítica, levando a decisões financeiras inadequadas.

Outro ponto de atenção é a necessidade de regulamentação e governança no uso de IA nos mercados financeiros. A adoção Inteligência Artificial pode ter impactos sistêmicos caso não exista uma supervisão adequada. A transparência na maneira como os modelos de IA tomam decisões é essencial para garantir que as operações financeiras sejam seguras, éticas e sustentáveis. Por exemplo, em mercados financeiros onde decisões de investimento e transações são automatizadas, a falta de supervisão pode permitir a manipulação de mercados ou o uso de informações privilegiadas, comprometendo a integridade dos sistemas financeiros globais. Danielson e Uthemann (2024) destacam a importância de uma abordagem equilibrada, onde os avanços tecnológicos não sejam apenas impulsionados pela inovação, mas acompanhados por uma governança robusta, que compreenda a transparência, responsabilidade e controle sobre o uso da IA.

Portanto, a regulamentação e a governança da IA devem ser cuidadosamente abordadas, com um foco claro na transparência dos processos algorítmicos, na mitigação de vieses e na implementação de protocolos para reduzir os riscos de interpretações equivocadas. A falta de regulamentação pode resultar em uma sobrecarga de riscos, tornando o mercado financeiro ainda mais vulnerável a erros humanos e falhas tecnológicas

2.3 MEDIDAS DE DESEMPENHO E DE RISCO NA GESTÃO DE RISCO DE CARTEIRAS

A Gestão de Risco em Carteira de Investimentos é o processo de identificação, avaliação, controle e mitigação de riscos associados a um portfólio de ativos financeiros. Esse

tipo de gestão é fundamental para investidores, gestores de fundos e instituições financeiras que desejam otimizar o desempenho de suas carteiras enquanto minimizam os riscos (PETROVNA et al., 2022).

Estratégias eficientes podem ajudar a mitigar riscos potenciais associados aos seus investimentos. Para manter a criação de valor e prevenir eventos adversos que possam ter passado despercebidos, é essencial quantificar a eficiência no investimento (ZAKARIA, 2017).

Risco e retorno estão interligados porque a tomada de decisões de gestão frequentemente envolve a consideração do risco e sua gestão. Os investidores enfrentam a responsabilidade de analisar os riscos que acompanham diferentes alternativas e estratégias para tomar decisões fundamentadas (PETROVNA et al., 2022).

O risco se refere à flutuação nos retornos de um investimento, e essa oscilação desempenha um papel crucial na determinação da probabilidade de atingir o retorno desejado. Quando a rentabilidade de um investimento varia substancialmente, existe a possibilidade de que ele não alcance os resultados esperados e, em algumas situações, até mesmo resulte em perdas financeiras.

A gestão de risco é o processo de identificar, avaliar, monitorar e controlar os riscos em uma organização ou em uma carteira de investimentos. O objetivo da gestão de risco é lidar com a incerteza e mitigar os impactos adversos dos riscos, quando necessário, para alcançar objetivos de forma mais segura e eficaz (JORION, 2007).

Para garantir uma gestão eficiente do risco em uma carteira de investimentos, é essencial adotar uma estratégia metódica e organizada. Isto envolve identificar e avaliar potenciais riscos, estabelecer um nível de tolerância, diversificar os investimentos, monitorizar e analisar regularmente o desempenho da carteira e fazer os ajustes necessários (ROTBLUT, 2021).

No trabalho realizado por Borges e Miranda (2021), eles analisaram estratégias de investimento na bolsa de valores de São Paulo, nos meses atingidos pela covid-19. É utilizado o método clássico de média e variância de Markowitz, e uma variação do método chamada média variância penalizada. Buscando melhor método a se utilizar para minimizar o risco e estimar o retorno desejado, o método média variância penalizada foi mais eficaz na gestão dos investimentos.

Tradicionalmente, a gestão em carteiras de investimento tem sido feita usando vários modelos estatísticos e técnicas de análise financeira (MA; HAN; WANG, 2021). Esses métodos tradicionais geralmente dependem de dados históricos, tendências de mercado e julgamento de especialistas para estimar os riscos potenciais associados a diferentes opções de investimento (MA; HAN; WANG, 2021). No entanto, com o avanço da tecnologia, principalmente no campo

da inteligência artificial, houve uma mudança para o uso de abordagens baseadas em IA para gestão de risco em carteiras de investimentos (ADEBIYI; OGUNBIYI; AMOLE, 2022).

Ao avaliar investimentos e tomar decisões financeiras, é importante considerar as métricas de desempenho e de risco associadas ao investimento. Estas métricas fornecem informações valiosas sobre os potenciais retornos e riscos envolvidos, ajudando os investidores a tomar decisões informadas. Ao avaliar o desempenho, os investidores baseiam-se frequentemente em indicadores financeiros como lucratividade, eficiência operacional e o crescimento dos ativos para medir o seu progresso (ARIAS; CUNHA; SAMANEZ, 2014). Esses indicadores refletem a saúde financeira e a rentabilidade dos investimentos, permitindo que os *stakeholders* avaliem o desempenho em termos de crescimento de vendas, lucro por ação e retorno. Por outro lado, a avaliação das métricas de risco financeiro garante que os investidores estejam cientes dos potenciais riscos e incertezas associados a um investimento. Essas métricas de risco incluem medidas como volatilidade, beta e desvio padrão, que fornecem *insights* sobre a estabilidade e variabilidade dos retornos do investimento (CARDOSO et al., 2019). Ao analisar as métricas de desempenho e de risco, os investidores podem avaliar as potenciais recompensas e riscos associados a um investimento, permitindo-lhes tomar decisões mais informadas.

A seguir, apresentam-se as medidas: Value at Risk e os Índices de Sharpe e de Sortino.

2.3.1 Método do Value at Risk (VaR)

O método VaR é uma ferramenta de gestão de risco amplamente utilizada que quantifica a perda potencial que uma carteira pode enfrentar ao longo de um horizonte de tempo especificado e em um determinado nível de confiança (GAIO; PIMENTA JÚNIOR, 2012). O método VaR calcula a perda máxima possível com base em dados históricos e análises estatísticas. A expressão do VaR é dada em (7).

A fórmula do VaR é:

$$VaR = |R - z \cdot \delta| \cdot V \quad (7)$$

Onde:

VaR = Valor em risco;

R = Retorno esperado;

Z = valor crítico associado ao nível de confiança;

δ = desvio padrão;

V = valor da carteira.

Ao estimar o VaR, os investidores podem definir limites de risco e tomar decisões informadas relativamente às suas estratégias de investimento. Também permite que os investidores avaliem a sua exposição à volatilidade do mercado e avaliem o impacto potencial na sua carteira de investimentos.

2.3.2 Índice de Sharpe

O Índice de Sharpe, criado por William Sharpe, é uma medida de desempenho que avalia o retorno de um investimento ou portfólio em relação ao risco assumido. Ele fornece uma métrica que ajuda a determinar se o retorno obtido por um investimento é compensador considerando o risco envolvido (SHARPE, 1966). O índice é calculado dividindo a diferença entre o retorno do ativo e a taxa livre de risco pela volatilidade do ativo representada pelo desvio padrão dos retornos. A fórmula do Índice de Sharpe é dado por (8):

$$SP = \frac{(E_{RA} - R_F)}{\delta} \quad (8)$$

Onde:

SP = Índice Sharpe;

E_{RA} = Retorno Esperado;

R_F = Retorno Livre de Risco;

δ = Desvio-padrão do retorno (risco do ativo).

Este indicador reflete a relação entre o risco e o retorno de um investimento. Quanto maior o valor do Índice de Sharpe, menor é o risco em relação ao retorno esperado. Por outro lado, quando o Índice de Sharpe é baixo, isso indica que o investimento carrega um risco significativamente maior em relação ao retorno que se espera obter (FERREIRA; COSTA, 2016). De maneira geral, valores mais altos do Índice de Sharpe indicam melhor desempenho ajustado ao risco. De acordo com a Investopédia (2024), um Índice de Sharpe inferior a 1 é geralmente considerado fraco, indicando que o retorno do investimento não compensa

adequadamente o risco assumido. Valores entre 1 e 2 são considerados aceitáveis ou razoáveis; entre 2 e 3, o desempenho é classificado como bom; e valores superiores a 3 são considerados excelentes, evidenciando uma ótima relação risco-retorno.

O Índice de Sharpe é uma ferramenta importante na avaliação de investimentos, auxiliando os investidores na seleção dos investimentos e na compreensão do equilíbrio entre risco e retorno. No entanto, é importante reconhecer suas limitações, particularmente quando aplicado a conjuntos de dados limitados. O Índice de Sharpe é mais eficaz quando usado em conjunto com séries históricas de dados mais extensas. Isso ocorre porque, com um histórico de dados mais amplo, os valores e resultados obtidos tornam-se mais robustos e representativos da realidade (FERREIRA; COSTA, 2016).

2.3.3 Índice de Sortino

O Índice de Sortino é um indicador de risco que se concentra especificamente na volatilidade negativa de um investimento, em contraste com o Índice de Sharpe, que considera a volatilidade total (ROLLINGER; HOFFMAN, 2015). O Índice de Sortino foi desenvolvido como uma métrica para avaliar o desempenho de investimentos, levando em consideração apenas o risco desvantajoso ou o risco de perda. A fórmula do Índice de Sortino é exposto em (9):

$$ST = \frac{(E_{RA}-T)}{DR} \quad (9)$$

Onde:

ST = Índice Sortino;

E_{RA} = Retorno Esperado;

T = Retorno-Alvo;

DR = *Downside risk*.

O objetivo do Índice de Sortino é avaliar o risco de não alcançar uma meta específica estabelecida pelo investidor, destacando assim sua distinção em relação a outros indicadores de risco. No entanto, é importante ressaltar que o uso do Índice de Sortino não exclui a necessidade de calcular outros indicadores, como o Índice de Sharpe (FERREIRA; COSTA, 2016).

O Índice de Sortino se diferencia do Índice de Sharpe ao empregar uma abordagem de análise denominada "risco de queda". Essa análise se concentra exclusivamente nas variações negativas, ou seja, aquelas que não atingem o objetivo desejado, mas que não necessariamente resultam em perdas financeiras diretas (MARTINS, 2019).

2.3.4 Retorno acumulado

O retorno acumulado mede o ganho percentual total de um ativo ou portfólio durante um determinado intervalo de tempo, considerando apenas os preços inicial e final do período. Trata-se de uma métrica útil para avaliar o desempenho absoluto de um investimento, independentemente da volatilidade ou do caminho percorrido pelos preços (DAMODARAN, 2012). O retorno acumulado é dado pela expressão (10):

$$Roi = \sum_{i=1}^N \left(\frac{P_{final}}{P_{inicial}} - 1 \right) \times 100 \quad (10)$$

Onde:

Roi = Retorno acumulado em porcentagem;

P_{final} = Preço do ativo no final do período;

$P_{inicial}$ = Preço do ativo no início do período.

Esse indicador fornece uma visão clara sobre o resultado total do investimento ao longo do tempo, sendo especialmente relevante para análises de longo prazo. Contudo, por não considerar a variabilidade dos retornos intermediários, deve ser utilizado em conjunto com medidas de risco (DAMODARAN, 2012).

2.3.5 Volatilidade acumulada

A volatilidade acumulada representa o grau de variação dos retornos de um ativo em relação à sua média, sendo uma medida estatística amplamente utilizada para quantificar o risco. Em finanças, a volatilidade é geralmente expressa como o desvio padrão dos retornos. Para fins comparativos e de consistência com outras métricas, como o Índice de Sharpe, é

comum a utilização da volatilidade anualizada (BODIE; KANE; MARCUS, 2014). A volatilidade acumulada é dada pela expressão (11).

$$\sigma_{Anual} = \sum_{i=1}^N \sigma_{diária} \times \sqrt{252} \quad (11)$$

Onde:

σ_{Anual} = Volatilidade anualizada do ativo;

$\sigma_{diária}$ = Desvio padrão dos retornos diários;

$\sqrt{252}$ = Número médio de pregões da bolsa em um ano.

A volatilidade acumulada permite avaliar a consistência dos retornos e o nível de risco ao qual o investidor está exposto. De acordo com a Teoria Moderna do Portfólio, quanto maior a volatilidade, maior é o risco do ativo, o que exige um retorno adicional para justificar a alocação de recursos (MARKOWITZ, 1999).

2.4 ESTUDOS CORRELATOS

Técnicas utilizando inteligência artificial no auxílio de investidores na escolha de seus investimentos se destacam pelos bons resultados obtidos pelo trabalho de Freitas e Reis (2022). O trabalho buscou desenvolver uma plataforma de investimento educacional baseada em inteligência artificial (IA) para tornar o processo de aprendizado sobre investimentos mais acessível e intuitivo. A pesquisa identificou que grande parte da população tem dificuldades em compreender os fatores que influenciam os investimentos financeiros e carece de informações sobre riscos e oportunidades. Com base nesses achados, foi proposta uma plataforma chamada "Investidor Consciente", que utiliza IA para oferecer suporte interativo e didático, ensinando conceitos financeiros de maneira acessível, especialmente para indivíduos de baixa renda.

Os resultados do estudo indicam que 71,7% dos entrevistados têm dificuldades em escolher investimentos devido à falta de conhecimento, e 86,5% afirmam que investiriam mais se tivessem maior clareza sobre os riscos. Além disso, a pesquisa revelou que há uma diferença estatisticamente significativa entre níveis de conhecimento financeiro de diferentes faixas de renda. A plataforma proposta pretende preencher essa lacuna oferecendo um ambiente livre de viés comercial, focado exclusivamente na educação financeira. O modelo desenvolvido inclui

um *chatbot* interativo, que simula conversas e direciona usuários para conteúdos educativos ou suporte direto, promovendo maior inclusão e consciência financeira.

Segundo Yoshigana e Castro (2023), com advento de tecnologias de inteligência artificial, tais como os algoritmos de aprendizado de máquina e aprendizado profundo, abriu caminho para o desenvolvimento de abordagens de investimento baseadas em quantidades significativas de dados. Essas tecnologias têm a capacidade de processar uma variedade de informações de maneira eficiente, abrangendo desde demonstrações financeiras e dados de mercado até artigos de notícias e a avaliação do sentimento do mercado com base em postagens em mídias sociais, bem como indicadores macroeconômicos.

O trabalho realizado por Ma, Han e Wang (2021) investiga a otimização de portfólios usando aprendizado profundo e *machine learning*. O estudo propõe uma abordagem inovadora ao integrar previsões de retorno na formação de portfólios, combinando modelos tradicionais com técnicas modernas de inteligência artificial. Foram utilizados modelos como *Random Forest* (RF) e *Support Vector Regression* (SVR) para aprendizado de máquina, e redes neurais profundas como *Long Short-Term Memory* (LSTM), *Deep Multilayer Perceptron* (DMLP) e CNN para aprendizado profundo. Os autores avaliaram a eficácia desses modelos ao aplicá-los a dados históricos da bolsa chinesa, especificamente os componentes do índice *China Securities 100*, entre 2007 e 2015. O objetivo foi comparar o desempenho desses métodos em relação ao modelo tradicional ARIMA.

Os resultados indicam que os modelos que incorporaram previsões de RF tiveram o melhor desempenho, especialmente na otimização baseada na variância média (MVF), superando outros modelos, inclusive aqueles que utilizaram SVR e LSTM. No entanto, a alta taxa de rotatividade das carteiras otimizadas com RF aumentou significativamente os custos transacionais, reduzindo parte dos retornos totais. Para mitigar esse efeito, os autores sugerem que investidores utilizem a abordagem MVF com previsão baseada em RF para negociações diárias. Além disso, para modelos baseados na métrica Ômega (OF), a melhor opção encontrada foi a que utilizou SVR para previsão de retornos.

Analisar o impacto da inteligência artificial na previsão de mercado de ações foi o trabalho realizado por Chopha e Sharma (2021). O estudo analisou 148 estudos utilizando técnicas neurais e híbridas para previsão do mercado de ações, categorizando-os em aspectos metodológicos e técnicos. Os autores destacam que as técnicas de IA conseguem capturar a não linearidade dos mercados financeiros, resultando em previsões mais precisas em comparação com modelos tradicionais, como a hipótese do mercado eficiente (EMH) e a teoria do passeio aleatório (RW).

Os resultados mostram que modelos baseados em aprendizado profundo, como Redes Neurais Convolucionais (CNNs) e Redes Neurais Recorrentes (RNNs), apresentam maior precisão na previsão de preços das ações. No entanto, os autores alertam que a maioria dos estudos não aborda corretamente questões como pré-processamento de dados, seleção de variáveis e ajustes de hiper parâmetros, o que pode levar a resultados distorcidos. Como agenda de pesquisa futura, os autores sugerem a exploração de novos algoritmos de seleção de recursos, aprimoramento de métricas de avaliação e integração de dados textuais, como sentimento do mercado capturados em redes sociais, para melhorar a precisão das previsões.

