



**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO**

**A Inteligência Artificial na Gestão de Fundos  
de Investimento**

Uma análise sobre os impactos do uso de IA e Machine Learning na performance e mitigação de riscos no mercado brasileiro

**Antônio Tovar Evangelista**

**TRABALHO DE CONCLUSÃO DE CURSO**

**CENTRO DE CIÊNCIAS SOCIAIS - CCS**

**DEPARTAMENTO DE ADMINISTRAÇÃO**

Graduação em Administração de Empresas

Rio de Janeiro, dezembro de 2025



**Antônio Tovar Evangelista**

**A Inteligência Artificial na Gestão de Fundos de  
Investimento**

**Uma análise sobre os impactos do uso de IA e Machine Learning na  
performance e mitigação de riscos no mercado brasileiro**

**Trabalho de Conclusão de Curso**

Trabalho de Conclusão de Curso, apresentado ao curso de graduação em Administração da PUC-Rio como requisito parcial para a obtenção do título de bacharel em Administração.

Orientador: André Cabús Klötzle

Rio de Janeiro  
Dezembro de 2025

## Resumo

Tovar, Antônio. A Inteligência Artificial na Gestão de Fundos de Investimento: Uma análise sobre os impactos do uso de IA e Machine Learning na performance e mitigação de riscos no mercado brasileiro. Rio de Janeiro, 2025. 46p. Trabalho de Conclusão de Curso – Departamento de Administração. Pontifícia Universidade Católica do Rio de Janeiro.

Este estudo analisa o impacto da Inteligência Artificial (IA) e do Machine Learning (ML) na performance e gestão de risco de fundos de investimento no Brasil. Com base em teorias clássicas e modelos quantitativos, a pesquisa compara dados históricos (2016-2025) de fundos que utilizam essas tecnologias com fundos tradicionais da mesma gestora. Utilizando métricas como Sharpe, Sortino e volatilidade, busca-se verificar se a IA proporciona vantagem real e sustentável. Os resultados devem contribuir tanto para o meio acadêmico quanto para investidores e gestores na tomada de decisão.

### Palavras-chave:

Inteligência Artificial; Machine Learning; Fundos de Investimento; Finanças Quantitativas; Avaliação de Performance; Gestão de Risco; Eficiência de Carteiras; Modelos Preditivos; Análise Comparativa; Indicadores de Rendimento (Sharpe, Sortino).

## Abstract

Tovar, Antônio. Artificial Intelligence in hedge fund management: An analysis of the impacts of using AI and Machine Learning on performance and risk mitigation in the Brazilian market. Rio de Janeiro, 2025. 46p. Trabalho de Conclusão de Curso – Departamento de Administração. Pontifícia Universidade Católica do Rio de Janeiro.

This study analyzes the impact of Artificial Intelligence (AI) and Machine Learning (ML) on the performance and risk management of investment funds in Brazil. Based on classical theories and quantitative models, the research compares historical data (2016–2025) from funds that use these technologies with traditional funds from the same asset managers. Using metrics such as Sharpe, Sortino, and volatility, the study aims to determine whether AI provides a real and sustainable advantage. The results are expected to contribute to both academic research and the decision-making processes of investors and fund managers.

### **Keywords:**

Artificial Intelligence; Machine Learning; Investment Funds; Quantitative Finance; Performance Evaluation; Risk Management; Portfolio Efficiency; Predictive Models; Comparative Analysis; Performance Indicators (Sharp, Sortino).

## Sumário

1 . O tema e o problema de estudo	1
1.1. Introdução ao tema e ao problema do estudo e sua contextualização	1
1.2. Objetivo do estudo	2
1.3. Objetivos intermediários e específicos do estudo	2
1.4. Delimitação e focalização do estudo	3
1.5. Justificativa e relevância do estudo e sua problematização	4
 2 . Referencial Teórico	 6
2.1. Finanças Tradicionais e Teoria de Portfolios	6
2.2. Finanças Quantitativas e Tecnologias Emergentes	8
2.3. Inteligência Artificial e Machine Learning	10
2.4. Aplicações Diretas de IA e ML na Gestão de Fundos de Investimento	12
2.5. Métricas de Avaliação de Performance e Risco	14
 3 . Metodologia	 18
3.1. Tipo de Pesquisa	18
3.1.1. Pesquisa Aplicada	18
3.1.2. Abordagem Quantitativa	19
3.1.3. Pesquisa Explicativa	19
3.1.4. Delineamento Teórico-Empírico	19
3.1.5. Pesquisa Comparativa	20
3.2. Abordagem Quantitativa e Justificativa	20
3.2.1. Fundamentação Epistemológica	20
3.2.2. Justificativa para a Escolha da Abordagem	21
3.3. População e Amostra	22
3.3.1. População	22
3.3.2. Critérios de Inclusão	23
3.3.3. Amostragem	23
3.3.4. Justificativa para a escolha da amostra	23
3.3.5. Limitações da Amostra	24
3.4. Análise dos Dados	24
3.4.1. Procedimentos estatísticos	25
3.4.2. Comparabilidade e controle de variáveis	25
3.4.3. Ferramentas e softwares utilizados	26
3.4.4. Análise dos resultados	26

3.5. Limitações da Pesquisa	26
3.5.1. Observação sobre os indicadores Sortino, Alfa e Beta	28
 4. Resultados	29
4.1. Objetivo da Análise de Resultados	29
4.1.1. Medir a performance ajustada ao risco	29
4.1.2. Comparar com benchmarks relevantes	30
4.1.3. Identificar padrões comportamentais dos fundos com IA/ML	30
4.1.4. Investigar consistência ao longo do tempo	30
4.1.5. Contribuir para a discussão acadêmica e prática	31
4.2. Abordagem Metodológica da Comparaçāo	31
4.3. Resultados dos testes	33
4.3.1. Fundos confirmados no estudo:	33
4.4. Apresentação e Discussão dos Resultados	36
4.5. Análise Crítica dos Resultados	37
 5. Conclusões	39
5.1. Principais Conclusões	39
5.2. Contribuições do Estudo	40
5.3. Limitações da Pesquisa	41
5.4. Possibilidades para Pesquisas Futuras	42
 6. Referências Bibliográficas	45

## **Lista de Gráficos**

<b>Gráfico 1:</b> Retorno Acumulado em 10 Anos .....	34
<b>Gráfico 2:</b> Índice de Sharpe .....	34
<b>Gráfico 3:</b> Volatilidade Anualizada .....	35
<b>Gráfico 4:</b> Drowdown Máximo .....	35

## 1. O tema e o problema de estudo

### 1.1. Introdução ao tema e ao problema do estudo e sua contextualização

Nas últimas décadas, o mercado financeiro tem vivenciado uma transformação estrutural impulsionada pelo avanço de tecnologias emergentes. Entre elas, destacam-se a inteligência artificial (IA) e o machine learning (ML), que têm sido progressivamente incorporados à gestão de fundos de investimento com o objetivo de aumentar a eficiência das análises, aprimorar a gestão de riscos e otimizar a tomada de decisões. Fundos quantitativos e modelos baseados em algoritmos têm se mostrado particularmente adeptos à adoção dessas tecnologias, que operam com base em grandes volumes de dados (big data), estatística aplicada e aprendizado adaptativo.

Diferentemente dos métodos tradicionais de gestão, que são baseados em interpretações subjetivas de indicadores macroeconômicos e fundamentos de empresas, os modelos de IA e ML permitem uma abordagem quantitativa, sistemática e automatizada. A promessa dessas ferramentas é entregar ganhos consistentes ao eliminar vieses humanos, detectar padrões que escapam à percepção tradicional e responder de forma rápida às mudanças do mercado.

No entanto, a adoção dessas tecnologias ainda suscita questionamentos importantes: até que ponto IA e ML estão, de fato, promovendo ganhos de performance em fundos de investimento? Há evidências concretas de que esses recursos superam as estratégias tradicionais? Ou estaríamos diante de uma tendência mais retórica do que efetiva?

Estudos internacionais sugerem que o uso dessas tecnologias pode reduzir a volatilidade das carteiras, melhorar os índices de Sharpe e aumentar a capacidade preditiva dos gestores. Em contrapartida, há desafios relevantes relacionados à transparência dos algoritmos, à compreensão dos riscos sistêmicos e à capacidade de explicar as decisões tomadas por modelos de caixa-preta (*black box models*). O Brasil segue essa tendência, ainda que de forma gradual. A partir de 2019, observa-se um aumento considerável no número de fundos que se apresentam como quantitativos ou baseados em algoritmos. Nesse

período, também cresceu a oferta de infraestrutura tecnológica e a disponibilidade de dados regulatórios e de mercado, impulsionando a viabilidade de aplicações de IA.

Assim, investigar a eficiência dessas ferramentas no contexto brasileiro não é apenas relevante, mas necessário para compreender as transformações em curso no setor financeiro e sua relação com a geração de valor aos investidores.

## **1.2. Objetivo do estudo**

Analizar como a utilização de IA e ML tem contribuído para melhorar o desempenho de fundos de investimento no Brasil, comparando seus resultados àqueles obtidos por fundos geridos por métodos tradicionais, com foco na eficiência, previsibilidade e capacidade de gestão de risco.

## **1.3. Objetivos intermediários e específicos do estudo**

**Construir uma base conceitual sólida sobre os modelos de IA mais recorrentes na gestão de ativos**, como redes neurais artificiais, árvores de decisão, algoritmos de classificação e regressão, modelos supervisionados e não supervisionados. Será considerada também a frequência de uso dessas tecnologias e seu nível de complexidade, com base em literatura especializada e dados do mercado.

**Identificar os fundos que incorporam essas tecnologias em seus processos decisórios:** Traçar um panorama do ecossistema brasileiro de fundos quantitativos, classificando-os quanto ao nível de automação (total, parcial ou assistida), tipo de estratégia (long/short, market neutral, macro, entre outros) e seu perfil de risco. Serão utilizados dados públicos da CVM, relatórios de gestoras e bases de dados setoriais para identificar os principais players que utilizam IA/ML.

**Compreender como essas ferramentas são aplicadas na prática na análise de dados, na formulação de estratégias e na gestão de risco:** Entender de forma detalhada o fluxo de trabalho envolvendo IA, desde a coleta e tratamento de dados até a execução automatizada de ordens. Também será abordada a atuação de equipes multidisciplinares (gestores, quants, engenheiros de dados) e os critérios de validação de modelos. Sempre que possível, incluir-se-á o estudo de casos reais de fundos que adotam essas tecnologias.

**Coletar dados de performance de fundos quantitativos e tradicionais entre 2016 e 2025:** Levantar dados históricos relevantes que permitam uma

comparação objetiva entre os dois grupos. Serão extraídas métricas como retorno absoluto, retorno anualizado, índice de Sharpe, índice de Sortino, drawdown máximo, volatilidade e tracking error. Os dados serão tratados estatisticamente para garantir comparabilidade e relevância.

**Realizar uma comparação crítica entre os resultados, avaliando a consistência da performance e a relação risco-retorno nos dois grupos analisados:** Interpretar os dados coletados com base em indicadores de desempenho ajustados ao risco, a fim de verificar se os fundos que usam IA/ML apresentam vantagens consistentes em relação aos fundos tradicionais. A análise buscará compreender se os ganhos são sustentáveis ao longo do tempo e sob diferentes condições de mercado, bem como identificar limitações ou efeitos colaterais da automação.

#### **1.4. Delimitação e focalização do estudo**

Este estudo está delimitado ao universo dos fundos de investimento regulados no Brasil, com foco especial naqueles classificados como multimercados e fundos de ações com gestão ativa. O período considerado para análise empírica será de 2016 a 2025, por ser um intervalo representativo do amadurecimento da adoção de tecnologias de IA e ML no setor financeiro nacional, além de incluir cenários econômicos diversos como pandemia, recuperação econômica e ciclos de política monetária restritiva.

O estudo irá comparar o desempenho de fundos que declaram utilizar IA/ML em seus processos decisórios com fundos tradicionais que utilizam modelos clássicos de análise fundamentalista ou técnica. Serão priorizados fundos com carteira pública, histórico de performance acessível e documentos oficiais que descrevam suas estratégias de gestão.

Além disso, serão exploradas as características técnicas dos algoritmos utilizados (quando disponíveis), os perfis de risco dos fundos analisados e a natureza dos dados empregados nos modelos preditivos. O recorte não incluirá fundos passivos ou ETFs, nem fundos exclusivamente voltados à renda fixa ou crédito privado, pois esses apresentam dinâmicas distintas de análise e alocação.

A abordagem será quantitativa, com ênfase na análise de dados históricos e na avaliação comparativa por meio de métricas consolidadas como retorno anualizado, volatilidade, drawdown e índices de risco-retorno. O foco não será na

modelagem algorítmica em si, mas nos efeitos observáveis da adoção de IA na performance dos fundos dentro do contexto regulado brasileiro.

### **1.5. Justificativa e relevância do estudo e sua problematização**

Apesar da crescente popularidade da inteligência artificial e do machine learning no setor financeiro, ainda há uma lacuna de conhecimento quanto à real eficácia dessas tecnologias na gestão de fundos de investimento. O entusiasmo gerado por essas inovações é frequentemente sustentado por expectativas teóricas e promessas de eficiência, mas faltam evidências empíricas que comprovem, de forma robusta, a superioridade dessas abordagens em relação aos métodos tradicionais.

A dúvida central que motiva este estudo reside justamente na complexidade de avaliar o valor agregado pela IA à performance de fundos. Muitos fundos que se dizem quantitativos ou baseados em algoritmos não deixam claro o grau de automação utilizado, a natureza dos modelos implementados ou o impacto real na gestão de riscos. Além disso, há o desafio de mensurar se os ganhos de performance ocorrem de maneira consistente ou apenas em períodos específicos de mercado, o que levanta questionamentos sobre a confiabilidade e a previsibilidade desses modelos.

Outro fator que aumenta a complexidade do problema é o contexto regulatório e tecnológico brasileiro, que ainda caminha para uma maior padronização e integração de dados. Isso torna a comparação entre fundos tradicionalmente geridos e fundos com IA ainda mais desafiadora, exigindo rigor metodológico e atenção à seleção das métricas de avaliação.

A relevância do estudo se manifesta nos seguintes âmbitos:

- **Para os gestores de fundos:** oferecer uma base empírica para orientar decisões sobre a adoção (ou não) de soluções baseadas em IA, ponderando custo, benefício e risco.
- **Para investidores individuais e institucionais:** contribuir para a tomada de decisão mais consciente ao esclarecer os reais impactos dessas tecnologias sobre a rentabilidade e o risco das carteiras.

- **Para o meio acadêmico:** aprofundar a discussão sobre finanças computacionais, aprendizado de máquina e sua integração à teoria da alocação de ativos.
- **Para reguladores e formuladores de políticas públicas:** servir como subsídio para a elaboração de normativas que garantam maior transparência, governança algorítmica e segurança nos processos automatizados de decisão.

Portanto, este estudo busca suprir uma necessidade concreta de compreensão crítica e embasada sobre o papel da inteligência artificial e do machine learning na construção de valor no mercado de fundos de investimento.

## 2. Referencial Teórico

Nesta seção serão abordados os principais conceitos que embasam a análise da aplicação de Inteligência Artificial (IA) e Machine Learning (ML) na gestão de fundos de investimento, com ênfase nas suas relações com performance, mitigação de riscos e eficiência de portfólio. O objetivo é estabelecer uma base conceitual sólida a partir da literatura acadêmica e prática para compreender os elementos críticos envolvidos no tema.

A seguir serão aprofundados os conceitos de: **(i)** Finanças tradicionais e teoria de portfólios; **(ii)** Finanças quantitativas e tecnologias emergentes; **(iii)** Inteligência Artificial e Machine Learning; **(iv)** Aplicações de IA/ML na gestão de investimentos; **(v)** Métricas de avaliação de performance e risco; e **(vi)** Estudos empíricos recentes e lacunas identificadas.

### 2.1. Finanças Tradicionais e Teoria de Portfolios

As finanças tradicionais constituem o alicerce teórico da moderna gestão de investimentos. Fundamentadas em premissas como a racionalidade dos agentes econômicos, a eficiência dos mercados e a previsibilidade dos retornos esperados, essas abordagens forneceram os primeiros modelos formais para a alocação de ativos em portfólios. Tais modelos buscam estruturar de forma lógica as decisões de investimento com base na relação risco-retorno.

A Teoria Moderna do Portfólio (Modern Portfolio Theory – MPT), proposta por Harry Markowitz (1952), representa um dos marcos fundadores da disciplina. De acordo com Markowitz (1952), "os investidores racionais devem construir carteiras eficientes, maximizando o retorno esperado para um dado nível de risco". O autor introduziu o conceito de diversificação como instrumento para a mitigação do risco específico, ao combinar ativos com correlação não perfeita. A partir dessa formulação, nasceu o conceito da "fronteira eficiente", que delimita o conjunto de carteiras ótimas.