Lu, Huang e Li (2023) testaram se a IA generativa ChatGPT conseguiria ajudar investidores a tomar decisões de investimento com base em sua capacidade de raciocínio. Para isso, foi construída uma carteira de ações com abordagem semelhante a utilizada por uma consultoria de investimento. Assim o ChatGPT demonstrou notável capacidade de estabelecer associações com dados baseados em notícias, política de governo e formas efetivas de análise e desempenho da carteira.

3 METODOLOGIA

3.1 TIPOS DE PESQUISA

A abordagem metodológica adotada neste trabalho é baseada na pesquisa experimental, seguindo as diretrizes estabelecidas por (GIL, 2017). A pesquisa experimental é escolhida por sua capacidade de proporcionar clareza, precisão e qualidade na manipulação das variáveis, permitindo a observação sistemática de seus efeitos. Essa abordagem se alinha de forma estratégica com a natureza do nosso problema de pesquisa e os objetivos do estudo.

Considerando essa perspectiva, este projeto se configura como um estudo de pesquisa experimental, com o objetivo de aplicação de métodos tradicionais e inteligência artificial na gestão de risco em uma carteira de investimentos.

A realização da pesquisa bibliográfica foi fundamentada consultando fontes e referenciais bibliográficos para embasamento teórico, como: livros, sites, artigos, teses e revistas. Foram consultadas as seguintes bases de dados: IEEEExplore, INVESTOPÉDIA, AMBIMA, SCIELO e o Google Acadêmico.

3.2 COLETA DE DADOS

Considerando o crescimento do número de investidores no mercado acionário brasileiro em 2022 e a projeção de expansão contínua em 2023 (AMBIMA, 2023), optou-se pela análise de ações negociadas na B3. Os dados foram obtidos por meio do site <https://finance.yahoo.com/>, que fornece informações históricas confiáveis sobre preços de ativos financeiros.

Foram selecionadas 50 diferentes tipo de ações, com o objetivo de garantir uma amostra mais representativa e diversificada das ações do mercado brasileiro. Essa abordagem é alinhada ao Índice Brasil 50 (IBrX-50), elaborado pela B3, que é composto pelas 50 ações mais negociadas e representativas da bolsa brasileira. O IBrX-50 é projetado para medir o desempenho médio das ações mais líquidas e representativas do mercado acionário brasileiro (ANÁLISE DE AÇÕES, 2025). Utilizar uma amostra baseada no IBrX-50 permite capturar uma ampla gama de setores e empresas de diferentes tamanhos, refletindo de forma mais precisa a heterogeneidade do mercado (ANÁLISE DE AÇÕES, 2025).

A escolha dos ativos também considerou os seguintes critérios:

- Diversificação setorial: ações de empresas de diferentes setores da economia como tecnologia, financeiro, energia, consumo, entre outros, a fim de reduzir o risco específico e aumentar a representatividade da amostra;
- Comportamento de preço (alta e baixa): incluiu-se tanto ativos com desempenho positivo e quanto com desempenho negativo no período de 2022, para permitir análise em diferentes contextos de mercado;
- Perfis variados de risco e retorno: foram incluídas ações com risco e retorno historicamente classificados como alto, moderado e baixo, com base em indicadores como volatilidade anual e retorno acumulado;
- Correlação moderada entre ativos: a seleção buscou incluir ativos com correlação histórica entre si, visando maior potencial de diversificação de risco na construção das carteiras.

Os critérios adotados visam comparar diferentes estratégias de alocação de ativos em contexto distintos de desempenho, risco, retorno e correlação.

O período selecionado para a análise compreende de 1º de janeiro de 2022 a 31 de dezembro de 2023, esse período permitiu uma avaliação mais robusta da performance dos ativos em diferentes regimes de mercado. O ano de 2022 foi marcado por elevada volatilidade nos mercados globais, em razão de fatores macroeconômicos como a recuperação econômica desgastada pela covid-19, o aumento das taxas de juros pelas principais economias, pressões inflacionárias persistentes e os impactos geopolíticos decorrentes da guerra entre Rússia e Ucrânia (RIZÉRIO, 2022).

Em contrapartida, 2023 apresentou um ambiente de relativa estabilização, com sinais de recuperação gradual, revisão de expectativas e reprecificação de ativos diante de perspectivas mais claras sobre a trajetória dos juros e da inflação (BCB, 2023).

Essa escolha temporal permite a comparação do desempenho das carteiras sob condições de estresse financeiro e posterior normalização, (ANG, 2013) destaca a importância de avaliar estratégias de investimento em diferentes regimes de mercado, incluindo períodos de crise, de recuperação e estabilidade para validar a robustez dos modelos de alocação e gerenciamento de risco. Essa abordagem é essencial para identificar carteiras verdadeiramente resilientes.

3.3 SELEÇÃO DE ATIVOS E MONTAGEM DAS CARTEIRAS

Segundo o artigo de Predebon et al. (2010), a diversificação de carteiras traz benefícios, pois possibilita a redução do risco global do investimento ao combinar ativos cujos retornos não variam na mesma direção e proporção, resultando em um risco total inferior ao dos ativos individuais. Assim a Tabela 1, demonstra as ações selecionadas com base nos critérios da sessão 3.2

Tabela 1 – Ações selecionadas para compor a carteira

Número	Nome do Ativo	Ticker	Setor de Atuação	Preço de fechamento no ano (reais)	Volatilidade Acumulada (%)	Retorno Acumulado (%)
1	ALIAR ON NM	AALR3	Saúde	R\$ 21.60	59.06%	33.85%
2	AMBEV ON	ABEV3	Bebidas	R\$ 12.96	-0.29%	24.83%
3	MARISA LOJAS S.A.	AMAR3	Varejo	R\$ 6.25	-64.99%	66.71%
4	AMAZON	AMZO34	Varejo	R\$ 22.41	-53.58%	52.66%
5	ASSAI ON NM	ASAI3	Varejo - atacado	R\$ 19.04	54.60%	35.52%
6	B3 ON	B3SA3	Bolsa de valores	R\$ 12.15	27.25%	44.27%
7	AMAZONIA ON	BAZA3	Financeiro	R\$ 39.66	42.97%	35.42%
8	BANCO DO BRASIL ON	BBAS3	Financeiro	R\$ 15.07	30.24%	32.68%
9	BRADESCO ON	BBD C3	Financeiro	R\$ 10.91	-8.17%	31.15%
10	BRADESCO PN	BBD C4	Financeiro	R\$ 12.31	-13.37%	33.24%
11	BBSEGURIDADE ON NM	BBSE3	Seguros e Previdência	R\$ 28.19	76.18%	25.18%
12	BRF ON	BRFS3	Alimentos	R\$ 8.24	-62.54%	54.76%
13	BRASKEM PNA	BRKM5	Química	R\$ 23.76	-54.66%	46.23%
14	CPFL ENERGIA ON	CPFE3	Energia Elétrica	R\$ 29.15	40.92%	29.20%
15	CSN ON	CSNA3	Siderurgia	R\$ 12.02	-30.40%	54.59%
16	CURY S/A ON NM	CURY3	Construção Civil	R\$ 10.34	104.16%	51.73%
17	CYRELA ON	CYRE3	Construção Civil	R\$ 11.58	-6.45%	49.25%
18	EQTL PARA ON	EQPA3	Energia Elétrica	R\$ 5.08	38.58%	41.28%
19	EZTEC ON	EZTC3	Construção Civil	R\$ 12.24	-27.70%	47.49%

20	GERDAU PN	GGB R4	Siderurgia	R\$ 20.85	22.63%	39.28%
21	FUNDO IMOBILIÁRIO HOTEL MAXINVEST	HTM X11	Hotelaria	R\$ 78.56	29.53%	25.15%
22	HYPERMARCAS ON NM	HYPE 3	Saúde e Bem-Estar	R\$ 41.35	69.67%	29.69%
23	IRB BRASIL RESSEGUROS S.A.	XINA 11	Resseguros	R\$ 25.80	-73.49%	68.57%
24	ITAÚ UNIBANCO PN	ITUB 4	Financeiro	R\$ 20.85	18.26%	26.64%
25	KEPLER WEBER ON	KEPL 3	Máquinas e Equipamentos	R\$ 8.62	67.62%	41.95%
26	KLABIN UNIT	KLB N11	Papel e Celulose	R\$ 16.21	-15.43%	28.80%
27	LOG-IN ON NM	LOG N3	Logística e Transporte	R\$ 35.10	48.10%	40.15%
28	LOJAS RENNER ON	LREN 3	Varejo	R\$ 17.53	-10.62%	44.98%
29	M. DIASBRANCO ON NM	MDIA 3	Alimentos e Bebidas	R\$ 34.80	55.16%	43.91%
30	MAGAZINE LUIZA ON	MGL U3	Varejo	R\$ 24.88	-59.23%	82.02%
31	MILLS ON NM	MILS 3	Engenharia e Construção	R\$ 10.41	93.44%	51.51%
32	MARFRIG ON	MRF G3	Alimentos	R\$ 8.65	-48.50%	46.49%
33	MRV ENGENHARIA ON	MRV E3	Construção Civil	R\$ 7.60	-30.04%	56.25%
34	NATURA ON	NTC O3	Cosméticos	R\$ 11.15	-54.90%	66.76%
35	PÃO DE AÇÚCAR ON	PCAR 3	Varejo	R\$ 16.52	-19.58%	46.54%
36	PETROBRAS ON	PETR 3	Petróleo, Gás e Biocombustíveis	R\$ 19.07	45.11%	41.49%
37	PETROBRAS PN	PETR 4	Petróleo, Gás e Biocombustíveis	R\$ 15.09	34.90%	41.37%
38	PETRORIO ON	PRIO 3	Petróleo, Gás e Biocombustíveis	R\$ 37.15	83.39%	47.76%
39	PORTO SEGURO S.A.	PSSA 3	Seguros	R\$ 20.93	22.71%	30.29%
40	QR BITCOIN CI	QBTC 11	ETF	R\$ 5.44	-66.83%	59.20%
41	RAIA DROGASIL ON	RAD L3	Saúde e Bem-Estar	R\$ 22.22	3.17%	31.73%
42	PETRORECSA ON NM	RECV 3	Petróleo, Gás e Biocombustíveis	R\$ 27.18	97.93%	48.63%
43	SANTANDER UNIT	SANB 11	Financeiro	R\$ 24.34	-1.12%	27.92%
44	SABESP ON NM	SBSP 3	Saneamento Básico	R\$ 52.84	46.05%	35.58%
45	SUZANO ON	SUZB 3	Papel e Celulose	R\$ 45.65	-13.83%	32.54%
46	TAESA UNIT	TAEE 11	Energia Elétrica	R\$ 28.19	2.83%	19.82%
47	TAURUS ARMAS S.A.	TASA 4	Industria de armas	R\$ 11.67	-41.99%	39.95%
48	USIMINAS PNA	USIM 5	Siderurgia	R\$ 6.60	-49.59%	46.89%

49	LE LIS BLANC ON NM	VSTE 3	Varejo - Moda	R\$ 16.54	49.29%	77.47%
50	VULCABRAS ON	VUL C3	Calçados e Artigos Esportivos	R\$ 9.59	45.14%	39.30%

Fonte: Bolsa de Valores de São Paulo (2022).

A Tabela 1 apresenta os ativos selecionados para análise, acompanhados de suas respectivas variáveis: preço de fechamento no ano, volatilidade acumulada (%) e retorno acumulado (%). As variáveis foram escolhidas por refletirem, de forma concisa, o comportamento do mercado em relação ao risco (volatilidade) e à rentabilidade (retorno), além de considerar o valor de mercado (preço). A seleção dos ativos foi baseada na sua representatividade em diferentes setores econômicos e na disponibilidade dos dados para o ano de 2022. Essa abordagem visa proporcionar uma análise comparativa entre setores e facilitar a construção de indicadores compostos de desempenho.

3.4 TIPOS DE ANÁLISE

Esta pesquisa pretende montar carteiras e gerenciar seus riscos por meio de métodos tradicionais e de inteligência artificial. São utilizados dados de 2022 para contruir as carteiras das duas abordagens, e conforme o trabalho realizado por Duarte (2024) são necessários de 15 a 20 ativos para reduzir o risco não-sistemático. Assim será criada uma carteira com 20 ativos, e será comparando o desempenho entre as abordagens para o ano de 2023.

3.4.1 Aplicação dos métodos tradicionais na gestão de carteiras

Esta subseção apresenta a operacionalização dos métodos tradicionais em montagem de carteiras - *factor investing* e método de Markowitz - e em gestão de risco e desempenho – os índices de Shape e de Sortino e o VaR.

Nos experimentos se utiliza a linguagem de programação Python para a aplicação dos métodos tradicionais, seguindo o seguinte protocolo:

- 1- Importação de bibliotecas e buscar de dados no site do yahoo finance dos anos de 2022 a 2023.
- 2- Utilização do *factor investing*, consistindo em selecionar ativos financeiros com base em múltiplos fatores, como tamanho, valor, *momentum*, qualidade e baixa volatilidade. O objetivo é ranquear os ativos de acordo com critérios quantitativos e identificar aqueles com maior potencial de retorno com os dados de 2022.

3 - Para aplicar o método de Markowitz, compõe-se uma carteira com os 20 melhores resultados baseados em:

- Ranqueamento do *factor investing*;
- Ativos com melhores desempenho em retorno acumulado e baixa volatilidade;
- Correlação moderada, no processo de otimização pelo método de média-variância de Markowitz, foram impostas restrições práticas de alocação, limitando o peso de cada ativo entre 1% e 30%. Os pesos são adotados em estudos contemporâneos e aplicações práticas com o objetivo de promover diversificação e evitar concentrações (BODIE; KANE; MARCUS, 2014).

4 – Em seguida, utiliza-se o índice de Sharpe para avaliar o desempenho da carteira otimizada em relação ao risco total nos dois anos:

- Com os dados de 2022 será avaliado o desempenho da carteira. Para isso, o risco total foi assumido a taxa selic de 13,75%. Essa taxa foi considerada, pois foi a taxa final do ano de 2022;
- Com os dados de 2023 será avaliado o desempenho da carteira. Para isso, o risco total foi assumido a taxa selic de 12,25%. Essa taxa foi considerada, pois foi a taxa final do ano de 2023

5 – O índice de Sortino é utilizado para medir o risco de perda e a volatilidade negativa nos dados de 2022 e 2023.

6 – Para o VaR será estima-se a perda máxima da carteira nos dados de 2022 e 2023, foi utilizado um nível de confiança de 95%, e um investimento de R\$ 1.000.000,00 milhão. A escolha de utilizar um investimento de R\$ 1.000.000,00 para o cálculo do *Value at Risk* (VaR), tem como objetivo facilitar a interpretação e comparação dos riscos absolutos entre diferentes carteiras. O montante é suficientemente expressivo para simular um cenário realista de aplicação em mercados financeiros. E a escolha do nível de confiança de 95%, é justificada por sua popularidade e fornece uma medida robusta sem ser excessivamente.

3.4.2 Aplicação da IA Generativa

Para a aplicação da Inteligência Artificial (IA) neste trabalho, foi utilizado o modelo DeepSeek, desenvolvido na China, selecionado por sua capacidade de processamento avançado e geração de respostas com alto nível de coerência e raciocínio lógico. O DeepSeek se destaca entre os modelos de IA por sua eficiência na interpretação de contextos complexos,

oferecendo resultados precisos e bem fundamentados, o que o torna uma ferramenta valiosa para pesquisas acadêmicas (SHEEHAN; SINGER, 2025).

Assim foi desenvolvido um *prompt* para a IA com os comandos:

- A IA é instruída para ser um gestor de investimentos, buscando investir em ativos do ano de 2022.
- Escolhem-se 20 ativos com base nos dados reais do ano de 2022, podendo a IA selecionar ações, ETFs, títulos ou outros instrumentos financeiros.
- A IA define a alocação do percentual de cada ativo na carteira e justifica suas escolhas com base em critérios financeiros sólidos.
- A IA utilizará métricas relevantes, como retorno esperado, volatilidade, índice de Sharpe, Índice de Sortino e VaR, para avaliar o desempenho e o risco da carteira com os dados de 2022.
- Após a IA a construção da carteira com dados de 2022, a IA avalia o desempenho e o risco com os dados reais de 2023.
- No final da metodologia, a IA vai documentar tudo, dados utilizados, o critério na seleção dos ativos, a alocação, a otimização, o processo de seleção da carteira, os métodos utilizados para avaliar o desempenho e o risco, os resultados e a sugestão de melhoria para futuros estudos.

No final do estudo, analisa-se o desempenho dos métodos tradicionais e do uso da inteligência artificial utilizados, comparando as seguintes métricas, conforme o Quadro 1:

Quadro 1 – Métricas de desempenho e comparação dos anos

Métricas	Comparação das carteiras 2022 e 2023
Índice de Sharpe	Comparação do índice entre os dois métodos.
Índice de Sortino	Comparação do índice entre os dois métodos.
Retorno anualizado	Comparação do retorno anualizado entre os dois métodos.
Volatilidade anualizada	Comparação da volatilidade anualizada entre os dois métodos.
VaR	Comparação do VaR entre os dois métodos.

Fonte: Elaboração própria (2025).

Após a comparação das métricas, seleciona-se a melhor carteira com os melhores resultados das métricas utilizadas, considerando o retorno do investimento relacionado ao risco assumido.

4 RESULTADOS

Nesta seção, são apresentados e discutidos os resultados obtidos a partir da aplicação da metodologia descrita no Capítulo 3. Detalha-se o processo de implementação dos métodos utilizados na construção e avaliação das carteiras de investimento, com ênfase na análise dos dados, na seleção dos ativos e na mensuração do desempenho e do risco das carteiras ao longo do período de estudo.

4.1 CRIAÇÃO E ANÁLISE DE DESEMPENHO DAS CARTEIRAS

4.1.1 Método tradicional desempenho em 2022

Para a seleção da carteira, aplicou-se a metodologia do *factor investing*, fundamentada na identificação de ativos com bom desempenho relativo utilizando três grupos de fatores como Valor, Qualidade e *Momentum* e ranqueando conforme os seus resultados.

O fator Valor é representado pelas métricas Preço sobre Lucro (P/L), e Preço sobre Valor Patrimonial (P/VPA), e a ele foi aplicado um ranqueamento ascendente, ou seja, ações com os menores múltiplos recebem as melhores posições.

O fator Qualidade, representado pelo Retorno sobre o Patrimônio Líquido (ROE), utilizou um ranqueamento descendente, priorizando ações com maior capacidade de geração de retorno em relação ao capital próprio.

O fator *Momentum* foi mensurado com base no retorno acumulados das ações do ano de 2022, cujo ranqueamento também foi descendente, favorecendo ações com melhor desempenho recente.

Após a ordenação das ações em cada fator, foi atribuído um ranking numérico para cada ativo conforme Tabela 2.

Tabela 2 – Ações rankeadas pelo *factor investing*

Ranking	Ticker	P/L	P/VPA	ROE	Momentum
1	PRI03.SA	2.820	1.092	0.517	0.833
2	KEPL3.SA	6.946	1.837	0.271	0.720
3	BAZA3.SA	4.001	0.75	0.182	0.429
4	MILS3.SA	8.294	1.549	0.196	0.934
5	BBAS3.SA	6.168	0.901	0.215	0.332
6	SBSP3.SA	8.196	2.127	0.286	0.460

7	VULC3.SA	7.938	2.155	0.277	0.451
8	CURY3.SA	1.196	7.091	0.605	10.415
9	BBSE3.SA	9.378	8.374	0.892	0.761
10	CPFE3.SA	8.246	2.172	0.275	0.409
11	RECV3.SA	8.812	0.908	0.099	0.979
12	EQPA3.SA	7.202	2.838	0.410	0.385
13	CYRE3.SA	5.413	1.003	0.208	0.064
14	GGBR4.SA	7.050	0.556	0.061	0.226
15	ITUB4.SA	9.330	1.796	0.200	0.203
16	PSSA3.SA	1.058	1.968	0.201	0.249
17	BBDC3.SA	7.806	0.761	0.104	0.081
18	MDIA3.SA	1.316	1.054	0.082	0.551
19	PETR3.SA	9.923	1.146	0.098	0.451
20	VSTE3.SA	6.600	0.072	0.110	0.492
21	PETR4.SA	9.317	1.076	0.098	0.349
22	ASAI3.SA	1.596	2.335	0.155	0.546
23	EZTC3.SA	7.302	0.613	0.089	0.276
24	HYPE3.SA	1.836	1.255	0.068	0.696
25	B3SA3.SA	1.593	3.791	0.236	0.272
26	BBDC4.SA	8.709	0.849	0.104	0.133
27	TAEE11.SA	3.930	1.795	0.251	0.014
28	AALR3.SA	2.949	0.662	0.112	0.590
29	LREN3.SA	1.286	1.419	0.114	0.106
30	SANB11.SA	1.388	1.773	0.114	0.011
31	ABEV3.SA	1.594	2.313	0.165	0.002
32	LOGN3.SA	1.573	2.430	0.056	0.481
33	RADL3.SA	2.770	5.312	0.193	0.031
34	HTMX11.SA	2.949	2.181	0.110	0.295
35	BRKM5.SA	2.949	1.866	0.110	0.546
36	BRFS3.SA	1.172	2.444	0.229	0.625
37	TASA4.SA	1.437	0.855	0.064	0.419
38	AMZO34.SA	3.372	1.948	0.242	0.535
39	MRFG3.SA	1.150	6.794	0.124	0.484
40	USIM5.SA	2.604	0.295	0.011	0.495
41	KLBN11.SA	2.829	1.709	0.183	0.154
42	MRVE3.SA	2.949	0.511	0.064	0.304
43	MGLU3.SA	1.636	0.648	0.042	0.592
44	PCAR3.SA	2.949	0.768	0.434	0.195
45	EMBR3.SA	2.355	2.471	0.086	0.433
46	CSNA3.SA	2.949	1.015	0.08	0.303
47	NTCO3.SA	2.949	0.844	0.038	0.548
48	QBTC11.SA	2.949	2.181	0.110	0.668
49	SUZB3.SA	2.949	1.933	1.822	0.138

50	AMAR3.SA	2.949	2.490	1.820	0.649
----	----------	-------	-------	-------	-------

Fonte: Dados obtidos pelo Yahoo Finance (2022).

Em seguida, foram criados três *rankings* combinados por meio de uma média ponderada, gerando o Score Final. E os pesos atribuídos aos fatores na composição do Score foram:

- Valor (P/L e P/VPA): foi atribuído peso de 40%, essa atribuição maior de peso, se justica pela ampla evidência empírica de ações negociadas a múltiplos baixos, tendem ao longo do tempo, apresentar retornos acima da média compensado o risco assumido, conforme destacado por (FAMA; FRENCH, 1992).
- Qualidade (ROE): foi atribuído peso de 30%, reconhecendo a importância da eficiência operacional e da capacidade de geração de lucro das empresas como um motor de retornos sustentáveis (BOUCHAUD et al., 2016) .
- *Momentum*: Foi atribuído peso de 30%, (JEGADEESH; TITMAN, 1993b)destaque que ativos com bom desempenho recente, tendem a continuar apresentando bom desempenho nos períodos subsequentes. O peso igual ao fator Qualidade representa o equilíbrio entre fundamentos estáveis e dinâmica de mercado, tornando o modelo mais responsivo.

Na Tabela 3 demonstra a média ponderada do Score Final das ações pelo método do *factor investing*.

Tabela 3 - Ranking das ações

Ranking	Ticker	Rank valor	Rank qualidade	Rank momentum	Score final
1	PRI03.SA	11.00	3.0	4.0	6.50
2	KEPL3.SA	17.00	8.0	6.0	11.00
3	BAZA3.SA	5.50	20.0	16.0	13.00
4	MIL3.SA	19.00	17.0	3.0	13.60
5	BBAS3.SA	9.50	13.0	20.0	13.70
6	SBSP3.SA	22.00	5.0	13.0	14.20
7	VULC3.SA	22.00	6.0	14.0	14.80
8	CURY3.SA	35.50	2.0	1.0	15.10
9	BBSE3.SA	33.50	1.0	5.0	15.20
10	CPFE3.SA	23.50	7.0	17.0	16.60
11	RECV3.SA	15.50	33.0	2.0	16.70
12	EQPA3.SA	25.50	4.0	18.0	16.80
13	CYRE3.SA	10.00	14.0	30.0	17.20

14	GGBR4.SA	5.00	40.0	24.0	21.20
15	ITUB4.SA	22.50	16.0	25.0	21.30
16	PSSA3.SA	26.00	15.0	23.0	21.80
17	BBDC3.SA	9.50	31.5	31.0	22.55
18	MDIA3.SA	22.00	37.0	9.0	22.60
19	PETR3.SA	20.50	34.5	15.0	23.05
20	VSTE3.SA	29.00	27.5	11.0	23.15
21	PETR4.SA	18.00	34.5	19.0	23.25
22	ASAI3.SA	35.00	22.0	10.0	23.60
23	EZTC3.SA	6.50	36.0	37.0	24.50
24	HYPE3.SA	28.00	38.0	7.0	24.70
25	B3SA3.SA	37.00	11.0	22.0	24.70
26	BBDC4.SA	13.50	31.5	33.0	24.75
27	TAE11.SA	38.00	9.0	27.0	26.00
28	AALR3.SA	24.75	47.0	8.0	26.40
29	LREN3.SA	24.00	24.0	32.0	26.40
30	SANB11.SA	26.00	25.0	29.0	26.60
31	ABEV3.SA	34.00	21.0	28.0	28.30
32	LOGN3.SA	34.00	41.0	12.0	29.50
33	RADL3.SA	41.00	18.0	26.0	29.60
34	HTMX11.SA	39.50	27.5	21.0	30.35
35	BRKM5.SA	21.75	27.5	45.0	30.45
36	BRFS3.SA	31.50	12.0	48.0	30.60
37	TASA4.SA	20.50	39.0	40.0	31.90
38	AMZO34.SA	39.50	10.0	44.0	32.00
39	MRFG3.SA	34.00	23.0	42.0	33.10
40	USIM5.SA	18.50	43.0	43.0	33.20
41	KLBN11.SA	43.50	19.0	35.0	33.60
42	MRVE3.SA	22.75	45.0	38.0	34.00
43	MGLU3.SA	19.00	42.0	47.0	34.30
44	PCAR3.SA	26.75	49.0	36.0	36.20
45	EMBR3.SA	38.00	30.0	41.0	36.50
46	CSNA3.SA	30.25	46.0	39.0	37.60
47	NTCO3.SA	27.25	44.0	46.0	37.90
48	QBTC11.SA	39.50	27.5	50.0	39.05
49	SUZB3.SA	36.25	48.0	34.0	39.10
50	AMAR3.SA	42.75	50.0	49.0	46.80

Fonte: Elaboração própria (2025).

Posteriormente à seleção dos ativos com base na metodologia de *factor investing*, foi aplicada a alocação ótima proposta por Harry Markowitz (1999), por meio do modelo de fronteira eficiente. Essa abordagem busca maximizar o retorno esperado dado um nível de risco, ou minimizar o risco para um nível de retorno pré-definido, utilizando como insumos

estatísticos os retornos históricos e a matriz de covariância entre os ativos selecionados previamente.

Assim o modelo de Markowitz foi utilizado para identificar os pesos ótimos de alocação, buscando a composição mais eficiente possível sob a ótica do risco-retorno. Dessa forma, os pesos finais atribuídos a cada ação não seguiram diretamente a ordem do *ranking* do *Factor Investing*, mas foi determinada uma restrição de peso mínimo de 1% e peso máximo de 30% conforme destacado na subseção 3.4.1, e com base na redução do risco e no aumento do retorno da carteira como um todo.

O Quadro 2 apresenta as ações selecionadas inicialmente com base na metodologia descrita e integradas à carteira final com os respectivos pesos calculados pelo modelo de Markowitz..

Quadro 2 – Pesos atribuídos pelo método de Markowitz

Ação	Ticker	Peso (%)	Sector de Atuação
BBSBGURIDADEON NM	BBSE3.SA	23,47%	Seguros e Previdência
AMAZONIA ON	BAZA3.SA	16,13%	Financeiro (banco regional)
HYPERMARCASON NM	HYPE3.SA	7,95%	Salde e Bem-Estar (farmacêutico)
PORTO SEGLROS.A	PSSA3.SA	7,30%	Seguros
ITAU UNIBANCO PN	ITUB4.SA	7,38%	Financeiro
QTL PARA ON	EQPA3.SA	7,31%	Energia Elétrica
GERDAU PN	GGBR4.SA	5,68%	Siderurgia
ASSAI ON NM	AS413.SA	3,84%	Varejo -Atacado
CPFL EN8G A ON	CPFE3.SA	3,65%	Energia Elétrica
BRDESCO ON	BBDC3.SA	4,84%	Financeiro
PETROR O ON	PR103.SA	3,15%	Petróleo, Gás e Biocombustíveis
PETROR CSA ON NM	RECV3.SA	1,39%	Petróleo, Gás e Biocombustíveis
KEPLERWEBERON	KEPL3.SA	1,00%	Máquinas e Equipamentos
LE LIS BLANC ON NM	VSTE3.SA	1,00%	Varejo -Moda
MILLSONNM	MILS3.SA	1,00%	Engenharia e Construção
BANCO DO BRASIL ON	B8AS3.SA	1,00%	Financeiro
CURYS/A ON NM	CURY3.SA	1,00%	Construção Civil
VULCABRAS ON	VULC3.SA	1,00%	Calçados e Artigos Esportivos
CYRELAON	CYRE3SA	1,00%	Construção Civil
SAB ESP ON NM	SBSP3.SA	1,00%	Saneamento Básico
		100,00%	

Fonte: Elaboração própria (2025) .

Como resultado, o método de Markowitz apresentou resultado final da otimização dos pesos das ações que compõem a carteira. Cada valor em porcentagem representa a proporção

de capital que deve ser investida em cada ativo, de forma que o portfólio atinja a melhor relação de risco-retorno possível.

A ação BBSE3.SA recebeu maior peso de 23,47%, indicando que ela possui uma boa relação de retorno *versus* risco e também uma correlação moderada com os demais ativos, contribuindo positivamente para a diversificação.

A ação BAZA3.SA também teve uma alocação expressiva de 16,13%, o que sugere um bom desempenho ajustado ao risco e correlação baixa com ativos mais voláteis.

Outras ações com peso relevante incluem HYPER3.SA (7,95%), PSSA3.SA (7,30%), ITUB4.SA (7,38%), EQPA3.SA (7,31%), GGBR4.SA (5,68%), ASAI3.SA (3,84%), CPFE3.SA (3,55%), BBDC3.SA (4,84%), PRIO3.SA (3,15%), RECV3.SA (1,39%), todas essas ações que compõem a carteira, segundo o modelo, possuem retornos atrativos e baixa correlação.

As ações KEPL3.SA, VSTE3.SA, MILS3.SA, BBAS3.SA, CURY3.SA, VULC3.SA, CYRE3.SA e SBSP3.SA, receberam a alocação mínima permitida de 1%, conforme definido no modelo. Essa atribuição decorre do fato de que, durante o processo de otimização pelo método de Markowitz, essas ações apresentaram menor contribuição marginal para a eficiência da carteira, por apresentarem risco elevado em relação ao retorno esperado, por estarem altamente correlacionadas com outros ativos da carteira. Assim, apesar de não serem retiradas, o modelo manteve com o menor peso possível, de modo a respeitar os limites estabelecidos sem comprometer a relação risco-retorno da carteira.

Após a seleção da carteira, foi analisado o desempenho da carteira no ano de 2022. Os resultados são destacados no Quadro 3.

Quadro 3 - Resultados indicadores carteira tradicional 2022

Indicador	Valor
Índice de Sharpe	1,43
Índice de Sortino	2,27
VaR (95%)	R\$ 285.190,64
Retorno Acumulado	38,47%
Volatilidade Acumulada	17,28%

Fonte: Dados obtidos do Yahoo Finance (2022).


A análise de desempenho da carteira selecionada para o ano de 2022 revela resultados expressivos sob a ótica de retorno e risco. Conforme apresentado no Quadro 3, Índice de Sharpe calculado foi de 1,43. De acordo com a literatura financeira, valores de Sharpe acima de 1 são considerados aceitáveis conforme destaca (SHARPE, 1966). Portanto, o resultado obtido

evidencia que a carteira apresentou desempenho superior ao esperado em relação ao risco assumido.

Além do Índice de Sharpe, foi analisado o Índice de Sortino, que aprimora a análise de risco ao considerar perdas para o investidor. Em 2022, a carteira apresentou um índice de Sortino de 2,27, um valor significativamente elevado, o que indica que a estratégia foi especialmente eficaz em evitar quedas expressivas.