Este modelo ganhou robustez com o desenvolvimento do Capital Asset Pricing Model (CAPM), elaborado por Sharpe (1964), que busca determinar o retorno esperado de um ativo com base em seu risco sistemático. Segundo

Sharpe (1964), "o retorno esperado de um ativo é função linear de seu beta, o coeficiente que expressa a sensibilidade do ativo em relação ao mercado". O CAPM introduz a ideia do prêmio de risco de mercado e propõe que somente o risco sistemático é remunerado.

A crítica empírica ao CAPM levou à evolução dos modelos multifatoriais. Fama e French (1992) destacaram que o CAPM não explicava totalmente os retornos observados de ações de pequenas empresas ou de empresas com alto valor contábil sobre o valor de mercado. Eles propuseram o modelo de três fatores, incluindo tamanho (SMB) e valor (HML) como variáveis adicionais. Posteriormente, Fama e French (2015) expandiram o modelo para cinco fatores, incorporando lucratividade e investimento. Conforme afirmam, "os retornos das ações são determinados por múltiplas dimensões de risco e características fundamentais".

No campo da avaliação de performance, diversas métricas foram desenvolvidas para quantificar o desempenho ajustado ao risco. O índice de Sharpe (1966) é um dos mais utilizados e é definido como "o excesso de retorno de um portfólio sobre a taxa livre de risco dividido pelo desvio padrão do portfólio". O índice de Sortino aprimora o Sharpe ao considerar apenas a volatilidade negativa, o que o torna particularmente útil para gestores focados na preservação de capital. O alfa de Jensen (1968), por sua vez, estima o retorno excedente obtido por um gestor em relação ao esperado pelo CAPM, fornecendo uma medida direta de habilidade de geração de alfa.

Apesar da solidez desses modelos, críticos apontam limitações significativas. A hipótese de agentes totalmente racionais tem sido questionada por pesquisadores das finanças comportamentais. Kahneman e Tversky (1979), com a Teoria da Perspectiva, demonstraram que os investidores são afetados por vieses cognitivos como aversão à perda, heurísticas de representatividade e excesso de confiança, desviando-se sistematicamente da racionalidade esperada. De acordo com os autores, "as decisões financeiras raramente são tomadas com base em cálculos probabilísticos frios; elas são fortemente influenciadas pelo enquadramento do problema e pela forma como os resultados são percebidos".

Essas críticas não invalidam a utilidade dos modelos tradicionais, mas reforçam a necessidade de complementá-los com abordagens mais flexíveis e adaptativas. É nesse contexto que a Inteligência Artificial e o Machine Learning se inserem, oferecendo ferramentas capazes de lidar com não linearidades, grandes volumes de dados e padrões não explícitos. Segundo Gu et al. (2020), "modelos baseados em redes neurais e aprendizado profundo superam, de forma

significativa, os modelos lineares tradicionais em tarefas de previsão de retorno de ativos".

Ao aplicar essas novas tecnologias no contexto da alocação de ativos, torna-se possível refinar a modelagem da fronteira eficiente de Markowitz com dados em tempo real, gerar previsões probabilísticas ajustadas ao regime de mercado e adaptar dinamicamente os pesos de portfólio. A IA não substitui as teorias clássicas — ela as complementa, ampliando sua capacidade analítica.

Para o presente estudo, a teoria de portfólio serve como contraponto fundamental para a avaliação do impacto da IA na performance e na mitigação de riscos. O objetivo não é rejeitar os fundamentos tradicionais, mas analisá-los sob uma nova ótica: a de um ambiente financeiro em constante mutação, no qual a vantagem competitiva pode estar diretamente relacionada à capacidade de aprendizado e adaptação algorítmica.

Dessa forma, compreender profundamente os pilares das finanças tradicionais é essencial para contextualizar o potencial disruptivo — e os limites — da adoção de IA e ML na gestão de fundos de investimento. Ao unir a racionalidade da fronteira eficiente com a adaptabilidade dos algoritmos inteligentes, pode-se vislumbrar um novo paradigma na arquitetura de portfólios, mais responsável aos riscos contemporâneos e às oportunidades emergentes.

## **2.2. Finanças Quantitativas e Tecnologias Emergentes**

A evolução das finanças, especialmente a partir da década de 1990, consolidou um movimento de crescente incorporação de métodos quantitativos e tecnologias computacionais no processo decisório. As chamadas finanças quantitativas podem ser entendidas como a aplicação sistemática de técnicas matemáticas, estatísticas e computacionais para resolver problemas complexos de precificação, alocação de ativos, modelagem de risco e análise de mercado. Essa abordagem difere das finanças tradicionais por substituir grande parte da intuição subjetiva dos gestores por processos baseados em evidências, dados extensos e algoritmos replicáveis.

O crescimento dos fundos quantitativos representou um divisor de águas nesse contexto. Esses veículos passaram a utilizar modelos algorítmicos e estatísticos para realizar operações sistemáticas em larga escala, reduzindo a interferência emocional e permitindo maior consistência na execução de estratégias. A filosofia de investimento quantitativo caracteriza-se pelo uso intensivo de bases de dados históricas, desenvolvimento de fatores explicativos

— como momentum, value, quality e volatilidade — e implementação via algoritmos de trading automatizado, capazes de operar em múltiplos mercados e ativos simultaneamente.

A emergência dos chamados fatores sistemáticos, também conhecidos como smart betas, reforçou a capacidade das finanças quantitativas de desmembrar o risco em componentes específicos, replicáveis e negociáveis. Essa lógica permitiu o surgimento de ETFs e fundos que replicam sistematicamente tais fatores, promovendo uma gestão mais transparente, escalável e baseada em evidências. A essência desse movimento é transformar intuições econômicas em regras claras, testáveis e passíveis de automação.

Com o avanço da capacidade computacional e o acesso a dados alternativos — big data, dados não estruturados, informações de redes sociais e indicadores em tempo real —, novos paradigmas emergiram. Tecnologias como a Inteligência Artificial (IA) e o Machine Learning (ML) passaram a ser integradas às finanças quantitativas, ampliando drasticamente seu poder preditivo. Os pesquisadores Heaton, Polson e Witte afirmam que a nova geração de modelos quantitativos se baseia em aprendizado supervisionado e não supervisionado, utilizando dados estruturados e não estruturados para identificar relações não lineares e padrões ocultos que escapam à análise tradicional.

Essa sofisticação trouxe também novos desafios. O risco de overfitting — ou seja, a modelagem excessiva que se ajusta perfeitamente ao passado, mas falha no futuro — tornou-se um tema central. Para mitigar esse problema, os gestores modernos empregam técnicas de validação cruzada, penalizações de complexidade, regularização e ensemble models. Essas ferramentas permitem encontrar um equilíbrio entre acurácia preditiva e capacidade de generalização, essencial para modelos que precisam operar em ambientes dinâmicos e incertos.

No contexto da gestão de fundos, essas abordagens possibilitam maior robustez na previsão de retornos, na identificação de regimes de mercado e na detecção de sinais precoces de reversão ou estresse. Fundos como os da Renaissance Technologies tornaram-se referência mundial ao utilizar modelos estatísticos altamente sofisticados, alimentados por big data e aprendizado de máquina. O gestor Jim Simons, por exemplo, construiu o Medallion Fund com modelos constantemente atualizados com centenas de variáveis, capazes de capturar relações temporais efêmeras que escapam à percepção humana.

Ao integrar a lógica das finanças quantitativas com a capacidade adaptativa da IA, observa-se a formação de um campo híbrido, tecnicamente avançado e potencialmente mais eficaz na gestão ativa de portfólios. Esse novo paradigma

não apenas refina os instrumentos clássicos de análise e alocação, mas também amplia o horizonte de possibilidades para a geração de alfa, a diversificação de risco e a antecipação de cenários de mercado.

Compreender a estrutura, os métodos e as limitações das finanças quantitativas é, portanto, essencial para interpretar corretamente os resultados obtidos na comparação entre fundos que utilizam IA e ML e fundos tradicionais. O gestor contemporâneo deixa de ser apenas um alocador de capital para tornar-se um arquiteto de modelos analíticos e pipelines de dados, apto a navegar em ambientes de incerteza, alta complexidade e rápida mutação tecnológica.