O *Value at Risk* (VaR) ao nível de 95% de confiança foi estimado em R\$ 285.190,64. Este valor indica que, sob condições normais de mercado, há apenas 5% de probabilidade de que a perda em um único período supere esse montante. Esse resultado evidencia que, embora a carteira tenha apresentado retorno elevado e consistente ao longo do ano, os riscos estavam controlados dentro de limites aceitáveis para um investidor com perfil moderado a arrojado.

O retorno acumulado atingiu 38,47%, indicando um desempenho significativo, conforme destaca o Gráfico 1.




Fonte: Elaboração própria (2025).

Durante o primeiro trimestre, o desempenho foi moderado, com oscilações suaves e retorno acumulado próximo de zero em fevereiro. A partir de março, a carteira passou a apresentar uma trajetória ascendente, refletindo a valorização de ativos com boa performance em um contexto de alta volatilidade nos mercados.

Ao longo do segundo semestre, entre julho e outubro, observa-se uma forte aceleração no retorno, indicando uma possível contribuição significativa de setores resilientes ou não-

correlacionados com o mercado. Apesar de algumas oscilações entre outubro e novembro, a carteira manteve a tendência de alta e demonstrou resiliência frente a possível choques de mercado.

Complementarmente, é fundamental compreender o nível de risco incorrido ao longo do período. Para isso, foi analisada a volatilidade anualizada da carteira. O Gráfico 2 mostra o risco do portfólio, que variou dinamicamente durante o ano, evidenciando períodos de maior ou menor instabilidade.



Fonte: Elaboração própria (2025).

A volatilidade se manteve dentro de patamares controlados, com picos em momentos específicos, como em março e setembro, que podem ter refletido por alguns eventos macroeconômicos e aumento ou diminuição dos preços.

De forma geral, os indicadores evidenciam que a carteira analisada apresentou elevado desempenho com risco controlado no ano de 2022, sendo caracterizada por retornos expressivos e métricas de risco ajustado que reforçam a eficácia da estratégia baseada em critérios quantitativos e otimização de portfólio.

4.1.2 Inteligência artificial desempenho em 2022

A contrução da carteira foi realizada com o auxílio de um modelo de *prompt* da inteligência artificial (IA). A abordagem adotada seguiu um processo metodológico fundamentado na Teoria Moderna do Portifólio proposta por Markowitz (1999), e critérios quantitativos e qualitativos de seleção de ativos. O objetivo foi identificar uma composição de ativos que maximizasse o retorno esperado ajustado ao risco, promovendo liquidez, diversificação e resiliência em cenários adversos.

Para selecionar os 20 ativos, a Inteligência Artificial (IA) adotou critérios estatísticos robustos, validados tanto empiricamente quanto teoricamente. Os filtros aplicados visaram garantir liquidez operacional e alinhamento estratégico com as condições de mercado observadas em 2022. Os principais critérios foram:

- **Liquidez:** A liquidez foi adotada como critério eliminatório, assegurando que os ativos escolhidos pudessem ser negociados com facilidade e sem impacto relevante nos preços.
- **Diversificação Setorial:** Para mitigar riscos específicos e evitar concentração excessiva em setores únicos, a carteira foi composta por ativos de diferentes setores econômicos, conforme a classificação da B3.
- **Desempenho Histórico:** A IA priorizou ativos que apresentam desempenho positivo, neutro ou resiliente.
- **Correlação entre ativos:** A diversificação da carteira combinou ativos com correlação moderadas e baixas.

O Quadro 4 apresenta os ativos selecionados pela Inteligência Artificial (IA).

Quadro 4 - Ações selecionadas pela inteligência artificial

Nome da Empresa	Ticker	Setor
Petrobras	PETR4	Energia (Óleo & Gás)
Vale	VALE3	Mineração (Ferro)
Itaú Unibanco	ITUB4	Financeiro
Banco Bradesco	BBDC4	Financeiro
Weg	WEGE3	Industrial (Motores)
Localiza	RENT3	Locação de Veículos
Suzano	SUZB3	Papel & Celulose
B3 (Bolsa Brasileira)	B3SA3	Financeiro (Bolsa)
Ambev	ABEV3	Bebidas
Raia Drogasil	RADL3	Saúde (Farmácias)
Lojas Renner	LREN3	Varejo
Equatorial Energia	EQTL3	Energia Elétrica

Gerda	GGBR4	Siderurgia
Hapvida	HAPV3	Saúde (Planos)
Cyrela	CYRE3	Construção Civil
Embraer	EMBR3	Aeroespacial
Totvs	TOTS3	Tecnologia (Software)
Magazine Luiza	MGLU3	Varejo (E-commerce)
BRF	BRFS3	Alimentos
Klabin	KLBN11	Papel & Celulose

Fonte: Yahoo Finance (2022)

Após a seleção dos ativos, para o processo de alocação de pesos, a Inteligência Artificial utilizou o modelo de média-variância proposto por Markowitz. Este método visa encontrar a combinação ótima de ativos que maximize o Índice de Sharpe da carteira, considerando as expectativas de retorno e a matriz de covariância dos ativos selecionados. A IA foi instruída a definir a alocação do percentual de cada ativo da carteira, alinhado ao risco assumido. As principais restrições impostas no processo de otimização foram:

- Definiu peso mínimo por ativo de foi de 1%, para garantir que todos os ativos tenham participação significativa, e para reduzir o risco de ativos correlacionados.
- Definiu peso máximo por ativo foi de 15%, para ativos com melhores desempenho de retorno, relacionado ao risco assumido.

Com base nesses parâmetros, a inteligência artificial (IA) calculou a Fronteira Eficiente e identificou o portfólio com maior retorno ajustado ao risco. Os pesos finais atribuídos a cada ativo estão descritos no Quadro 5 .

Quadro 5 - Alocação da carteira otimizada pela IA (2022)

Nome da Empresa	Ticker	Peso (%)	Setor
Petrobras	PETR4	12.0%	Energia
Weg	WEGE3	10.5%	Industrial
Vale	VALE3	9.8%	Mineração
Itaú Unibanco	ITUB4	8.7%	Financeiro
Suzano	SUZB3	7.5%	Papel & Celulose
Raia Drogasil	RADL3	6.3%	Saúde
Banco Bradesco	BBDC4	5.9%	Financeiro
Localiza	RENT3	5.5%	Locação de Veículos
Equatorial Energia	EQTL3	5.2%	Energia Elétrica
Totvs	TOTS3	4.8%	Tecnologia
B3	B3SA3	4.5%	Financeiro (Bolsa)

Lojas Renner	LREN3	3.7%	Varejo
Klabin	KLBN11	3.2%	Papel & Celulose
Embraer	EMBR3	2.8%	Aeroespacial
Gerdau	GGBR4	2.5%	Siderurgia
Ambev	ABEV3	2.0%	Bebidas
Cyrela	CYRE3	1.8%	Construção Civil
BRF	BRFS3	1.5%	Alimentos
Hapvida	HAPV3	1.2%	Saúde (Planos)
Magazine Luiza	MGLU3	1.0%	Varejo (E-commerce)

Fonte: Elaboração própria.

Assim a Inteligência Artificial montou a carteira que reflete uma combinação de ativos com a seguintes observações:

Os ativos PETR4, WEGE3, VALE3, ITUB4 e SUZB3 concentram a maior parte do peso da carteira de 48,05%, os pesos atribuídos a esses ativos, reflete a combinação de alto retorno esperado e baixa correlação entre eles.

Os setores com maiores pesos foram o financeiro (ITUB4, BBDC4 e B3SA3), concentrando 19,01% e o setor de energia e *commodities* com 29,03%

Ativos com pesos aproximadamente do mínimo, foram atribuídos para MGLU3, HAPV3 e BRFS3, para diversificar os setores e controlar o risco.

Após a criação da carteira e atribuição de peso, foi analisado o desempenho da carteira no ano de 2022. O Quadro 6 apresenta os resultados.

Quadro 6 – Resultados indicadores carteira da IA 2022

Indicadores	Valor
Índice de Sharpe	0,77
Índice de Sortino	1,12
VaR (95%)	R\$ 105.000
Retorno Acumulado	18,50%
Volatilidade Acumulada	16,20%

Fonte: Dados obtidos pelo Yahoo Finance (2022).

Os resultados da carteira em 2022 revelam um equilíbrio entre o risco e o retorno, com nuances importantes a serem destacadas.

O Índice de Sharpe de 0,77, a carteira demonstra uma boa capacidade de gerar retorno acima da taxa livre de risco (13,75%), mas ainda abaixo do valor referência de 1.


O Índice de Sortino de 1,12, mais elevado que o Índice de Sharpe, é um sinal positivo. Isso ocorre porque o Sortino considera apenas a volatilidade negativa, ignorando os ganhos

acima da média. Um valor acima de 1 indica que a carteira foi eficiente em limitar perdas durante o ano de 2022, ou seja, os retornos positivos compensaram significativamente os riscos de queda.

O *Value at Risk* (VaR) de um nível de significância de 95%, tem perda máxima de R\$ 105.000,00. Este valor indica que, sob condições normais de mercado, há apenas 5% de probabilidade de que a perda em um único período supere esse montante.

O retorno acumulado de 18,5% demonstrou resiliência em um ano marcado por volatilidade global, conforme demonstra o Gráfico 3.

Gráfico 3 - Retorno acumulado da carteira pela IA em 2022




Fonte: Elaboração própria (2025).

O Gráfico 3 evidencia um comportamento ascendente do retorno acumulado da carteira ao longo de 2022, o primeiro trimestre inicia positivo em janeiro e fevereiro. No entanto, em março observa uma queda do retorno momentâneo. A recuperação vem a partir do segundo trimestre, começando em abril, e seguindo um crescimento contínuo em maio e junho. No terceiro trimestre a trajetória é consistente, finalizando dezembro com o patamar mais alto.

A evolução do retorno acumulado da carteira ao longo de 2022 demonstra capacidade adaptativa frente a cenários desafiadores, com uma recuperação sólida e um crescimento contínuo a partir do segundo semestre.

Além do retorno acumulado, a Inteligência Artificial (IA) monitorou a volatilidade anualizada da carteira, conforme representado no Gráfico 4.

Gráfico 4 - Volatilidade da carteira pela IA em 2022

Fonte: Elaboração própria (2025).

O Gráfico 4 mostra variações mensais ao longo de 2022, no primeiro trimestre apresenta uma tendência de alta volatilidade nos meses de janeiro a março. No segundo trimestre entre os meses de abril e junho, a volatilidade mostra uma redução gradual, sugerindo uma maior estabilidade da carteira. E no segundo semestre entre julho e dezembro, a volatilidade é marcada por relativa estabilidade.

Assim a volatilidade ao longo do ano de 2022 revela que, apesar de um início de ano bastante volátil, a carteira conseguiu reduzir e manter níveis de risco mais baixos nos meses subsequentes.

4.1.3 Método tradicional, referente a 2023

Com as carteiras construídas e analisadas frente ao ano de 2022, foi possível simular e acompanhar o desempenho dos portfólios elaborados pelo método tradicional e pela abordagem com Inteligência Artificial (IA) ao longo do ano de 2023. O Quadro 7 resume os principais resultados obtidos com a carteira tradicional.

Quadro 7 - Desempenho da carteira tradicional em 2023

Indicadores	Valor
Índice de Sharpe	1,29
Índice de Sortino	2,1
VaR (95%)	R\$ 212.808,12

Retorno Acumulado	28,95%
Volatilidade Acumulada	12,90%

Fonte: Dados obtidos pelo Yahoo Finance (2023).


Em termos quantitativos, os resultados foram:

O Índice de Sharpe atingiu aproximadamente 1,29, um resultado acima do valor referência de 1, demonstrando que os retornos negativos foram relativamente controlados.

O Índice de Sortino foi de 2,1, o valor demonstra que os retornos negativos foram relativamente controlados.

O *Value at Risk* (VaR) a 95%, estimado em R\$ 212.208,00, representa a maior perda esperada em condições normais de mercado.

O retorno acumulado da carteira foi de 28,95%, revelando forte valorização dos ativos, conforme destaca o Gráfico 5.




Fonte: Elaboração própria (2025).

Ao longo do ano de 2023, a carteira apresentou uma trajetória marcada por oscilações pontuais, mas com tendência de alta sustentada. No primeiro trimestre, observou-se um forte início em janeiro, com expressivo crescimento do retorno acumulado. Contudo, em março houve uma correção significativa, que chegou a levar o desempenho da carteira para o campo negativo. A partir de abril, iniciou-se uma recuperação consistente, que se estendeu até o mês de junho, período caracterizado por leve valorização e relativa estabilidade. Em julho, a carteira

experimentou um avanço mais robusto, ultrapassando, refletindo um cenário mais favorável no mercado. Nos meses de agosto e setembro mantiveram a tendência de alta, embora com pequenas correções. Em outubro, houve uma nova queda moderada, e em novembro e dezembro a carteira voltou a acelerar seu desempenho, resultando em um encerramento do ano favorável.

A volatilidade acumulada indica um risco moderado e sugerindo uma performance mais estável ao longo do ano de 2023, conforme Gráfico 6.

Gráfico 6 - Volatilidade acumulada da carteira tradicional em 2023



Fonte: Elaboração própria (2025).

A volatilidade acumulada da carteira iniciou o ano de 2023 com indicadores bastante elevados, no qual a elevada volatilidade no início do período, reflete a instabilidade típica do começo do ano. A partir de fevereiro, nota-se uma trajetória de queda da volatilidade, com pequenas flutuações, mas mantendo-se em declínio até o mês de abril. Durante esse período, a carteira demonstrou maior estabilidade, com menor dispersão nos retornos.

Em maio, observa-se uma nova elevação, com a volatilidade ultrapassando os 18%, sinalizando um aumento da incerteza nos preços dos ativos. Entretanto, essa elevação foi temporária, pois a partir de junho, inicia-se um movimento contínuo de redução da volatilidade, que se estende até o mês de agosto. Nos meses seguintes, entre setembro e novembro, a volatilidade apresenta comportamento cíclico, com oscilações que indicam períodos alternados de maior e menor risco, sem ultrapassar os picos do primeiro semestre.

Por fim, em dezembro, a volatilidade volta a cair finalizando o ano em 12,90%, evidenciando um ambiente de maior previsibilidade e menor risco na carteira à medida que o ano se encerra.

4.1.4 Inteligência artificial, referente a 2023

A carteira constituída pela Inteligência Artificial (IA), que foi contruída por critérios qauntitativos, como liquidez mínima, diversificação setorial, correlação reduzida e otimização de média-variância, apresentou desempenho competitivo no ano de 2023, conforme demonstra o Quadro 8.

Quadro 8 - Desempenho da carteira da IA em 2023

Indicadores	Valor
Índice de Sharpe	0,42
Índice de Sortino	0,68
VaR (95%)	R\$ 121.000
Retorno Acumulado	9,80%
Volatilidade Acumulada	19,40%


Fonte: Dados obtidos pelo Yahoo Finance (2023).

O índice de Sharpe de 0,42 ficou abaixo o valor de referência de 1, indica uma relação modesta entre risco e retorno. Esse resultado sugere que a carteira teve dificuldades em converter a volatilidade assumida em retornos proporcionais, ou seja, o prêmio pelo risco foi relativamente baixo ao longo do período analisado.

O índice de Sortino que considera a volatilidade negativa, apresentou um resultado de 0,68. Esse valor, embora também abaixo do ideal, revela que as perdas foram menos frequentes ou menos intensas em comparação com a volatilidade captada pelo Índice de Sharpe.

O *Value at Risk* (VaR) a 95%, estimado em R\$ 121.000, representa a perda máxima esperada, com 95% de confiança. Esse valor evidencia o nível de risco da carteira em termos absolutos e pode ser interpretado como uma medida prudencial de exposição ao risco extremo.


O retorno acumulado de 9,80% demonstra um desempenho positivo no período, embora moderado, conforme destaca o Gráfico 7.

Gráfico 7 - Retorno acumulado da carteira da IA em 2023

Fonte: Elaboração própria (2025).

O retorno acumulado apresentou variações significativas ao longo do ano de 2023. Nos meses de janeiro e fevereiro, os ganhos foram modestos, mas consistentes. Contudo, em março, houve uma queda expressiva, levando o retorno acumulado para um valor negativo. A partir de abril, a carteira iniciou uma recuperação sólida, com um desempenho positivo contínuo nos meses de maio a julho. Essa tendência de crescimento manteve-se de forma estável durante os meses de agosto, setembro e outubro, alcançando um patamar mais elevado nos meses de novembro e encerrando dezembro com retorno acumulado de 9,80%, refletindo a eficácia da estratégia adotada.

Por fim, a volatilidade acumulada denota um ambiente de risco considerável, conforme destaca o Gráfico 8.



Fonte: Elaboração própria (2025).

A análise da volatilidade acumulada ao longo de 2023 mostra oscilações relevantes entre os meses. Em janeiro, a volatilidade começou em um patamar moderado, crescendo em fevereiro e atingindo seu pico em março, sinalizando um período de maior incerteza no mercado. A partir de abril, observou-se uma redução gradual do risco, com os menores níveis ocorrendo entre maio e junho. Nos meses seguintes — de julho a outubro — a volatilidade se manteve relativamente estável, com pequenas variações. Já em novembro e dezembro, houve uma leve retomada na volatilidade, embora sem comprometer o desempenho da carteira, que permaneceu em trajetória ascendente.

4.2 COMPARAÇÃO DO DESEMPENHO DAS CARTEIRAS

4.2.1 Comparação do desempenho entre carteiras do método tradicional nos anos de 2022 e 2023

Por mais que o ano de 2023 foi um ano de recuperação, conforme destacado pela XP Investimentos (2024), os indicadores de risco e retorno da carteira tradicional foram menos expressivos, e notou-se uma mudança significativa ao longo dos dois anos. Fazendo uma comparação de desempenho da carteira tradicional no ano de 2022 e 2023, a Tabela 4 resume essa comparação entre os dois períodos, destacando as principais variações nos indicadores de desempenho.

Tabela 4 - Comparação de desempenho da carteira tradicional - 2022 x 2023

Indicador	Carteira tradicional 2022	Carteira tradicional 2023	Varição
Índice de Sharpe	1,43	1,29	↓ -0,14
Índice de Sortino	2,27	2,1	↓ -0,17
VaR (95%)	R\$ 285.190,64	R\$ 212.808,12	↓ -72382,52
Retorno Acumulada	38,47%	28,95%	↓ -0,0952
Volatilidade Acumulada	17,28%	12,90%	↓ -0,0438

Fonte: Dados do Yahoo Finance (2022 e 2023).


Ao comparar os dois períodos, observa-se uma queda geral nos indicadores de desempenho no ano de 2023 em relação ao ano de 2022.

O Índice de Sharpe passou de 1,43 para 1,29, houve uma variação de 0,14, sinalizando que embora o retorno em relação ao risco ainda seja considerado bom, houve uma leve diminuição na eficiência da carteira em gerar retornos ajustados ao risco.

Da mesma forma, o Índice de Sortino, variou de 2,27 para 2,1, mantendo um bom nível, mas indicando um leve aumento nas perdas abaixo da média.

O *Value At Risk* (VaR) a um nível de confiança de 95% teve uma redução significativa de R\$ 72.382,52, o que representa uma melhora do ponto de vista do controle de perdas potenciais, ou seja, o risco de perdas extremas foi menor em 2023.

A comparação do retorno acumulado, é demonstrada no Gráfico 9.

Gráfico 9 - Retorno acumulado carteira tradicional 2022 x 2023


Fonte: Elaboração Própria (2025).

Observa-se que o ano de 2022 apresentou um crescimento expressivamente superior em relação a 2023. A carteira obteve um retorno acumulado de aproximadamente 38,47%, ao final de 2022, enquanto em 2023 o retorno final foi de 28,95%. O ano de 2022, apresentou um performace mais consistente e acentuada ao longo dos meses, especialmente em julho, e com destaques para o meses de agosto, outubro e novembro, onde os retornos atingiram picos significativos.

Em contraste, o ano de 2023 apresentou um comportamento mais moderado e volátil. Após um início positivo, observa-se uma queda no retorno acumulado em março, refletindo possíveis instabilidades de mercado naquele período. Ainda que a carteira tenha se recuperado e mantido trajetória de crescimento a partir de abril, o ritmo foi inferior ao observado no ano anterior, com um crescimento mais linear e contido.

Essa comparação evidencia que, embora a carteira tenha mantido desempenho positivo nos dois anos, mas o o ano de 2022 apresentou retornos superiores, provavelmente devido a uma combinação mais favorável de fatores macroeconômicos e desempenho dos ativos selecionados.

A comparação da volatilidade acumulada, é demonstrada no Gráfico 10.



Fonte: Elaboração própria.

Observa-se que, em 2022, a carteira apresentou níveis de volatilidade mais elevados de forma consistente ao longo do ano, com destaque para os meses de novembro e dezembro. Isso reflete um ambiente de mercado mais incerto e possivelmente mais volátil, o que é compatível com os riscos sistêmicos enfrentados no período, como incertezas macroeconômicas, política

monetária restritiva e eventos geopolíticos. Mas em 2023, houve uma clara tendência de redução da volatilidade ao longo dos meses. O ano se inicia com um pico elevado em janeiro, mas declina de forma progressiva ao longo dos meses, alcançando valores inferiores a 10% em setembro, e permanecendo relativamente estável até dezembro. Isso sugere uma maior estabilidade no comportamento dos ativos da carteira durante 2023, possivelmente refletindo um ambiente econômico mais previsível ou uma composição de ativos mais resiliente.

A comparação entre os dois anos revela que a carteira foi significativamente menos volátil em 2023, sobretudo no segundo semestre. Essa redução na volatilidade pode indicar uma melhoria no perfil de risco da carteira ou uma maior eficiência na sua construção.

4.2.2 Comparação do desempenho entre as carteiras geradas pela inteligência artificial nos anos de 2022 e 2023

A análise comparativa do desempenho da carteira gerada pela Inteligência Artificial (IA) entre os anos de 2022 e 2023 evidencia uma queda significativa nos principais indicadores de eficiência e desempenho ajustado ao risco, conforme demonstrado na Tabela 5.

Tabela 5- Comparação de desempenho da carteira IA 2022 x 2023

Indicador	Carteira IA 2022	Carteira IA 2023	Variação
Índice de Sharpe	0,77	0,42	↓ -0,35
Índice de Sortino	1,12	0,68	↓ -0,44
VaR (95%)	R\$ 105.000,00	R\$ 121.000,00	↑ 16000
Retorno Anualizado	18,50%	9,80%	↓ -0,087
Volatilidade Anualizada	16,20%	19,40%	↑ 0,032

Fonte: Dados obtidos do Yahoo Finance (2025).

Em 2022, a carteira criada pela IA apresentou um desempenho relativamente sólido, com bom equilíbrio entre retorno e risco. No entanto, em 2023, houve uma deterioração considerável nos indicadores, refletindo a dificuldade do modelo em se adaptar a mudanças nos ciclos econômicos e nas dinâmicas setoriais.


O Índice de Sharpe, que mensura o retorno excedente por unidade de risco total, caiu de 0,77 para 0,42 representando uma redução de 0,35 pontos. Essa queda indica que, em 2023, a carteira entregou um retorno significativamente menor para cada unidade de risco assumida, revelando uma eficiência inferior na alocação dos ativos do ponto de vista risco-retorno.

O Índice de Sortino, também apresentou declínio, passando de 1,12 para 0,68. A queda de 0,44 pontos reforça a percepção de que os retornos negativos se tornaram mais frequentes ou mais severos em 2023, impactando negativamente a performance ajustada ao risco de queda.

O *Value at Risk* (VaR) aumentou de R\$ 105.000,00 para R\$ 121.000,00, indicando que a perda potencial estimada em condições adversas foi mais elevada em 2023. Isso pode ser explicado tanto pelo aumento da volatilidade como por uma maior concentração ou sensibilidade da carteira a riscos sistêmicos.

O retorno acumulado, houve uma redução expressiva, passando de 18,50% em 2022 e 9,80% em 2023, conforme destaca o Gráfico 11.


Gráfico 11 - Retorno acumulado carteira IA 2022 x 2023



Fonte: Elaboração própria (2025).

Houve uma variação de aproximadamente 8,7 pontos percentuais. Esta desaceleração no desempenho da carteira evidencia que os ativos selecionados pela IA, embora eficientes em 2022, foram menos eficazes no ambiente de mercado de 2023, possivelmente devido à mudança no regime econômico ou no comportamento dos fatores de risco utilizados na seleção.

Por fim, observa-se que a Volatilidade Anualizada aumentou de 16,20% para 19,40%, sinalizando que a carteira enfrentou maior incerteza nos preços dos ativos em 2023. O Gráfico 12 desmostra esse aumento.



Fonte: Elaboração própria (2025).

A volatilidade maior em 2023, contribui para explicar os índices de Sharpe e Sortino mais baixos, já que o maior risco não foi compensado por um retorno proporcional.

4.2.3 Comparação do desempenho entre as carteiras geradas pelo método tradicional e gerada pela IA

A análise comparativa entre a carteira tradicional e a carteira otimizada por inteligência artificial (IA) visa avaliar, de forma abrangente, o desempenho de ambas as estratégias de investimento durante o ano de 2022, com foco em retorno, risco e eficiência na relação risco-retorno. Os dois métodos utilizaram critérios distintos na escolha das ações, conforme representado no Quadro 9.

Quadro 9 - Critérios utilizados pelos dois métodos		
Critério	Método Tradicional	Inteligência Artificial
Base de seleção	Funfamentais (P/L, P/VPA, ROE, <i>Momentum</i>)	Estatística, liquidez, correlação, Sharpe
Dados utilizados	Contábeis e de preços	Preços históricos, volume e volatilidade
Foco	Rentabilidade com base em fundamentos	Eficiência de risco e resiliência
Diversificação setorial	Limitada (dependente do score)	Priorizada para minimizar o risco total
Correlação entre ativos	Não considerada na seleção inicial	Comsiderada para minimizar risco total
Complexidade	Menor (fácil replicação)	Maior (análise estatística e otimização)

Fonte: Elaboração própria (2025).

Os critérios utilizados por cada método evidenciam que ambas as estratégias oferecem contribuições valiosas, sendo a tradicional mais voltada à maximização de retornos com base em fundamentos econômicos, enquanto a IA foca em resiliência, estabilidade e controle de risco, especialmente em cenários de incerteza. Assim, compreender as diferenças nos critérios de seleção é essencial para avaliar a adequação de cada estratégia ao perfil e aos objetivos do investidor.

Comparando o desempenho das carteiras no ano de 2022, a Tabela 6 apresenta a comparação e variação.

Tabela 6 - Comparação de desempenho carteira IA 2022

Indicador	Carteira tradicional 2022	Carteira IA 2022	Variação Tradicional - IA
Índice de Sharpe	1,43	0,77	↓ -0,66
Índice de Sortino	2,27	1,12	↓ -1,15
VaR (95%)	285190,64	105000	↑ -R\$ 180.190,64
Retorno Acumulado	38,47%	18,50%	↓ -0,1997
Volatilidade Acumulada	17,28%	16,20%	↑ -0,0108

Fonte: Dados obtidos do Yahoo Finance (2025).

A comparação entre a carteira tradicional e a carteira gerada por Inteligência Artificial (IA) em 2022 revela diferenças substanciais no desempenho e na relação risco-retorno, com destaque para a superioridade da abordagem tradicional nos principais indicadores de eficiência.


O Índice de Sharpe da carteira tradicional foi de 1,43, enquanto o da carteira da IA foi de 0,77, representando uma diferença negativa de 0,66 pontos. Esse resultado demonstra que a carteira tradicional proporcionou um retorno ajustado ao risco significativamente superior, indicando maior eficiência na alocação de ativos sob a ótica da teoria moderna do portfólio. Em outras palavras, para cada unidade de risco total assumida, a carteira tradicional gerou quase o dobro do retorno em relação à carteira de IA.

O Índice de Sortino, que foca especificamente no risco de perdas, foi 2,27 na carteira tradicional e 1,12 na carteira da IA, revelando uma variação ainda mais expressiva de 1,15 pontos. Isso indica que a carteira tradicional não apenas teve melhor desempenho, mas também foi menos suscetível a retornos negativos, consolidando-se como uma alternativa mais robusta em termos de risco assimétrico.

O *Value at Risk* (VaR) a 95% de confiança, carteira tradicional apresentou um valor significativamente maior: R\$ 285.190,64, em comparação com R\$ 105.000,00 da carteira de

IA. Embora isso indique maior potencial de perda sob condições adversas, o maior risco foi acompanhado de um retorno superior, o que justifica parcialmente a maior exposição.

O Gráfico 13 apresenta a comparação do retorno acumulado entre a carteira tradicional e a carteira otimizada por Inteligência Artificial (IA) ao longo de 2022. Observa-se que ambas as carteiras apresentaram desempenhos positivos durante o ano, porém com trajetórias distintas.



Fonte: Elaboração própria (2025).


A carteira tradicional apresentou uma trajetória de crescimento mais intensa e com maior volatilidade, apresentou um desempenho superior com retorno acumulado de 38,47% ao ano, frente a 18,50% da carteira da IA. A diferença de quase 20 pontos percentuais evidencia que, em 2022, a estratégia tradicional foi mais eficaz em capturar ganhos no mercado. A trajetória do Gráfico 13 demonstra aceleração significativa a partir de março. Após um início modesto nos dois primeiros meses, a carteira tradicional apresenta um salto expressivo em março e abril, seguido de leve volatilidade nos meses seguintes de maio a julho, mas retomando fortemente a partir de agosto. O destaque fica para o avanço acentuado entre agosto e novembro, quando o retorno acumulado atinge seu pico de aproximadamente 48% em novembro, antes de uma leve correção em dezembro. Esse comportamento reflete uma exposição a ativos com maior potencial de valorização e, possivelmente, maior volatilidade, mas que resultou em retornos superiores no consolidado do ano.

Já a carteira de IA apresenta uma trajetória mais estável e conservadora ao longo dos meses. Após uma queda em março, o Gráfico 13 revela uma recuperação progressiva, com crescimento contínuo e menos volátil até o final do ano. O retorno acumulado da carteira da IA

atinge fecha o ano com 18,5%, significativamente inferior ao da carteira tradicional. No entanto, sua estabilidade sugere uma menor sensibilidade a choques de mercado, coerente com um perfil de risco mais moderado.

A diferença entre as trajetórias indica que, enquanto a carteira tradicional se beneficiou de movimentos mais agressivos de mercado, a carteira da IA adotou uma postura mais prudente e diversificada, priorizando consistência e menor exposição a oscilações bruscas. Essa divergência reflete diretamente nas métricas de risco-retorno analisadas anteriormente, onde a carteira tradicional, apesar de mais volátil, entregou resultados superiores em 2022.

O Gráfico 14, por sua vez, compara a volatilidade acumulada entre as duas carteiras.



Fonte: Elaboração própria (2025)

A carteira tradicional apresenta uma trajetória de volatilidade mais oscilante, com picos e vales mais pronunciados. Observa-se um aumento em março, uma queda significativa em maio, e um novo aumento em novembro. Essa dinâmica indica que a carteira tradicional esteve mais exposta a eventos de mercado específicos ou a ativos com maior sensibilidade a variações econômicas. Apesar da maior instabilidade, essa estratégia conseguiu compensar com retornos superiores, como visto anteriormente.

Por outro lado, a carteira da IA demonstra uma trajetória de volatilidade mais constante, embora com um pico expressivo em março. Após esse ponto, a volatilidade da carteira da IA se estabiliza em torno de 15% a 16% nos demais meses, com pequenas flutuações. Isso sugere uma gestão de risco mais robusta, com maior diversificação e foco em ativos menos voláteis, o que reflete a proposta da IA de construir uma carteira resiliente e balanceada.

De forma geral, o gráfico evidencia que a carteira tradicional assumiu mais risco de forma intermitente ao longo do ano, enquanto a carteira da IA manteve um risco mais controlado e previsível, alinhado com estratégias de menor volatilidade.

Essa diferença ajuda a explicar por que a carteira tradicional teve retorno superior, ainda que com um nível de risco um pouco mais elevado.

Em 2023, tanto a carteira tradicional quanto a carteira contruída pela Inteligência Artificial (IA) apresentaram resultados positivos, embora com características e estratégias distintas, na Tabela 7, apresenta-se uma análise comparativa detalhada dos principais indicadores de desempenho, permitindo avaliar a eficácia relativa de cada abordagem no cenário pós-pandemia, marcado por incertezas econômicas, flutuações nas taxas de juros e reacomodação dos setores produtivos.

Tabela 7 - Comparativa: Carteira Tradicional vs. Carteira da IA (2023)

Indicador	Carteira tradicional 2023	Carteira IA 2023	Variação Tradicional - IA
Índice de Sharpe	1,29	0,42	↓ -0,87
Índice de Sortino	2,1	0,68	↓ -1,42
VaR (95%)	212808,12	121000	↑ -91808,12
Retorno Acumulado	28,95%	9,80%	↓ -0,1915
Volatilidade Acumulada	12,90%	19,40%	↓ 0,065

Fonte: Dados do Yahoo Finance (2023).

Em 2023, a comparação entre a carteira tradicional e a carteira construída por Inteligência Artificial (IA) revela um desempenho bastante discrepante, tanto em termos de retorno quanto de risco.