### **2.3. Inteligência Artificial e Machine Learning**

A ascensão da Inteligência Artificial (IA) e do Machine Learning (ML) representa uma das transformações mais disruptivas no campo das finanças e, em particular, na gestão de investimentos. Enquanto a IA corresponde a um campo abrangente voltado a replicar ou ampliar a capacidade cognitiva humana por meio de máquinas, o ML é um subconjunto que se concentra no desenvolvimento de algoritmos capazes de aprender padrões a partir de dados, adaptando-se dinamicamente a novas informações sem depender de programação explícita.

Essa distinção conceitual é essencial para compreender seu impacto. A IA abrange o propósito mais amplo de simular a inteligência humana — percepção, raciocínio, tomada de decisão — enquanto o ML foca especificamente na capacidade de adaptação e aprendizado com base em dados históricos e presentes. O pesquisador Pedro Domingos, por exemplo, descreve cinco “tribos” do aprendizado de máquina — simbolistas, conexionistas, evolucionistas, bayesianos e analogistas — que traduzem abordagens distintas para resolver problemas preditivos ou de classificação. No contexto financeiro, destacam-se os métodos conexionistas (redes neurais), bayesianos (modelagem probabilística) e ensemble (modelos compostos como Random Forest e Gradient Boosting), por sua capacidade de capturar interações não lineares entre múltiplas variáveis e reduzir erros por meio da combinação de algoritmos.

Essa capacidade é particularmente relevante em ambientes de mercado marcados por alta complexidade, múltiplas variáveis interdependentes e ruído estocástico, nos quais modelos lineares tradicionais têm dificuldade para generalizar. O pesquisador Heaton e colaboradores afirmam que métodos de aprendizado de máquina superam os modelos lineares justamente por

identificarem padrões ocultos e estruturas de alta dimensionalidade, tornando-se ferramentas valiosas para previsões de retornos, volatilidades e riscos extremos.

No universo das finanças, destacam-se três grandes famílias de abordagens:

- **Modelos supervisionados**, como regressões penalizadas, máquinas de vetores de suporte (SVM) e redes neurais profundas, utilizados para prever retornos, spreads de crédito ou probabilidades de default com base em variáveis econômicas e financeiras;

- **Modelos não supervisionados**, como clustering e análise de componentes principais (PCA), voltados a agrupar ativos com comportamentos semelhantes, identificar regimes de mercado e revelar fatores de risco ocultos;

- **Aprendizado por reforço**, que simula ambientes de tomada de decisão dinâmica, permitindo treinar agentes artificiais para otimizar alocações de portfólio em tempo real, rebalancear posições e adaptar estratégias a condições de mercado mutáveis.

Além desses métodos clássicos, técnicas modernas como deep learning e NLP (processamento de linguagem natural) vêm sendo incorporadas em estratégias cada vez mais sofisticadas. O uso de NLP permite que fundos quantitativos capturem sinais de sentimento e antecipem movimentos de mercado com base em conteúdo textual desestruturado, como comunicados de empresas, notícias e transcrições de conferências. Essa integração entre dados não estruturados e modelos preditivos abre caminho para estratégias mais responsivas e informadas, complementando as abordagens tradicionais de análise fundamentalista ou técnica.

Na prática, gestores renomados como BlackRock Systematic Active Equity, Two Sigma e Renaissance Technologies vêm aplicando essas técnicas para aperfeiçoar modelos de seleção de ativos, alocação de capital e hedge dinâmico. O diferencial competitivo desses fundos está não apenas no uso intensivo de dados e algoritmos, mas também na construção de pipelines robustos de coleta, limpeza e atualização contínua das informações, permitindo que os modelos aprendam e se ajustem diariamente a novos sinais de mercado.

Entretanto, a adoção de ML em finanças apresenta desafios significativos. O risco de overfitting — quando um modelo se ajusta em excesso aos dados passados e falha ao generalizar para dados futuros — continua sendo uma barreira importante. A opacidade dos modelos, especialmente em arquiteturas de

deep learning, dificulta a interpretação das decisões tomadas (“caixa-preta”), enquanto vieses presentes nos dados podem comprometer previsões e gerar riscos inesperados. Por isso, gestores de ponta investem não apenas em algoritmos, mas em governança, validação cruzada, regularização e técnicas de interpretabilidade para equilibrar acurácia preditiva e transparência.

No contexto deste estudo, compreender o funcionamento, os tipos e as limitações do ML é fundamental para avaliar o diferencial competitivo dos fundos que utilizam essas tecnologias. A proposta não é apenas verificar se esses fundos performam melhor, mas entender como essa performance é obtida e quais riscos estão envolvidos nesse processo. A hipótese central é que o uso de ML confere vantagens informacionais e preditivas que se traduzem em retornos ajustados ao risco superiores, especialmente em ambientes voláteis e com grande dispersão de retornos setoriais ou regionais — condições nas quais a capacidade adaptativa dos algoritmos pode se mostrar decisiva para a geração consistente de alfa.

A seguir será detalhada a aplicação direta dessas tecnologias na estrutura e operação de fundos de investimento, examinando os mecanismos pelos quais IA e ML impactam a performance e a gestão de risco.

## **2.4. Aplicações Diretas de IA e ML na Gestão de Fundos de Investimento**

A aplicação direta de técnicas de Inteligência Artificial (IA) e Machine Learning (ML) na gestão de fundos de investimento consolidou-se como um dos principais diferenciais competitivos no mercado global. Impulsionados pela maior disponibilidade de dados, pelo aumento exponencial do poder computacional e pela sofisticação das plataformas de negociação, gestores quantitativos incorporaram essas tecnologias para transformar a forma como analisam, decidem e executam operações. Não se trata apenas de usar ferramentas avançadas, mas de redesenhar processos inteiros de investimento para torná-los mais sistemáticos, escaláveis e responsivos.

De forma geral, as aplicações podem ser agrupadas em três frentes principais: seleção de ativos, alocação dinâmica de portfólio e gestão de risco/hedge adaptativo.

**Seleção de ativos:** Técnicas supervisionadas como Random Forest, regressões penalizadas (Lasso, Ridge) e redes neurais profundas vêm sendo empregadas para prever retornos esperados a partir de variáveis

fundamentalistas, técnicas e, cada vez mais, dados alternativos. Essa abordagem amplia o escopo analítico para além dos filtros tradicionais baseados em múltiplos contábeis ou fatores simples de valor, permitindo identificar oportunidades em ativos ou nichos de mercado antes invisíveis. Em mercados líquidos, esses modelos podem ser combinados com estratégias de arbitragem estatística — explorando desvios temporários de preços entre ativos correlacionados — para gerar ganhos ajustados ao risco.

**Alocação dinâmica de portfólio:** Algoritmos de aprendizado por reforço têm sido utilizados para simular ambientes de mercado e otimizar decisões sequenciais de investimento. Isso significa que as decisões de rebalanceamento deixam de seguir cronogramas fixos ou regras lineares e passam a ser tomadas com base em previsões dinâmicas do regime de mercado, volatilidade implícita, liquidez, dispersão setorial e sentimento dos investidores. Essa arquitetura torna a alocação mais próxima de um “agente” que aprende continuamente, adaptando pesos, hedge e exposição direcional às condições vigentes.

**Gestão de risco e hedge adaptativo:** Modelos não supervisionados como análise de componentes principais (PCA) e K-means clustering ajudam a revelar fontes ocultas de risco sistêmico, antecipar movimentos de correlação e simular cenários de estresse. Essa visão granular do risco permite que gestores ajustem proteções — via derivativos, overlay de opções ou arbitragem de volatilidade — de forma mais cirúrgica, construindo portfólios mais resilientes a choques de mercado. Em operações de alta frequência (high frequency trading), a detecção de padrões efêmeros e microcorrelações é crítica para evitar perdas e capturar spreads que desaparecem em segundos.

Fundos globais como BlackRock Systematic Active Equity, Man AHL e Acatis AI Global Equities incorporam IA em sua arquitetura decisória para calibrar exposição setorial com base em sinais proprietários extraídos de dados estruturados e não estruturados. O uso de NLP (processamento de linguagem natural) para extrair sentimento de relatórios financeiros, conferências e notícias alimenta modelos preditivos quase em tempo real, permitindo que ajustes de portfólio sejam realizados antes de movimentos amplos do mercado. Já gestores como a Renaissance Technologies operam com dados de altíssima frequência, avaliando dezenas de milhares de variáveis em tempo real, atualizando modelos diariamente e otimizando resultados em ambientes paralelos de simulação — prática essencial para estratégias sistemáticas de curtíssimo prazo e arbitragem estatística.