Os índices de Sharpe e Sortino forneceram uma análise fundamental sobre a eficiência das carteiras ao ajustar os retornos pelo risco assumido. Ambos os indicadores mostram que a carteira tradicional superou com folga a carteira IA não apenas em retorno absoluto, mas também em retorno ajustado ao risco.

O Índice de Sharpe da carteira tradicional, apresentou um valor de 1,29, valor considerado bom, acima do valor referência de 1, indicando que o retorno obtido compensou amplamente a volatilidade enfrentada. Já a carteira da IA apresentou um índice de Sharpe inferior de 0,42, sinalizando que, apesar de ter apresentado certa rentabilidade, ela não foi suficiente para justificar o risco total da carteira, ou seja, o desempenho foi ineficiente do ponto de vista do risco-retorno.

O Índice de Sortino em 2023, a carteira tradicional apresentou um Sortino de 2,10, valor excelente que reflete não apenas retornos consistentes, mas uma baixa frequência e intensidade


de quedas. Já a carteira IA teve um Sortino de apenas 0,68, reforçando a leitura de que, embora sua volatilidade tenha sido elevada, os retornos positivos não compensaram adequadamente os momentos de perdas.

A diferença entre os dois indicadores em cada carteira é significativa: enquanto a carteira tradicional manteve uma boa proporção entre risco total e risco de queda, a carteira IA teve uma relação muito fraca, com Sortino de 0,68, indicando que as perdas ou retornos fracos ocorreram com frequência ou intensidade significativa.

Esses dados sugerem que, em 2023, a carteira tradicional não só entregou mais retorno, mas também gerenciou melhor o risco, especialmente o risco de queda, enquanto a carteira IA teve desempenho aquém do ideal tanto em termos absolutos quanto ajustados ao risco.

O *Value at Risk* (VaR) a 95% mostra que a carteira da IA teria uma perda potencial menor (R\$ 121.000,00) em um cenário extremo, frente à carteira tradicional (R\$ 212.808,12). Isso indica que, mesmo com maior volatilidade, a carteira IA foi construída com uma distribuição de ativos que protegeu parcialmente contra perdas severas — provavelmente devido à diversificação ou escolha de ativos menos concentrados.

O retorno acumulado representa o crescimento total da carteira ao longo do ano, a carteira tradicional obteve um retorno expressivo de 28,95%, superando a carteira da IA, que apresentou apenas 9,80%. A diferença de quase 20 pontos percentuais, reflete claramente no Gráfico 15 a trajetória da carteira tradicional frente a carteira da IA.




Fonte: Elaboração própria (2025).

Ao analisar o gráfico, percebe-se que a carteira tradicional apresentou uma trajetória mais dinâmica e consistente de crescimento, com fortes recuperações ao longo do ano, especialmente a partir de abril e um forte salto em dezembro. Já a carteira da IA seguiu uma curva de crescimento mais linear e modesta, com retornos estáveis, porém menos expressivos. Isso indica que, embora a IA tenha conseguido evitar grandes perdas, ela também não capturou os momentos de maior valorização do mercado com a mesma eficiência da carteira tradicional.

A volatilidade acumulada, por outro lado, a carteira da IA apresentou uma volatilidade maior (19,40%) do que a carteira tradicional (12,90%), contrariando o que se poderia esperar de uma abordagem geralmente mais conservadora como a baseada em IA. Esse dado é particularmente relevante porque reforça a ineficiência da carteira IA em 2023: ela assumiu mais risco (maior volatilidade), mas entregou um retorno consideravelmente menor. Já a carteira tradicional demonstrou uma relação mais saudável entre risco e retorno, com menor oscilação e maior rentabilidade.

No Gráfico 16 demonstra essa comparação.



Fonte: Elaboração própria (2025).

No gráfico, é possível notar que a carteira da IA manteve uma volatilidade elevada e relativamente constante ao longo dos meses, enquanto a carteira tradicional reduziu significativamente sua volatilidade no segundo semestre, especialmente entre julho e setembro. Esse comportamento indica um controle mais eficaz do risco pela carteira tradicional, talvez

pela composição mais eficiente dos ativos ou por uma melhor adaptação ao cenário macroeconômico do ano.

4.3 CONSIDERAÇÕES SOBRE OS RESULTADOS

A análise dos resultados obtidos neste estudo comparativo entre a alocação de ativos por métodos tradicionais e por Inteligência Artificial (IA), permite produzir considerações relevantes sobre o desempenho e o perfil de risco de cada abordagem. A investigação centrou-se em responder se a IA poderia oferecer um balanço mais vantajoso entre rentabilidade e segurança em comparação com estratégias consagradas, como a otimização de Markowitz combinada à análise fundamentalista.

Um dos primeiros pontos a se destacar é a performance de rentabilidade. Os dados revelaram que a carteira construída sob a metodologia tradicional consistentemente apresentou retornos brutos superiores aos da carteira gerenciada por IA no período avaliado (2023), e também demonstrou forte desempenho em 2022. Este resultado demonstra a eficácia dos modelos tradicionais, que ao focarem em fundamentos e otimização de média-variância com base em dados históricos, conseguem identificar ativos com alto potencial de valorização. A carteira tradicional, em 2022, alcançou um retorno acumulado de 38,47%, e em 2023 de 28,95%. Em contrapartida, a carteira da IA obteve 18,50% em 2022 e um retorno mais modesto de 9,80% em 2023. Todavia, a análise de risco constitui um elemento de contraponto essencial.

A carteira da IA, apesar de retornos menores, exibiu um perfil de risco mais controlado e maior resiliência. Indicadores como o *Value at Risk* (VaR) foram consistentemente menores para a carteira da IA (R\$ 105.000 em 2022 e R\$ 121.000 em 2023) em comparação com a tradicional (R\$ 285.190,64 em 2022 e R\$ 212.208,00 em 2023), que, apesar da queda observada em 2023, já se encontrava em um patamar elevado anteriormente. A volatilidade da carteira da IA também se mostrou, mais contida, especialmente em 2022 (16,20% para IA vs 17,28% para tradicional), embora em 2023 a volatilidade da carteira da IA (19,40%) tenha superado a da tradicional (12,90%), embora a inteligência artificial não tenha eliminado o risco, ela demonstrou uma capacidade de gerenciamento mais cautelosa, possivelmente ao priorizar a diversificação e a redução de correlações entre ativos. Essa abordagem contrasta com a estratégia tradicional baseada em *factor investing* e na otimização de Markowitz, que, por se apoiar em dados históricos de um conjunto pré-selecionado, pode não ter captado com a mesma ênfase essas nuances em todos os cenários.

Os índices de Sharpe e Sortino, ao ajustarem os retornos de acordo com o risco assumido, fornecem uma análise mais refinada do desempenho dos ativos. A carteira tradicional apresentou um Índice de Sharpe de 1,43 em 2022 e 1,29 em 2023, valores considerados acima do valor de referência de 1, e indicativos de retorno adequado pelo risco assumido. A carteira da IA, por sua vez, registrou um Sharpe de 0,77 em 2022 e 0,42 em 2023. Embora inferiores, o valor de 2022 para a IA ainda sugere uma certa eficiência. O Índice de Sortino, que foca no risco de perdas (downside risk), também foi superior para a carteira tradicional (2,27 em 2022 e 2,1 em 2023) em relação à da IA (1,12 em 2022 e 0,68 em 2023). Esses resultados indicam que, mesmo após o ajuste pelo risco, o desempenho superior da carteira tradicional foi suficiente para compensar o risco assumido de ao longo dos períodos analisados.

A avaliação do desempenho das duas carteiras nos períodos de 2022 e 2023 revela as diferenças nas estratégias adotadas. Ambas as carteiras foram impactadas pelas condições de mercado. A carteira tradicional, em particular, teve uma redução em sua eficiência (medida pelos índices de Sharpe e Sortino) e no retorno acumulado em 2023, quando comparada a 2022. No entanto, sua volatilidade e o VaR (Valor em Risco) diminuíram, o que pode indicar tanto um ambiente de menor risco quanto uma adaptação da carteira às novas condições de mercado. A carteira da IA, por outro lado, apresentou uma queda mais significativa nos indicadores de retorno e eficiência em 2023, além de um aumento na volatilidade e no VaR. Isso sugere que, apesar de os critérios e algoritmos de IA terem sido eficazes em 2022, eles podem ter enfrentado dificuldades em se adaptar às dinâmicas específicas do mercado de 2023. Isso pode ocorrer devido a uma natureza da IA que busca padrões, mas foi desafiada por um ambiente de mercado com características distintas das observadas no período de otimização.

Os resultados mostram um compromisso claro entre as duas abordagens: a metodologia tradicional, que combina análise de fatores e a otimização de Markowitz, gerou retornos mais elevados, mas com maior exposição ao risco. Já a Inteligência Artificial focou na construção de uma carteira com menor risco e maior diversificação, o que resultou em retornos mais modestos, mas com maior potencial de estabilidade em cenários voláteis. A escolha entre essas duas abordagens dependerá do perfil de risco do investidor e de seus objetivos financeiros. Investidores dispostos a assumir mais risco e focados na maximização de ganhos podem preferir a abordagem tradicional, enquanto aqueles que priorizam a preservação de capital e a minimização de perdas podem se beneficiar das estratégias baseadas em IA.

5 CONSIDERAÇÕES FINAIS

O presente Trabalho de Conclusão de Curso propôs-se a realizar uma análise comparativa aprofundada entre os métodos tradicionais de alocação de ativos financeiros e as abordagens baseadas em Inteligência Artificial (IA). A pergunta central que norteou esta investigação buscou elucidar qual metodologia apresentaria um balanço mais favorável entre desempenho e risco na construção de carteiras de investimento, considerando o dinâmico e complexo cenário do mercado financeiro brasileiro. Para tanto, foram construídas e avaliadas duas carteiras distintas: uma fundamentada na análise fundamentalista e no modelo de otimização de Markowitz, e outra concebida através de algoritmos de IA que consideraram critérios como liquidez, diversificação setorial e correlação reduzida, com otimização por média-variância.

Os resultados obtidos ao longo da pesquisa revelaram nuances importantes sobre as capacidades e limitações de cada abordagem. A carteira elaborada com base nos métodos tradicionais demonstrou uma rentabilidade superior no período analisado, superando a carteira da IA em termos de retorno. Este achado corrobora a eficácia histórica de modelos consolidados, como o de Markowitz, em identificar oportunidades de investimento com potencial de valorização expressiva, especialmente quando combinados com uma criteriosa análise de fatores do *factor investing*. Contudo, essa maior rentabilidade veio acompanhada de uma exposição ao risco também mais elevada, evidenciada por indicadores como a volatilidade e o Value at Risk (VaR). Tal característica sugere que, embora lucrativa, a estratégia tradicional pode ser mais suscetível a oscilações de mercado e a perdas mais acentuadas em cenários adversos.

Por outro lado, a carteira construída com o auxílio de Inteligência Artificial, embora tenha apresentado um retorno absoluto inferior, destacou-se por sua maior resiliência e menor exposição ao risco. Os indicadores de risco para esta carteira foram consistentemente mais baixos, indicando uma capacidade superior da IA em construir portfólios mais diversificados e menos sensíveis a movimentos bruscos do mercado. A IA demonstrou habilidade em realizar uma análise multidimensional dos ativos, considerando um espectro mais amplo de variáveis e correlações, o que resultou em uma alocação mais conservadora, porém mais estável. Este comportamento é particularmente relevante em contextos de incerteza econômica, onde a preservação de capital e a minimização de perdas tornam-se prioritárias.

A análise comparativa dos desempenhos ao longo de diferentes períodos (2022 e 2023) também trouxe à luz a adaptabilidade de cada método. Observou-se que o desempenho de ambas as carteiras variou conforme as condições de mercado de cada ano, reforçando a ideia de que não existe uma estratégia universalmente ótima para todas as circunstâncias. A carteira tradicional, por exemplo, embora tenha performado bem em ambos os anos, mostrou uma queda em seus indicadores de eficiência (Sharpe e Sortino) em 2023 comparado a 2022, enquanto a carteira de IA, apesar de um retorno menor, manteve um perfil de risco mais controlado, embora também com variações em sua eficiência.

Diante do exposto, este estudo conclui que a escolha entre métodos tradicionais e Inteligência Artificial para alocação de ativos não se traduz em uma superioridade absoluta de uma abordagem sobre a outra, mas sim em um compromisso entre rentabilidade e risco. A metodologia tradicional pode ser mais adequada para investidores com maior apetite ao risco e foco em maximização de retornos, enquanto a IA surge como uma ferramenta poderosa para a construção de carteiras mais robustas e resilientes, ideais para perfis mais conservadores ou para momentos de maior instabilidade. Mais importante, os resultados sugerem que a convergência entre o conhecimento consolidado dos métodos tradicionais e as capacidades analíticas avançadas da Inteligência Artificial representa um caminho promissor para o futuro da gestão de investimentos. A combinação da intuição e experiência humana com o poder de processamento e identificação de padrões da IA pode levar a estratégias de alocação mais eficientes, adaptativas e personalizadas.

Como limitações deste estudo, aponta-se o horizonte temporal relativamente curto para a análise de desempenho das carteiras e a seleção específica de ativos e algoritmos de IA, que podem não representar a totalidade das possibilidades existentes. Sugere-se, para pesquisas futuras, a ampliação do período de análise, a inclusão de uma gama maior e mais diversificada de ativos (incluindo outras classes, como renda fixa e ativos internacionais), bem como a exploração de diferentes arquiteturas e técnicas de Inteligência Artificial, como redes neurais profundas, técnicas sofisticadas de *machine learning*, modelos de previsão baseados em séries temporais e análise de sentimentos de mercado.

Em suma, a presente pesquisa contribui para o debate acadêmico e prático sobre alocação de ativos ao fornecer uma análise comparativa detalhada e evidências empíricas sobre o desempenho de métodos tradicionais e de Inteligência Artificial. Espera-se que os achados aqui apresentados possam auxiliar investidores, gestores de portfólio e pesquisadores na tomada de decisões mais informadas e na busca por estratégias de investimento cada vez mais sofisticadas e alinhadas aos seus objetivos e perfis de risco.

6 REFERÊNCIAS

ABDUL KAREEM, A. A. et al. Factors Influencing Investment Decisions in Financial Investment Companies. **Systems**, v. 11, n. 3, 1 mar. 2023.

ADEBIYI, S. O.; OGUNBIYI, O. O.; AMOLE, B. B. Artificial intelligence model for building investment portfolio optimization mix using historical stock prices data. **Rajagiri Management Journal**, v. 16, n. 1, p. 36–62, 11 abr. 2022.

AHMED, S. et al. Artificial intelligence and machine learning in finance: A bibliometric review. **Research in International Business and Finance**, v. 61, p. 101646, 1 out. 2022.

ALIPOUR, H.; PENDAR, N.; ROY, K. CHATGPT Alternative Solutions: Large Language Models Survey. p. 153–173, 2024.

ALONSO, M. N. I; SRIVASTAVA, S. Deep Reinforcement Learning for Asset Allocation in US Equities. **SSRN Electronic Journal**, 9 out. 2020.

AMBIMA. Cresce número de investidores brasileiros em 2022 e perspectiva para 2023 é de novo aumento – ANBIMA. Disponível em: <https://www.anbima.com.br/pt_br/noticias/cresce-numero-de-investidores-brasileiros-em-2022-e-perspectiva-para-2023-e-de-novo-aumento.htm>. Acesso em: 21 out. 2023.

ANÁLISE DE AÇÕES. O que é Índice Brasil 50? | Análise de Ações. Disponível em: <<https://www.analisedeacoes.com/dicionario/i/indice-brasil-50/>>. Acesso em: 5 maio. 2025.

ANG, A. Factor Investing. **SSRN Electronic Journal**, 2013.

ARIAS, F.; CUNHA, F. D. S.; SAMANEZ, C. P. Análise de desempenho dos investimentos sustentáveis no mercado acionário brasileiro. n. 2, p. 420–434, 2014.

ASNESS, C. S.; FRAZZINI, A.; PEDERSEN, L. H. **Quality Minus Junk**. [s.l: s.n.]. Disponível em: <<http://www.stern.nyu.edu/~lpederse/Wethank>>.

AUGUSTO, F. **Árvores de decisão e florestas aleatórias**. Disponível em: <<https://medium.com/oiluna/%C3%A1rvores-de-decis%C3%A3o-e-florestas-aleat%C3%B3rias-3894bfa5e8ff>>. Acesso em: 5 maio. 2025.

BAKER, N. L.; HAUGEN, R. A. Low Risk Stocks Outperform within All Observable Markets of the World. **SSRN Electronic Journal**, 27 abr. 2012.

BCB. **Relatório de Economia Bancária 2023**. [s.l: s.n.]. Disponível em: <<http://www.bcb.gov.br/?ATENDIMENTO>>.

BENDER, E. M. et al. On the dangers of stochastic parrots: Can language models be too big? **FACCT 2021 - Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency**, p. 610–623, 3 mar. 2021.

BLITZ, D.; VIDOJEVIC, M. The Characteristics of Factor Investing. **The Journal of Portfolio Management**, v. 45, n. 3, p. 69–86, 28 fev. 2019.

BODIE, Z.; KANE, A.; MARCUS, A. J. **Investments**. 10. ed. Penn Plaza: McGraw-Hill Education, 2014.

BOREIKO, D.; MASSAROTTI, F. How Risk Profiles of Investors Affect Robo-Advised Portfolios. **Frontiers in Artificial Intelligence**, v. 3, 18 set. 2020.

BOUCHAUD, J.-P. et al. The Excess Returns of “Quality” Stocks: A Behavioral Anomaly. **SSRN Electronic Journal**, 18 jan. 2016.

CARDOSO, R. T. N. et al. Analysis of risk measures in multiobjective optimization portfolios with cardinality constraint. **Brazilian Review of Finance**, v. 17, n. 3, p. 26–46, 15 out. 2019.

CHOPRA, R.; SHARMA, G. D. Application of Artificial Intelligence in Stock Market Forecasting: A Critique, Review, and Research Agenda. **Journal of Risk and Financial Management**, v. 14, n. 11, p. 526, 4 nov. 2021.

CLARKE, R. G.; DE SILVA, H.; THORLEY, S. Minimum-Variance Portfolios in the U.S. Equity Market. **The Journal of Portfolio Management**, v. 33, n. 1, p. 10–24, 31 out. 2006.

DAMODARAN, A. **Investment Valuation**. 3. ed. Hoboken: John Wiley & Sons, 2012.

DANIELSSON, J.; UTHEMANN, A. On the use of artificial intelligence in financial regulations and the impact on financial stability *. **SSRN Electronic Journal**, 5 jun. 2024.

DENG, X. et al. What do LLMs Know about Financial Markets? A Case Study on Reddit Market Sentiment Analysis. **ACM Web Conference 2023 - Companion of the World Wide Web Conference, WWW 2023**, p. 107–110, 21 dez. 2022.

DOLPHIN, R. et al. Extracting Structured Insights from Financial News: An Augmented LLM Driven Approach. **Proceedings of International Conference on AI in Finance (ICAIF '24)**, v. 1, 22 jul. 2024.

DUARTE, T. P. **Avaliação da quantidade mínima de ativos para um portfólio diversificado aplicado ao mercado brasileiro**. Belo Horizonte: Universidade Federal de Minas Gerais, 5 ago. 2024. Disponível em: <<https://repositorio.ufmg.br/handle/1843/76635>>. Acesso em: 9 mar. 2025.

FAMA, E. F.; FRENCH, K. R. The Cross-Section of Expected Stock Returns. **The Journal of Finance**, v. 47, n. 2, p. 427, jun. 1992.

FARNESCHLÄDER, T. **Alucinações de IA: Um guia com exemplos | DataCamp**. Disponível em: <https://www.datacamp.com/pt/blog/ai-hallucination?utm_source>. Acesso em: 15 mar. 2025.

FERREIRA, E. DA C.; COSTA, S. R. R. DA. A utilização do Índice de Sharpe como ferramenta para comparação de risco/retorno em fundos de investimento. **Revista ESPACIOS | Vol. 37 (Nº 15) Año 2016**, 5 jun. 2016.

FERREIRA, F. C. **Alucinações em Modelos de Linguagem de Grande Escala (LLMs) - FelipeCFerreira IANews.** Disponível em: <https://news.felipecferreira.com.br/alucinacoes-em-llms/?utm_source=>. Acesso em: 15 mar. 2025.

FREITAS, D. DE C.; REIS, D. L. Educação financeira por meio de uma plataforma interativa de investimento: a aplicabilidade da inteligência artificial (IA): Financial education through an interactive investment platform: the applicability of artificial intelligence (IA). **Brazilian Journal of Development**, v. 8, n. 11, p. 75525–75545, 29 nov. 2022.

GAIO, L. E.; PIMENTA JÚNIOR, T. Value-at-Risk da Carteira do Ibovespa: uma análise com o uso de modelos de memória longa. **Gestão & Produção**, v. 19, n. 4, p. 779–792, dez. 2012.

GIL, A. C. **Como elaborar projetos de pesquisa.** 6^a ed. São Paulo: Atlas, 2017.

GLOVER, E. **Strong AI vs. Weak AI: What's the Difference? | Built In.** Disponível em: <<https://builtin.com/artificial-intelligence/strong-ai-weak-ai>>. Acesso em: 2 maio. 2025.

GRUBER, M.; BROWN, S.; GOETZMANN, W. **Moderna teoria de carteiras e análise de investimentos.** 1^a ed. Brasil: Elsevier Brasil, 2012.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems.** [s.l.] The MIT Press, 1992.

Inteligência artificial no setor financeiro | YTecnologia. Disponível em: <https://ytecnologia.com/blog/inteligencia-artificial-no-setor-financeiro/?utm_source=chatgpt.com>. Acesso em: 2 maio. 2025.

JEGADEESH, N.; TITMAN, S. Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. **The Journal of Finance**, v. 48, n. 1, p. 65, mar. 1993a.

JEGADEESH, N.; TITMAN, S. Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. **The Journal of Finance**, v. 48, n. 1, p. 65–91, 30 mar. 1993b.

JIANG, J. et al. A Survey on Large Language Models for Code Generation. 1 jun. 2024.

JORION, PHILIPPE. **Value at Risk: The New Benchmark for Managing Financial Risk**. 3. ed. New York: [s.n.].

KHURANA, D. et al. Natural language processing: state of the art, current trends and challenges. **Multimedia Tools and Applications**, v. 82, n. 3, p. 3713–3744, 1 jan. 2023.

KIM, K. Financial time series forecasting using support vector machines. **Neurocomputing**, v. 55, n. 1–2, p. 307–319, set. 2003.

LAKONISHOK, J.; SHLEIFER, A.; VISHNY, R. W. Contrarian Investment, Extrapolation, and Risk. **The Journal of Finance**, v. 49, n. 5, p. 1541–1578, 1994.

LEE, D. K. C. ; et al. A Comprehensive Review of Generative AI in Finance. **FinTech 2024, Vol. 3, Pages 460-478**, v. 3, n. 3, p. 460–478, 20 set. 2024.

LO, A. W.; CRAIG, A. **A Non-Random Walk Down Wall Street**. Princeton: Princeton University Press, 1999.

LORD, M. University Endowment Committees, Modern Portfolio Theory and Performance. **Journal of Risk and Financial Management**, v. 13, n. 9, 1 set. 2020.

LU, F.; HUANG, L.; LI, S. ChatGPT, Generative AI, and Investment Advisory. **SSRN Electronic Journal**, 2023.

MA, Y.; HAN, R.; WANG, W. Portfolio optimization with return prediction using deep learning and machine learning. **Expert Systems with Applications**, v. 165, 1 mar. 2021.

MARKOWITZ, H. M. The Early History of Portfolio Theory: 1600–1960. **Financial Analysts Journal**, v. 55, n. 4, p. 5–16, 2 jul. 1999.

MARTINS, B. C. **Melhores Práticas em Planejamento Urbano e Regional**. Brasil: Atena Editora, 2019.

MATHEUS, R. **Inteligência Artificial e Reconhecimento de Padrões: Transformando Dados em Decisões Estratégicas**. Disponível em: <<https://rodrigomatheus.com.br/inteligencia-artificial-e-reconhecimento-de-padroes-transformando-dados-em-decisoos-estrategicas/>>. Acesso em: 2 maio. 2025.

MIRANDA, P. B. D. **Estratégias de Gestão de Carteiras de Investimento no Mercado Brasileiro**. Dissertação (Mestrado Profissional em Matemática em Rede Nacional)—Curitiba: Universidade Tecnológica Federal do Paraná. <https://repositorio.utfpr.edu.br/jspui/handle/1/24662>, 19 fev. 2021.

MWANGI, J. M.; IRUNGU, A.; MUTWIRI, N. Firm-Specific Factors and Performance of Commercial Banks in Kenya. **International Journal of Innovative Research and Development**, 31 out. 2022.

O impacto da inteligência artificial no setor financeiro - ABE. Disponível em: <https://www.abe.com.br/o-impacto-da-inteligencia-artificial-no-setor-financeiro/?utm_source=chatgpt.com>. Acesso em: 2 maio. 2025.

PAVÃO, E. A. F. **Inteligência Artificial aplicada ao Mercado Financeiro**. [s.l.] AYA Editora, 2024.

PESSANHA, G. R. G.; VIEIRA, A. G.; BRANDÃO, W. C. Large Language Models (LLMs): A systematic study in Administration and Business. **RAM. Revista de Administração Mackenzie**, v. 25, n. 6, 2024.

PETROVNA, K. N. et al. Institutional Investors in the Green Transformation of Modern Financial Markets. **Financial Engineering and Risk Management**, v. 5, n. 7, p. 114–119, 23 dez. 2022.

PREDEBON, E. A. et al. Estimativa do Risco e Retorno de Uma Carteira de Investimentos Financeiros a Partir de Planilha Eletrônica. n. 2, p. 63–86, 2010.

QIAN, X.-Y. Financial Series Prediction: Comparison Between Precision of Time Series Models and Machine Learning Methods. 3 jun. 2017.

Raio-XP: Retrospectiva 2023 - O que movimentou mercados - XP Investimentos. Disponível em: <<https://conteudos.xpi.com.br/acoes/relatorios/raio-xp-retrospectiva-2023-o-que-movimentou-mercados/>>. Acesso em: 5 abr. 2025.

REHMAN, S. et al. Are Stock Prices a Random Walk? An Empirical Evidence of Asian Stock Markets. **ETIKONOMI**, v. 17, n. 2, 2018.

RIZÉRIO, L. **A linha do tempo que mostra como foi 2022 para a Bolsa brasileira – e o que esperar para o mercado em 2023.** Disponível em: <<https://www.infomoney.com.br/mercados/a-imagem-que-mostra-como-foi-2022-para-a-bolsa-brasileira-e-o-que-esperar-para-o-mercado-em-2023/>>. Acesso em: 5 maio. 2025.

ROLLINGER, T. N.; HOFFMAN, S. T. **Sortino: A “Sharper” Ratio.** Disponível em: <www.RedRockCapital.com>. Acesso em: 8 fev. 2025.

ROTBLUT, C. **Effectively Monitoring Your Portfolio | AAI.** Disponível em: <<https://www.aai.com/journal/article/14754-effectively-monitoring-your-portfolio?via=emailsignup-readmore>>. Acesso em: 21 out. 2023.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach.** 4. ed. [s.l.] Pearson, 2020.

SEGAL, T. **Fundamental Analysis: Principles, Types, and How to Use It.** Disponível em: <<https://www.investopedia.com/terms/f/fundamentalanalysis.asp>>. Acesso em: 21 out. 2023.

Setor de serviços financeiros brasileiro aposta na Inteligência Artificial para alcançar reinvenção, mostra PwC. Disponível em: <https://www.pwc.com.br/pt/sala-de-imprensa/release/setor-de-servicos-financeiros-brasileiro-aposta-na-inteligencia-aposta-na-inteligencia-artificial-para-alcancar-reinvencao.html?utm_source=chatgpt.com>. Acesso em: 2 maio. 2025.

SEZER, O. B.; GUDELEK, M. U.; OZBAYOGLU, A. M. Financial Time Series Forecasting with Deep Learning : A Systematic Literature Review: 2005-2019. **Applied Soft Computing Journal**, v. 90, 29 nov. 2019.

SHARPE, F. W. **The Sharpe Ratio.** Disponível em: <<https://web.stanford.edu/~wfs Sharpe/art/sr/sr.htm>>. Acesso em: 21 out. 2023.

SHEEHAN, M.; SINGER, S. **How DeepSeek's AI Model Changes U.S.-China Competition.** Disponível em: <<https://foreignpolicy.com/2025/02/03/deepseek-china-ai-artificial-intelligence-united-states-tech-competition/>>. Acesso em: 3 maio. 2025.

SINGH, G. Machine Learning Models in Stock Market Prediction. **International Journal of Innovative Technology and Exploring Engineering**, v. 11, n. 3, p. 18–28, 6 fev. 2022.

SINHA, A.; AGARWAL, C.; MALO, P. FinBloom: Knowledge Grounding Large Language Model with Real-time Financial Data. 4 fev. 2025.

SOUZA, J. C. F.; SANTOS, P. H.; ANDRADE, V. M. M. Uso do Value-at-Risk (VaR) para Mensuração de Risco em Fundos de Investimento de Renda Fixa a Partir do Modelo Deltanormal e Simulação de Monte Carlo. **Revista de Gestão, Finanças e Contabilidade**, v. 7, n. 1, 2017.

TA, V. D.; LIU, C. M.; TADESSE, D. A. Portfolio optimization-based stock prediction using long-short term memory network in quantitative trading. **Applied Sciences (Switzerland)**, v. 10, n. 2, 1 jan. 2020.

INVESTOPÉDIA. **Understanding the Sharpe Ratio**. Disponível em: <https://www.investopedia.com/articles/07/sharpe_ratio.asp>. Acesso em: 3 maio. 2025.

VIANA, L. **Política e Investimentos: como o cenário interfere na economia**. Disponível em: <<https://blog.inco.vc/mercado-financeiro/politica-e-investimentos/>>. Acesso em: 2 maio. 2025.

YOSHINAGA, C. E.; CASTRO, F. H. Inteligência artificial: a vanguarda das finanças. **GV-EXECUTIVO**, v. 22, n. 3, 15 ago. 2023.

ZAKARIA, S. The use of financial derivatives in measuring bank risk management efficiency: A data envelopment analysis approach. **Asian Academy of Management Journal**, v. 22, n. 2, p. 209–244, 2017.

ZANINI, F. A. M.; FIGUEIREDO, A. C. As Teorias de Carteiras 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, jun. 2005.

ZHU, H. et al. Forecasting Asset Dependencies to Reduce Portfolio Risk. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 36, n. 4, p. 4397–4404, 28 jun. 2022.