A operacionalização dessas estratégias envolve pipelines de dados totalmente automatizados, integração com sistemas de execução algorítmica, camadas de backtesting robustas e validação cruzada para minimizar overfitting. Cada etapa — da coleta e limpeza de dados até a execução no mercado — é projetada para reduzir latência, aumentar a confiabilidade dos sinais e permitir que os modelos aprendam continuamente. Em estratégias de alta frequência ou arbitragem, milissegundos de vantagem na execução podem ser decisivos para capturar oportunidades de lucro.

Contudo, essa sofisticação tecnológica traz também novos desafios. A dificuldade de interpretar decisões tomadas por modelos do tipo “caixa-preta” (black-box) exige dos gestores estruturas de governança mais rígidas, mecanismos de validação e monitoramento contínuo, além de métricas de interpretabilidade para justificar decisões perante investidores e reguladores. O equilíbrio entre performance preditiva e transparência tornou-se uma competência central para fundos que operam com IA e ML.

Dentro do escopo deste trabalho, a aplicação direta de IA e ML será analisada por meio de uma amostra de fundos brasileiros, comparando performance e mecanismos de controle de risco entre aqueles com uso intensivo dessas tecnologias e fundos tradicionais. A hipótese é que fundos com IA apresentam não apenas retorno superior, mas uma gestão de risco mais responsiva e adaptada à realidade contemporânea de alta complexidade, volatilidade e velocidade de mercado — condições nas quais a vantagem informacional e a execução precisa podem ser determinantes para a geração de alfa sustentável.

## **2.5. Métricas de Avaliação de Performance e Risco**

A mensuração de desempenho e risco é um dos pilares centrais da gestão de fundos de investimento. Ela permite comparar, com rigor e em bases homogêneas, estratégias que possuem diferentes filosofias, horizontes e níveis de risco. Sem métricas consistentes, não é possível avaliar se um retorno elevado decorre de habilidade do gestor, de alavancagem, de um cenário favorável ou simplesmente de sorte. Por isso, a indústria desenvolveu indicadores padronizados que procuram isolar a verdadeira relação risco-retorno e oferecer uma visão objetiva do desempenho.

**Índice de Sharpe:** A razão de Sharpe mede o excesso de retorno de um portfólio em relação à taxa livre de risco, ajustado pelo desvio padrão dos retornos totais. Em termos práticos, indica quanto de retorno adicional o investidor recebeu para cada unidade de risco assumido. Quanto maior o índice, melhor a eficiência da estratégia em transformar risco em retorno. No entanto, como a métrica considera toda a variância — tanto positiva quanto negativa — ela pode mascarar estratégias que apresentam picos de perda apesar de retornos elevados.

$$\text{Sharpe Ratio} = \frac{R_p - R_f}{\sigma_p}$$

$R_p$  = retorno médio do portfólio (no período analisado)

$R_f$  = taxa livre de risco (no mesmo período)

$\sigma_p$  = desvio padrão dos retornos do portfólio

**Índice de Sortino:** Para contornar essa limitação, o índice de Sortino foca apenas nos desvios negativos em relação a um retorno mínimo aceitável (MAR – Minimum Acceptable Return). Ele mostra quanto de retorno excedente é gerado por unidade de “risco de queda”. Essa métrica é particularmente útil para fundos que usam alavancagem, derivativos ou estratégias assimétricas — como muitas carteiras baseadas em IA — porque oferece uma visão mais precisa sobre a proteção do capital em cenários adversos.

$$\text{Sortino Ratio} = \frac{R_p - R_f}{\sigma_d}$$

$R_p$  = retorno médio do portfólio

$R_f$  = taxa livre de risco ou retorno mínimo aceitável (MAR)

$\sigma_d$  = desvio padrão apenas dos retornos abaixo do MAR (volatilidade negativa)

**Alfa de Jensen:** O alfa representa o retorno excedente obtido pelo fundo em relação ao que seria esperado pelo seu nível de risco sistemático (beta de mercado). Alfa positivo significa que o gestor agregou valor além do que seria explicado pelo risco de mercado; alfa negativo indica destruição de valor. Em estratégias quantitativas com IA, esse indicador é importante para capturar a eficiência adicional obtida pela modelagem preditiva, diferenciando fundos que realmente entregam performance ajustada ao risco daqueles que apenas surfam tendências gerais.

$$\alpha = R_p - [R_f + \beta_p (R_m - R_f)]$$

$R_p$  = retorno do portfólio

$R_f$  = taxa livre de risco

$R_m$  = retorno do mercado ou benchmark

$\beta_p$  = beta do portfólio em relação ao mercado

**Volatilidade:** A volatilidade anualizada, normalmente calculada a partir do desvio padrão dos retornos mensais multiplicado pela raiz do número de períodos, continua sendo a medida clássica do risco total. Ela expressa a amplitude das oscilações dos retornos e serve como base para a maioria das outras métricas. Embora simples, a volatilidade permite identificar se um fundo está assumindo mais risco do que seu benchmark e se seu retorno compensa essa exposição.

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \text{Cov}(R_i, R_j)$$

**Drawdown Máximo:** Enquanto a volatilidade mede a dispersão em torno de uma média, o drawdown máximo captura a maior perda acumulada do fundo em um determinado período, do pico ao vale. Essa métrica traduz o pior cenário vivido pelo investidor e ajuda a entender a resiliência da estratégia em crises. Para gestores que usam IA, monitorar drawdowns é essencial para avaliar se os modelos conseguem reagir a mudanças abruptas de regime ou se ficam expostos a perdas profundas antes de se ajustar.

$$\text{Max Drawdown} = \max_{t \in T} \left( \frac{\text{Pico}_t - \text{Vale}_t}{\text{Pico}_t} \right)$$

"Pico" = valor máximo atingido pelo portfólio antes de uma queda

"Vale" = menor valor subsequente antes de nova alta

**Value-at-Risk (VaR) e Conditional Value-at-Risk (CVaR):** O VaR estima a perda máxima esperada para um determinado nível de confiança e horizonte de tempo. Por exemplo, um VaR de 5% para um dia indica que, em 95% dos casos, a perda não deve exceder aquele valor. O CVaR vai além: ele calcula a média das perdas que ultrapassam o VaR, capturando o "rabo gordo" das distribuições de retorno. Essas métricas são amplamente usadas por reguladores e mesas de risco porque fornecem uma visão probabilística do risco extremo e ajudam a dimensionar limites de exposição.

$$\text{VaR}_c = \mu_p + z_c \cdot \sigma_p$$

$\mu_p$  = retorno esperado do portfólio

$\sigma_p$  = desvio padrão dos retornos

$z_c$  = quantil crítico da distribuição

$$\text{CVaR}_c = E[\text{Perda} \mid \text{Perda} > \text{VaR}_c]$$

Ao aplicar essas métricas ao contexto deste estudo, será possível comparar a performance e o risco de fundos com uso intensivo de IA e ML versus fundos tradicionais da mesma gestora no período de 2016 a 2025. O uso conjunto de Sharpe, Sortino, alfa, volatilidade, drawdown e VaR/CVaR permitirá avaliar não apenas se os fundos quantitativos com IA apresentam vantagem estatisticamente significativa, mas também se essa vantagem é consistente, sustentável e robusta a diferentes condições de mercado. A análise estatística — por exemplo, testes t para médias emparelhadas — trará evidência empírica para verificar se há superioridade persistente no uso de técnicas de IA para geração de retorno ajustado ao risco.

O aprofundamento dessas métricas e sua relação com tecnologias avançadas fornece ainda embasamento para refletir sobre a adaptabilidade das estratégias quantitativas em cenários de alta incerteza, como crises financeiras, ciclos de aumento de juros ou mudanças abruptas de regime. Assim, os indicadores funcionam não apenas como régua de desempenho, mas também como termômetro da capacidade dos fundos de absorver choques e manter disciplina algorítmica em contextos adversos — um ponto crítico para qualquer gestor que utilize IA e ML como diferencial competitivo.

### 3. Metodologia

Este capítulo descreve, de forma sistemática, os procedimentos metodológicos utilizados para o desenvolvimento da presente pesquisa, a qual investiga a aplicação de técnicas de Inteligência Artificial (IA) e Machine Learning (ML) na gestão de fundos de investimento. Com base nas diretrizes propostas por Gil (2010; 2011), a estrutura metodológica contempla a classificação da pesquisa, os procedimentos técnicos adotados, as fontes de dados, os critérios de seleção e análise, bem como as limitações e justificativas das opções metodológicas.