APÊNDICE A – SCRIPT DA METODOLOGIA TRADICIONAL

```

# Importando biblioteca e dados
import yfinance as yf
import pandas as pd
import numpy as np
import scipy.optimize as sco
import matplotlib.pyplot as plt

# Ações selecionadas
acoes = [
    'AALR3.SA', 'ABEV3.SA', 'AMAR3.SA', 'AMZO34.SA', 'ASAI3.SA', 'B3SA3.SA',
    'BAZA3.SA', 'BBAS3.SA', 'BBDC3.SA', 'BBDC4.SA', 'BBSE3.SA', 'BRFS3.SA',
    'BRKM5.SA', 'CPFE3.SA', 'CSNA3.SA', 'CURY3.SA', 'CYRE3.SA', 'EQPA3.SA',
    'EZTC3.SA', 'GGBR4.SA', 'HTMX11.SA', 'HYPE3.SA', 'IRBR3.SA', 'ITUB4.SA',
    'KEPL3.SA', 'KLBN11.SA', 'LOGN3.SA', 'LREN3.SA', 'MDIA3.SA', 'MGLU3.SA',
    'MILS3.SA', 'MRFG3.SA', 'MRVE3.SA', 'NTCO3.SA', 'PCAR3.SA', 'PETR3.SA',
    'PETR4.SA', 'PRIO3.SA', 'PSSA3.SA', 'QBTC11.SA', 'RADL3.SA', 'RECV3.SA',
    'SANB11.SA', 'SBSP3.SA', 'SUZB3.SA', 'TAEE11.SA', 'TASA4.SA', 'USIM5.SA',
    'VSTE3.SA', 'VULC3.SA'
]

# Preço de fechamento para 2022 e 2023
def preco_fechamento(acoes, start_date, end_date):
    dados = yf.download(acoes, start=start_date, end=end_date, interval='1d')['Close']
    return dados

# Obtendo preços de fechamento para 2022 e 2023
precos_fechamento_completo = preco_fechamento(acoes, start_date='2022-01-01', end_date='2024-01-01')
precos_fechamento_2022 = precos_fechamento_completo[(precos_fechamento_completo.index >= '2022-01-01') & (precos_fechamento_completo.index <= '2022-12-31')]
precos_fechamento_2023 = precos_fechamento_completo[(precos_fechamento_completo.index >= '2023-01-01') & (precos_fechamento_completo.index <= '2024-01-01')]

print("Preços de fechamento para o ano de 2022:")
print(precos_fechamento_2022)

print("\nPreços de fechamento para o ano de 2023:")
print(precos_fechamento_2023)

## Factor Investing
# Dados financeiros das ações
fundamentais = {}
for acao in acoes:
    try:

```

Fonte: Elaboração própria (2025).

```

ticker = yf.Ticker(acao)
dados = ticker.info
fundamentais[acao] = {
    'P/L': dados.get('trailingPE', None),
    'P/VPA': dados.get('priceToBook', None),
    'ROE': dados.get('returnOnEquity', None)
}
except Exception as e:
    print(f"Erro ao obter dados para {acao}: {e}")

# Criando DataFrame com os dados fundamentais
df_fundamentais = pd.DataFrame(fundamentais).T

# Calcular momentum (retorno dos últimos 12 meses do ano de 2022)
if len(precos_fechamento_2022) > 0:
    # Cálculo do momentum utilize apenas os dados de 2022
    retorno_12m_2022 = precos_fechamento_2022.pct_change(
        periods=min(len(precos_fechamento_2022) - 1, 252)).iloc[-1]
    df_fundamentais['Momentum'] = retorno_12m_2022
else:
    df_fundamentais['Momentum'] = None

# Garantindo que as colunas sejam numéricas
df_fundamentais['P/L'] = pd.to_numeric(df_fundamentais['P/L'], errors='coerce')
df_fundamentais['P/VPA'] = pd.to_numeric(df_fundamentais['P/VPA'], errors='coerce')
df_fundamentais['ROE'] = pd.to_numeric(df_fundamentais['ROE'], errors='coerce')

# Substituir os NaN pela média de cada coluna
df_fundamentais['P/L'] = df_fundamentais['P/L'].fillna(df_fundamentais['P/L'].mean())
df_fundamentais['P/VPA'] = df_fundamentais['P/VPA'].fillna(df_fundamentais['P/VPA'].mean())
df_fundamentais['ROE'] = df_fundamentais['ROE'].fillna(df_fundamentais['ROE'].mean())

# Normalizando os fatores e rankear os ativos
df_fundamentais['Rank_Valor'] = df_fundamentais[['P/L', 'P/VPA']].rank(ascending=True).mean(axis=1)
df_fundamentais['Rank_Qualidade'] =
df_fundamentais['ROE'].rank(ascending=False)
df_fundamentais['Rank_Momentum'] = df_fundamentais['Momentum'].rank(ascending=False)

# Combinar os rankings
peso_valor = 0.4
peso_qualidade = 0.3
peso_momentum = 0.3
df_fundamentais['Score Final'] = (
    df_fundamentais['Rank_Valor'] * peso_valor +
    df_fundamentais['Rank_Qualidade'] * peso_qualidade +

```

Fonte: Elaboração própria (2025).

```

df_fundamentais['Rank_Momentum'] * peso_momentum
)

# Exibição dos resultados para todas as ações de 2022
print("Resultados do Factor Investing para todas as ações de 2022:")
print(df_fundamentais.sort_values(by='Score_Final'))

### Seleção de Carteira com Markowitz com dados de 2022
# Seleção das 20 melhores ações com base no score final
melhores_acoes = df_fundamentais.sort_values(by='Score_Final').index[:20]

# Filtrando os preços das melhores ações
melhor_score_2022 = precos_fechamento_2022[melhores_acoes]

# Calculando os retornos logarítmicos
retornos_2022 = np.log(melhor_score_2022 / melhor_score_2022.shift(1)).dropna()

# Calculando matriz de covariância
cov_matrix_2022 = retornos_2022.cov()

# Função de minimização do risco
def portfolio_volatilidade(pesos, cov_matrix):
    return np.sqrt(np.dot(pesos.T, np.dot(cov_matrix, pesos)))

# Restrições e limites
peso_minimo = 0.01
peso_maximo = 0.30

num_acoes = len(melhores_acoes)
pesos_iniciais = np.ones(num_acoes) / num_acoes
limites = tuple((peso_minimo, peso_maximo) for _ in range(num_acoes))
restricao = ({'type': 'eq', 'fun': lambda x: np.sum(x) - 1})

# Otimização para encontrar a alocação de menor risco
resultado_markowitz = sco.minimize(portfolio_volatilidade, pesos_iniciais,
    args=(cov_matrix_2022,),
    method='SLSQP', bounds=limites, constraints=restricao)

# Exibe os resultados da carteira criada pelo método de Markowitz com dados de 2022
print("Ranking das Melhores Ações Seleccionadas para a Carteira de Markowitz:\n")
print(f"{'Ranking':<10} {'Nome da Ação'}")
print("-" * 30)

# Exibe o ranking numerado
for i, acao in enumerate(melhores_acoes, 1):
    print(f"{'i':<10} {acao}")

```

Fonte: Elaboração própria (2025).

```

# Exibindo a alocação ótima
print("Alocação ótima das ações na carteira:")
print(pd.Series(resultado_markowitz.x, index=melhores_acoes))

# === Cálculo dos indicadores para 2022 === #

# Filtrando os preços das melhores ações para 2022
melhor_score_2022 = precos_fechamento_2022[melhores_acoes]

# Calculando os retornos logarítmicos diários para 2022
retornos_2022 = np.log(melhor_score_2022 / melhor_score_2022.shift(1)).dropna()

# Calculando os retornos diários ponderados pela alocação ótima
retornos_diarios_portfolio_2022 = (retornos_2022 * resultado_markowitz.x).sum(axis=1)

# Retorno acumulado da carteira em 2022
retorno_acumulado_2022 = np.exp(retornos_diarios_portfolio_2022.cumsum()) - 1

# Cálculo do retorno e volatilidade anualizados
retorno_anualizado_2022 = retornos_diarios_portfolio_2022.mean() * 252
volatilidade_anualizada_2022 = retornos_diarios_portfolio_2022.std() * np.sqrt(252)

# Índice de Sharpe (taxa livre de risco = 13,75%)
taxa_selic_ano_2022 = 0.1375
sharpe_ratio_2022 = (retorno_anualizado_2022 - taxa_selic_ano_2022) / volatilidade_anualizada_2022

# Índice de Sortino
retornos_negativos_2022 = retornos_diarios_portfolio_2022[retornos_diarios_portfolio_2022 < 0]
volatilidade_negativa_2022 = retornos_negativos_2022.std() * np.sqrt(252)
sortino_ratio_2022 = (retorno_anualizado_2022 - taxa_selic_ano_2022) / volatilidade_negativa_2022

# VaR 95% (valor da carteira = R$ 1.000.000)
valor_carteira = 1_000_000
desvio_padrao_anualizado_2022 = retornos_diarios_portfolio_2022.std() * np.sqrt(252)
percentil_95 = 1.65
VaR_95_2022 = valor_carteira * desvio_padrao_anualizado_2022 * percentil_95

# Converter retorno acumulado para percentual
retorno_acumulado_percentual = retorno_acumulado_2022 * 100

# Plot do retorno acumulado
plt.figure(figsize=(12, 6))
plt.plot(retorno_acumulado_percentual, label='Retorno Acumulado da Carteira (%)', color='blue')
plt.xlabel('Data', fontsize=12)
plt.ylabel('Retorno Acumulado (%)', fontsize=12)
plt.legend(fontsize=12)
plt.tick_params(axis='both', labelsize=10) # Eixos x e y
plt.show()

```

Fonte: Elaboração própria (2025).

```

# Exibindo resultados
print(f"Retorno anualizado da carteira (2022): {retorno_anualizado_2022:.4f}")
print(f"Volatilidade anualizada da carteira (2022): {volatilidade_anualizada_2022:.4f}")
print(f"Índice de Sharpe (2022): {sharpe_ratio_2022:.4f}")
print(f"Índice de Sortino (2022): {sortino_ratio_2022:.4f}")
print(f"VaR a 95% (2022): R${VaR_95_2022:,.2f}")

# Tabela resumida
resultados_2022 = pd.DataFrame({
    'Indicador': ['Retorno Anualizado', 'Volatilidade Anualizada', 'Índice de Sharpe', 'Índice de Sortino', 'VaR (95%)'],
    'Valor': [retorno_anualizado_2022, volatilidade_anualizada_2022, sharpe_ratio_2022, sortino_ratio_2022, VaR_95_2022]
})
print("\nResumo dos Indicadores de 2022:")
print(resultados_2022)

# === Cálculo dos indicadores para 2023 ===

# Filtrando os preços das melhores ações para 2023
melhor_score_2023 = precos_fechamento_2023[melhores_acoes]
# Calculando os retornos logarítmicos diários para 2023
retornos_2023 = np.log(melhor_score_2023 / melhor_score_2023.shift(1)).dropna()
# Calculando os retornos diários ponderados pela alocação ótima
retornos_diarios_portfolio_2023 = (retornos_2023 * resultado_markowitz.x).sum(axis=1)

# Retorno acumulado da carteira em 2023
retorno_acumulado_2023 = np.exp(retornos_diarios_portfolio_2023.cumsum()) - 1

# Cálculo do retorno e volatilidade anualizados
retorno_anualizado_2023 = retornos_diarios_portfolio_2023.mean() * 252
volatilidade_anualizada_2023 = retornos_diarios_portfolio_2023.std() * np.sqrt(252)

# Índice de Sharpe (taxa livre de risco = 12,25%)
taxa_selic_ano_2023 = 0.1225
sharpe_ratio_2023 = (retorno_anualizado_2023 - taxa_selic_ano_2023) / volatilidade_anualizada_2023

# Índice de Sortino
retornos_negativos_2023 = retornos_diarios_portfolio_2023[retornos_diarios_portfolio_2023 < 0]
volatilidade_negativa_2023 = retornos_negativos_2023.std() * np.sqrt(252)
sortino_ratio_2023 = (retorno_anualizado_2023 - taxa_selic_ano_2023) / volatilidade_negativa_2023

# VaR 95% (valor da carteira = R$ 1.000.000)
valor_carteira = 1_000_000
desvio_padrao_anualizado_2023 = retornos_diarios_portfolio_2023.std() * np.sqrt(252)
percentil_95 = 1.65

```

Fonte: Elaboração própria (2025).

```
VaR_95_2023 = valor_carteira * desvio_padrao_anualizado_2023 * percentil_95
```

```
# Converter retorno acumulado para percentual
```

```
retorno_acumulado_percentual_2023 = retorno_acumulado_2023 * 100
```

```
# Plot do retorno acumulado em percentual com fonte tamanho 10
```

```
plt.figure(figsize=(12, 6))
```

```
plt.plot(retorno_acumulado_percentual_2023, label='Retorno Acumulado da Carteira (%)', color='blue')
```

```
plt.xlabel('Data', fontsize=12)
```

```
plt.ylabel('Retorno Acumulado (%)', fontsize=12)
```

```
plt.legend(fontsize=12)
```

```
plt.tick_params(axis='both', labelsize=10) # Eixos x e y
```

```
plt.show()
```

```
# Exibindo resultados
```

```
print(f'Retorno anualizado da carteira (2023): {retorno_anualizado_2023:.4f}')
```

```
print(f'Volatilidade anualizada da carteira (2023): {volatilidade_anualizada_2023:.4f}')
```

```
print(f'Índice de Sharpe (2023): {sharpe_ratio_2023:.4f}')
```

```
print(f'Índice de Sortino (2023): {sortino_ratio_2023:.4f}')
```

```
print(f'VaR a 95% (2023): R${VaR_95_2023:,.2f}')
```

```
# Tabela resumida
```

```
resultados_2023 = pd.DataFrame({
```

```
    'Indicador': ['Retorno Anualizado', 'Volatilidade Anualizada', 'Índice de Sharpe', 'Índice de Sortino', 'VaR (95%)'],
```

```
    'Valor': [retorno_anualizado_2023, volatilidade_anualizada_2023, sharpe_ratio_2023, sortino_ratio_2023, VaR_95_2023]
```

```
})
```

```
print("\nResumo dos Indicadores de 2023:")
```

```
print(resultados_2023)
```

```
# Volatilidade acumulada (rolling window de 21 dias)
```

```
volatilidade_rolling_2023 = retornos_diarios_portfolio_2023.rolling(window=21).std() * np.sqrt(252)
```

```
# Converter para porcentagem
```

```
volatilidade_rolling_2023_pct = volatilidade_rolling_2023 * 100
```

```
# Plot da volatilidade acumulada com fonte tamanho 10 e em porcentagem
```

```
plt.figure(figsize=(12, 6))
```

```
plt.plot(volatilidade_rolling_2023_pct, label='Volatilidade Acumulada (%)', color='red')
```

```
plt.xlabel('Data', fontsize=12)
```

```
plt.ylabel('Volatilidade Acumulada (%)', fontsize=12)
```

```
plt.legend(fontsize=12)
```

```
plt.tick_params(axis='both', labelsize=12)
```

```
plt.grid(False)
```

```
plt.show()
```

Fonte: Elaboração própria (2025).

APÊNDICE B – PROMPT DA INTELIGÊNCIA ARTIFICIAL

Prompt

1. Você é uma gestora de carteiras de investimento e seu objetivo é criar uma carteira diversificada e eficiente. Para isso, você analisará os dados históricos e construirá uma carteira de investimentos composta por 20 ativos da bolsa de valores do Brasil (B3), utilizando apenas os dados disponíveis entre 1º de janeiro de 2022 e 31 de dezembro de 2022. Sua meta é maximizar o retorno esperado ajustado ao risco, aplicando uma metodologia rigorosa, replicável e documentada.
2. Regras e Restrições:
 - a) Seleção de Ativos:
 - Escolha 20 ativos da bolsa de valores do Brasil (B3) com base nos dados reais disponíveis exclusivamente no ano de 2022.
 - Você pode selecionar ações, ETFs, títulos ou outros instrumentos financeiros.
 - Justifique a seleção de cada ativo com base em critérios como liquidez, desempenho histórico, setor de atuação e correlação com outros ativos.
 - b) Alocação de Pesos:
 - Defina a alocação percentual de cada ativo na carteira
 - Utilize métodos quantitativos, como otimização de média-variância (Markowitz), maximização do índice de Sharpe ou outras técnicas de otimização de portfólio
 - Justifique as alocações com base em critérios financeiros sólidos, considerando fatores como desempenho histórico, retorno esperado, volatilidade, correlação e risco sistemático.
 - c) Análise de Desempenho e Risco:
 - Utilize métricas relevantes, como retorno acumulado, volatilidade acumulada, índice de Sharpe, Índice de Sortino, VaR para avaliar o desempenho e o risco da carteira com os dados de 2022.
 - Justifique as métricas utilizadas.
 - d) Teste em 2023:
 - Após construir a carteira, avalie seu desempenho e risco com os dados reais de 2023.
 - Os dados de 2023 não podem ser utilizados para selecionar ativos ou definir

Fonte: Elaboração própria (2025).

alocações, apenas para validar a metodologia.

- Analise o desempenho da carteira em 2023, comparando com os resultados esperados em 2022

3. Metodologia Replicável:

a) Fontes de dados utilizadas:

- Liste todas as fontes de dados utilizadas.
- Descreva como os dados foram tratados.

b) Critério na seleção de ativos:

- Descreva os critérios utilizados para selecionar os 20 ativos.
- Inclua uma análise qualitativa e quantitativa para justificar a escolha de cada ativo.

c) Processo de Alocação e Otimização:

- Explique o método de otimização utilizado.
- Descreva como os pesos foram calculados e ajustados.

d) Avaliação de Desempenho e Risco:

- Apresente as métricas de desempenho e risco calculadas para a carteira.
- Compare a carteira com benchmarks relevantes.
- Inclua gráficos e tabelas para ilustrar os resultados

e) Validação em 2023:

- Apresente os resultados da carteira em 2023, comparando com as previsões feitas em 2022.
- Análise possíveis desvios e suas causas.
- Sugira melhorias para a metodologia com base nos resultados observados.

4. Formato da Resposta

a) A resposta deve ser estruturada da seguinte forma:

- Introdução: Contextualize o estudo e apresente os objetivos.
- Metodologia: Descreva as etapas do processo, incluindo seleção de ativos, alocação e otimização.
- Resultados (2022): Apresente as métricas de desempenho e risco da carteira.
- Validação (2023): Analise o desempenho da carteira em 2023.

Fonte: Elaboração própria (2025).

- Conclusão e Sugestões: Conclua o estudo e proponha melhorias para futuras análises.
- Detalhamento da Seleção de Ativos: Inclua uma tabela com os 20 ativos selecionados, seus setores, retornos históricos, volatilidades e correlações.
- Detalhamento da Otimização: Mostre a fronteira eficiente e explique como os pesos foram calculados.
- Análise de Cenários: Inclua gráficos e tabelas comparando o desempenho da carteira em diferentes cenários macroeconômicos.

Fonte: Elaboração própria (2025).