#### 3.1. Tipo de Pesquisa

A presente pesquisa classifica-se, em termos metodológicos, como uma **pesquisa aplicada, quantitativa, explicativa, com delineamento teórico-empírico e abordagem comparativa**. Essa caracterização decorre tanto da natureza do problema investigado — a eficácia da aplicação de Inteligência Artificial (IA) e Machine Learning (ML) na gestão de fundos de investimento no Brasil — quanto dos objetivos pretendidos, que envolvem avaliar, de forma objetiva e estatisticamente robusta, a influência dessas tecnologias sobre o desempenho e a mitigação de riscos de carteiras de investimento.

##### 3.1.1. Pesquisa Aplicada

Trata-se de uma **pesquisa aplicada**, pois visa gerar conhecimento para aplicação prática, com implicações diretas no processo decisório de gestores de fundos, analistas quantitativos e instituições financeiras. De acordo com Gil (2010, p. 42), a pesquisa aplicada “é motivada pela necessidade de solucionar problemas concretos”, o que se alinha perfeitamente ao objetivo deste estudo: entender se o uso de IA e ML confere vantagem competitiva real aos fundos que adotam essas tecnologias em comparação aos fundos tradicionais.

### 3.1.2. Abordagem Quantitativa

A abordagem é **quantitativa**, por envolver a coleta e o tratamento de dados numéricos — principalmente séries históricas de rentabilidade, volatilidade e métricas de risco — que serão submetidos a análises estatísticas e comparativas. A abordagem quantitativa, segundo Marconi e Lakatos (2003), permite “quantificar variáveis e estabelecer padrões de associação ou correlação entre elas”, característica essencial para a análise de performance ajustada ao risco em fundos de investimento.

Nesse contexto, a pesquisa se apoia em ferramentas estatísticas como razão de Sharpe, razão de Sortino, alfa de Jensen, Value-at-Risk (VaR), entre outras, além de testes de hipótese (como o teste t para amostras pareadas) com significância estatística de 5% ( $p < 0,05$ ).

### 3.1.3. Pesquisa Explicativa

Quanto aos fins, o estudo é **explicativo**, pois busca compreender as relações de causa e efeito entre o uso de IA/ML e os resultados obtidos pelos fundos analisados. Como salienta Gil (2011, p. 28), pesquisas explicativas “buscam identificar os fatores que determinam ou contribuem para a ocorrência dos fenômenos”, o que neste caso se traduz na tentativa de verificar se a presença de tecnologias baseadas em IA pode ser considerada um fator explicativo para o desempenho superior (ou não) de determinados fundos.

A pesquisa vai além da simples descrição de características ou comparação de médias; ela busca **estabelecer relações causais controladas**, com base em métodos estatísticos e fundamentação teórica sólida, seguindo os princípios da inferência quantitativa.

### 3.1.4. Delineamento Teórico-Empírico

O delineamento é **teórico-empírico**, pois combina uma base conceitual ampla — construída a partir da literatura científica nas áreas de finanças, estatística e ciência de dados — com uma aplicação prática sobre dados reais do mercado financeiro brasileiro. Como aponta Vergara (2009), essa combinação é

típica de pesquisas em Administração e Finanças que visam não apenas descrever fenômenos, mas testá-los empiricamente em ambientes reais.

A parte teórica está ancorada em autores como Markowitz (1952), Jensen (1968), Fama (1970), Treynor (1965), Bodie, Kane e Marcus (2014), entre outros. Já a parte empírica será desenvolvida com base em fundos registrados na Anbima e na CVM, com dados extraídos de plataformas como Economática, Morningstar, XP e relatórios de gestoras.

### **3.1.5. Pesquisa Comparativa**

Por fim, trata-se também de uma **pesquisa comparativa**, pois envolve a análise de dois grupos distintos: (i) fundos de investimento que utilizam IA/ML como parte central de sua estratégia de gestão; e (ii) fundos tradicionais da mesma gestora (quando possível) ou de mesma categoria. A comparação é central para a estrutura lógica da pesquisa, uma vez que permite isolar o uso da tecnologia como variável explicativa dos diferenciais de performance.

## **3.2. Abordagem Quantitativa e Justificativa**

A presente pesquisa adota uma **abordagem quantitativa**, fundamentada na análise estatística de dados financeiros, com o objetivo de testar hipóteses claras e mensuráveis sobre o impacto do uso de Inteligência Artificial (IA) e Machine Learning (ML) na performance e na mitigação de riscos em fundos de investimento brasileiros.

Segundo **Richardson (1999)**, a abordagem quantitativa “se caracteriza pela objetividade, replicabilidade e uso de instrumentos estatísticos na coleta e análise dos dados”, sendo especialmente adequada quando o fenômeno estudado envolve mensuração de variáveis numéricas — como retorno, volatilidade e índice de Sharpe — e relações causais entre elas. Essa metodologia se coaduna com o objetivo central deste trabalho, que é verificar se os fundos que utilizam IA/ML obtêm desempenho estatisticamente superior aos fundos tradicionais.

### **3.2.1. Fundamentação Epistemológica**

A abordagem quantitativa parte do **positivismo lógico**, corrente epistemológica que pressupõe que o conhecimento é obtido por meio da

observação empírica e da testagem de hipóteses com base em evidências concretas e replicáveis.

Dessa forma, a presente pesquisa se insere no modelo **hipotético-dedutivo**, formulando hipóteses que serão testadas com base em dados reais. A hipótese central pode ser formulada da seguinte maneira:

**H<sub>0</sub>**: Não há diferença significativa entre a performance ajustada ao risco de fundos que utilizam IA/ML e fundos tradicionais;

**H<sub>1</sub>**: Fundos que utilizam IA/ML apresentam performance ajustada ao risco estatisticamente superior.

A partir disso, as métricas quantitativas escolhidas permitirão avaliar a significância estatística das diferenças observadas entre os grupos de fundos analisados.

### 3.2.2. Justificativa para a Escolha da Abordagem

A escolha pela abordagem quantitativa se justifica, primordialmente, por **três razões centrais**:

1. **Natureza dos dados disponíveis**: O estudo se baseia em dados secundários extraídos de fontes públicas e confiáveis, como CVM, Anbima, Economática, Morningstar e relatórios de performance das gestoras. São dados estruturados em séries temporais (de 2016 a 2025), permitindo análises econométricas e estatísticas robustas.
2. **Objetividade e replicabilidade**: A utilização de métricas como Sharpe, Sortino, Alfa de Jensen, Value-at-Risk (VaR) e volatilidade permite comparações padronizadas e replicáveis. Segundo **Hair et al. (2009)**, a abordagem quantitativa é mais indicada quando se busca “verificar relações específicas entre variáveis com o uso de modelos matemáticos e estatísticos”.
3. **Capacidade de inferência estatística**: Ao empregar testes de significância (como teste t de Student para amostras pareadas), o estudo permite inferir, com determinado grau de confiança, se o uso de IA/ML resulta em desempenho superior em relação aos benchmarks tradicionais. Isso eleva o grau de rigor da análise e aproxima a pesquisa de um modelo explicativo sólido.

### **3.3. População e Amostra**

A definição adequada da população e da amostra é essencial para assegurar a validade externa da pesquisa, ou seja, a possibilidade de generalização dos resultados para o universo mais amplo dos fundos de investimento brasileiros. Neste estudo, o universo de interesse abrange fundos de investimento com histórico operacional de, no mínimo, 10 anos entre 2016 e 2025, com especial atenção para aqueles que declararam, de forma explícita em seus regulamentos ou materiais públicos, o uso de algoritmos baseados em Inteligência Artificial (IA) ou Machine Learning (ML) na gestão da carteira.

#### **3.3.1. População**

A população-alvo deste estudo consiste em dois grandes grupos de fundos de investimento sob gestão profissional no Brasil:

**1. Fundos quantitativos com uso declarado de IA e ML:**

São aqueles fundos que, em seus documentos regulatórios (lâmina, regulamento, carta de gestão) ou relatórios de performance, fazem referência explícita ao uso de algoritmos preditivos, modelos de aprendizado de máquina, redes neurais, regressões multivariadas adaptativas, árvores de decisão, reinforcement learning, ou outros métodos automatizados de decisão baseados em dados.

**2. Fundos tradicionais:**

Como grupo de controle, serão incluídos fundos de estratégia tradicional (fundamentalista, macro, etc.), da mesma gestora que os fundos do grupo experimental, com o objetivo de controlar efeitos de cultura institucional, filosofia de risco e infraestrutura tecnológica. Isso reduz vieses externos e melhora a validade interna da comparação.

A população total, portanto, é intencionalmente segmentada, com base em critérios teóricos e práticos, para permitir uma análise comparativa direta e justa.

### 3.3.2. Critérios de Inclusão

Para garantir a homogeneidade e robustez dos dados analisados, os seguintes critérios de inclusão foram estabelecidos:

- Fundos domiciliados no Brasil e registrados na CVM;
- Existência de dados históricos diários ou mensais de performance entre janeiro de 2016 e setembro de 2025;
- Declaração pública do uso de IA ou ML para compor o grupo experimental;
- Existência de fundo comparável (sem uso declarado de IA/ML) da mesma gestora, com perfil de risco e mandato similares (por exemplo, FIM, FIQ, Multimercado Livre); e
- Não estar em processo de liquidação ou com patrimônio líquido inferior a R\$ 5 milhões.

### 3.3.3. Amostragem

A amostragem adotada será do tipo não-probabilística, intencional e emparelhada, ou seja, será feita a seleção deliberada de pares de fundos (um com uso de IA e outro tradicional) para permitir a comparação entre estratégias dentro de contextos organizacionais semelhantes. Esse tipo de amostragem é amplamente usado em estudos exploratórios e comparativos quando o universo é restrito ou especializado.

A amostra selecionada é composta de:

- **3 fundos quantitativos com uso de IA/ML**, distribuídos entre casas como Giant Steps, Kadima, entre outras; e
- **3 fundos tradicionais correspondentes**, com gestão manual, bottom-up, top-down ou macro, dentro das mesmas instituições gestoras.

### 3.3.4. Justificativa para a escolha da amostra

A opção por uma **amostragem emparelhada** visa mitigar ruídos exógenos à estratégia de gestão (como diferenças de taxas, objetivos, restrições ou

estrutura de capital), permitindo que a principal variável em análise seja o **uso ou não de IA e ML** como método decisório.

Essa escolha metodológica também se justifica pelo caráter **comparativo e aplicado** da pesquisa, visto que a amostragem emparelhada é indicada quando se busca analisar diferenças entre grupos em condições controladas, sem necessidade de extração para populações probabilísticas.

### 3.3.5. Limitações da Amostra

Reconhece-se, no entanto, que há limitações:

- Nem todos os fundos divulgam claramente o uso de IA/ML, o que pode limitar o tamanho da amostra;
- O uso de IA pode variar em grau — desde decisões automatizadas até apenas auxílio analítico — o que pode introduzir heterogeneidade interna no grupo experimental; e
- O recorte temporal (2016–2025) pode conter períodos de crise (por exemplo, pandemia de COVID-19 e alta de juros), afetando a estabilidade dos retornos.

Apesar disso, a amostra proposta é considerada adequada, representativa e suficiente para a realização da análise estatística pretendida.

## 3.4. Análise dos Dados

A etapa de análise dos dados constitui uma fase crítica para a verificação das hipóteses e o atendimento aos objetivos da pesquisa, uma vez que é por meio dela que se obtêm evidências empíricas a respeito da influência da Inteligência Artificial (IA) e do Machine Learning (ML) sobre o desempenho e a mitigação de riscos em fundos de investimento brasileiros. Neste estudo, optou-se por uma abordagem quantitativa e comparativa, com foco na análise estatística de indicadores de performance e risco de fundos que utilizam IA/ML em relação a fundos tradicionais da mesma gestora, no período de 2016 a 2025.

A base de dados foi estruturada com informações obtidas por meio de plataformas públicas e privadas, como a Comissão de Valores Mobiliários (CVM), Economatica e Quantum Axis. Os fundos foram selecionados com base em

critérios de comparabilidade, como **(i)** pertencimento à mesma gestora; **(ii)** mesma categoria de risco; e **(iii)** mesma política de investimento, com a diferença central sendo a adoção ou não de tecnologias de IA e ML.

### **3.4.1. Procedimentos estatísticos**

Para a análise dos dados, serão utilizadas estatísticas descritivas e inferenciais. Inicialmente, será apresentada uma análise exploratória, com médias, desvios-padrão, máximos, mínimos e quartis dos principais indicadores: retorno acumulado, retorno médio mensal, volatilidade, índice de Sharpe, índice de Sortino, alfa de Jensen, drawdown máximo e Value at Risk (VaR).

Em seguida, serão conduzidos testes estatísticos para verificar se as diferenças entre os fundos com uso de IA e os tradicionais são estatisticamente significativas. Para isso, será aplicado o teste t pareado, considerando que os pares de fundos pertencem à mesma gestora e categoria. Esse tipo de teste é indicado quando se deseja comparar médias de dois grupos relacionados.

Também será utilizado o teste de Shapiro-Wilk para verificar a normalidade das distribuições amostrais. Caso a normalidade não seja verificada, será aplicado o teste não-paramétrico de Wilcoxon para amostras emparelhadas, conforme sugerido por Marôco para situações em que a suposição de normalidade não é atendida.

### **3.4.2. Comparabilidade e controle de variáveis**

Para evitar vieses e permitir que as diferenças observadas sejam atribuídas, de fato, à adoção de IA/ML, será feito controle de variáveis como:

- Categoria ANBIMA do fundo;
- Política de investimento (ações, multimercado, renda fixa);
- Grau de alavancagem;
- Índice de benchmark (exemplo: CDI, Ibovespa); e
- Horizonte de investimento.

Além disso, pretende-se calcular o alfa condicional, conforme o modelo de Fama e French, para verificar se a performance dos fundos com IA permanece

superior mesmo após controle pelos fatores de mercado (fator de mercado, tamanho e valor).

### **3.4.3. Ferramentas e softwares utilizados**

A análise será conduzida por meio da seguinte linguagem de programação e seus respectivos softwares:

- **Python (pandas, numpy, scipy, statsmodels):** para processamento dos dados e realização dos testes estatísticos.

O uso de ferramentas programáveis como Python é especialmente pertinente neste trabalho, por permitir replicabilidade, transparência e customização de análises complexas, características que dialogam com o próprio objeto de estudo, centrado no uso de tecnologias para análise financeira.

### **3.4.4. Análise dos resultados**

Os resultados serão interpretados à luz da literatura apresentada no capítulo 2. Espera-se que os fundos que utilizam IA e ML apresentem, em média, índices de Sharpe e Sortino superiores, bem como menor drawdown e VaR, refletindo maior eficiência na geração de retorno ajustado ao risco.

A análise também buscará identificar se a performance superior é estatisticamente significativa e consistente ao longo do período analisado. Caso os resultados confirmem essas hipóteses, eles oferecerão evidência empírica de que a adoção de IA e ML representa uma vantagem competitiva relevante na gestão de fundos no mercado brasileiro.

Adicionalmente, os resultados obtidos também permitirão discutir se o uso dessas tecnologias contribui para uma resposta mais rápida a eventos de mercado, maior capacidade de modelar não linearidades e melhor adaptação a regimes de mercado distintos – temas abordados nos subcapítulos anteriores.

## **3.5. Limitações da Pesquisa**

Toda pesquisa científica está sujeita a determinadas limitações, e reconhecê-las é essencial para a construção de uma análise crítica e transparente dos resultados. No presente trabalho, que busca analisar os impactos do uso de

Inteligência Artificial (IA) e Machine Learning (ML) na performance e mitigação de riscos em fundos de investimento no Brasil, algumas restrições metodológicas e contextuais foram identificadas desde o planejamento até a fase de execução.

Em primeiro lugar, destaca-se a limitação temporal da base de dados utilizada. A pesquisa se concentra no período de 2016 a 2025, e, embora esse recorte inclua eventos significativos — como a pandemia da COVID-19, ciclos de alta de juros e mudanças na dinâmica dos mercados — ele ainda representa um horizonte relativamente curto para avaliar o desempenho de estratégias baseadas em IA em comparação a modelos tradicionais, especialmente quando se considera a natureza estrutural de investimentos de longo prazo.

Em segundo lugar, há restrições relacionadas ao acesso aos dados. Ainda que a análise tenha priorizado fundos da mesma gestora com estratégias distintas (tradicionais versus quantitativas com IA/ML), a disponibilidade pública de informações detalhadas sobre os algoritmos utilizados, bem como sobre os critérios de reequilíbrio, treinamento dos modelos e ajustes internos de risco, é limitada. Por questões de sigilo industrial e competitividade, gestoras raramente divulgam essas metodologias em profundidade. Assim, parte da análise foi feita com base em inferência indireta por meio de resultados e descrições genéricas de estratégia, o que pode impactar o grau de precisão do diagnóstico técnico.

Outra limitação relevante diz respeito à variabilidade dos contextos econômicos e políticos do Brasil, que podem introduzir ruídos nos dados analisados. Fatores exógenos como alterações regulatórias, crises fiscais, instabilidade cambial e choques geopolíticos não podem ser inteiramente isolados nos modelos de regressão, ainda que controles estatísticos tenham sido aplicados para mitigar seus efeitos.

No campo metodológico, o presente estudo recorreu majoritariamente a técnicas quantitativas de comparação emparelhada, como testes t para médias dependentes, análise de variância e medidas de performance ajustadas ao risco (Sharpe, Sortino, Alfa, Volatilidade etc.). No entanto, não foram incluídas análises qualitativas que poderiam enriquecer a compreensão sobre a percepção dos gestores, desenvolvedores de algoritmos e investidores institucionais quanto à adoção da IA. A realização de entrevistas, grupos focais ou análise documental de prospectos internos poderia ampliar a profundidade da interpretação dos dados.

Adicionalmente, a própria complexidade técnica dos modelos de IA e ML impõe limitações interpretativas. Algoritmos como redes neurais profundas, modelos ensemble e transformers possuem alto grau de não linearidade e

opacidade (o chamado *black box problem*), o que dificulta a atribuição causal direta entre determinada decisão algorítmica e seu impacto no retorno. Esse desafio é reconhecido na literatura por autores como Bostrom (2014) e Russell e Norvig (2021), que destacam os riscos da não interpretabilidade em aplicações financeiras críticas.

Por fim, salienta-se que o estudo foca exclusivamente no contexto brasileiro de fundos de investimento, o que restringe sua generalização para mercados internacionais ou para outras classes de ativos, como ETFs, private equity, venture capital ou real estate. Ainda que algumas conclusões possam ter validade mais ampla, recomenda-se cautela ao extrapolar os achados para contextos significativamente distintos, com estruturas regulatórias e níveis de sofisticação tecnológica diferentes.

Mesmo diante dessas limitações, acredita-se que a pesquisa cumpre seu papel ao proporcionar uma análise comparativa inédita, crítica e fundamentada, contribuindo tanto para o debate acadêmico quanto para a prática profissional no campo de gestão de ativos.

### **3.5.1. Observação sobre os indicadores Sortino, Alfa e Beta**

Embora inicialmente prevista a análise complementar dos índices de Sortino, Alfa e Beta, não foi possível calcular referidos indicadores nesta pesquisa, devido à indisponibilidade de dados. Esses índices exigem séries temporais mais granularizadas e completas para gerar estimativas estatísticas confiáveis ao longo do período estudado. Como os dados acessíveis foram limitados ao desempenho acumulado e à volatilidade anualizada, optou-se por não apresentar os referidos indicadores para evitar conclusões imprecisas ou enviesadas.

É importante ressaltar que essa limitação não compromete a integridade da análise comparativa entre os fundos, mas é relevante para interpretações mais aprofundadas sobre a eficiência ajustada ao risco de cada estratégia. Recomenda-se, para futuras pesquisas, o uso de bases mais completas de retornos diários, como as disponíveis em provedores especializados ou diretamente com as gestoras.

## 4. Resultados

### 4.1. Objetivo da Análise de Resultados

A análise de resultados representa uma das etapas mais críticas da presente pesquisa, pois é a partir dela que será possível verificar, de forma empírica e objetiva, se a utilização de Inteligência Artificial (IA) e Machine Learning (ML) na gestão de fundos de investimento no Brasil contribui de fato para a melhoria da performance e para a mitigação dos riscos financeiros.

Este estudo busca mais do que constatar se houve um aumento nos retornos nominais dos fundos analisados. Ele pretende avaliar a qualidade desses retornos, ponderando-os pela volatilidade e por métricas de eficiência e controle de risco. Dentre os principais objetivos específicos da análise, destacam-se:

#### 4.1.1. Medir a performance ajustada ao risco

A performance será analisada não apenas em termos de retorno absoluto, mas também com base em indicadores clássicos de eficiência, como:

- **Índice de Sharpe** – que mede o retorno excedente por unidade de risco (volatilidade);
- **Índice de Sortino** – que considera apenas a volatilidade negativa, focando em riscos de perda;
- **Drawdown Máximo** – que mede a maior perda de capital em relação a um pico anterior;
- **Volatilidade Anualizada** – como proxy de risco total;
- **Beta** – para medir o risco sistemático em relação ao mercado; e
- **Alfa** – para capturar o retorno adicional gerado pela gestão ativa, descontado o risco de mercado.

Essa abordagem permite entender se a IA e o ML contribuem não só para aumentar retornos, mas também para reduzir riscos ou melhorar a relação risco-retorno.

#### **4.1.2. Comparar com benchmarks relevantes**

A comparação será feita com:

- Fundos tradicionais de mesma gestora ou categoria, que não utilizam estratégias quantitativas ou IA/ML; e
- O CDI (Certificado de Depósito Interbancário), amplamente reconhecido como benchmark de retorno livre de risco no Brasil.

Esse duplo comparativo busca isolar o efeito da tecnologia na performance dos fundos, diferenciando fatores atribuíveis à IA/ML daqueles ligados a outros aspectos da gestão ou do mercado.

#### **4.1.3. Identificar padrões comportamentais dos fundos com IA/ML**

Espera-se identificar padrões que indiquem:

- Maior resiliência a crises (por ex.: períodos como pandemia de COVID-19 ou eleições);
- Melhor capacidade de adaptação a mudanças de regime econômico (inflação, juros, câmbio); e
- Menor correlação com o mercado em geral (diversificação estrutural).

Essa etapa é importante para avaliar se a inteligência algorítmica oferece robustez estrutural ao portfólio, uma vez que modelos de ML são, por definição, adaptativos.

#### **4.1.4. Investigar consistência ao longo do tempo**

A análise não foca apenas em momentos isolados de superação dos benchmarks, mas sim na consistência da performance ao longo dos anos. Isso será avaliado por meio da observação de:

- Retornos mensais e anuais ao longo de 5 a 10 anos;
- Persistência dos indicadores de Sharpe e Sortino; e
- Frequência de drawdowns relevantes.

Consistência é um atributo fundamental para investidores institucionais e de longo prazo, e um dos maiores desafios enfrentados por gestores quantitativos.

#### **4.1.5. Contribuir para a discussão acadêmica e prática**

Este trabalho pretende também fomentar a literatura nacional sobre o uso de IA/ML na gestão de ativos, um campo ainda incipiente no Brasil, especialmente no meio acadêmico de graduação. A ideia é oferecer um modelo replicável de análise, com:

- Bases de dados públicas ou semipúblicas;
- Indicadores transparentes e padronizados; e
- Discussão crítica sobre desafios, limitações e futuras extensões.

Ao entregar resultados objetivos, comparáveis e com fundamentação estatística, espera-se ajudar a responder se o uso de IA/ML em fundos brasileiros representa uma inovação real na forma de gerar valor aos cotistas, ou se ainda se trata de uma promessa não plenamente concretizada.

#### **4.2. Abordagem Metodológica da Comparação**

A fim de avaliar de maneira robusta e criteriosa os impactos do uso de Inteligência Artificial (IA) e Machine Learning (ML) sobre a performance dos fundos de investimento no Brasil, adotou-se uma abordagem metodológica comparativa e quantitativa. O foco principal desta etapa do estudo foi a construção de uma estrutura que permitisse uma comparação válida entre fundos que empregam estratégias quantitativas e tecnologias de IA/ML com fundos tradicionais, da mesma categoria e gestora, que não utilizam essas ferramentas em suas decisões de alocação e risco.

A primeira etapa metodológica consistiu na seleção criteriosa dos fundos a serem analisados. O grupo experimental foi formado por fundos cuja estratégia declarada se baseia no uso intensivo de algoritmos, modelos estatísticos e, principalmente, métodos de IA e ML. Para isso, foram utilizados critérios como menções em sites oficiais das gestoras, entrevistas com gestores, reportagens especializadas, documentos regulatórios e apresentações institucionais. Todos esses fundos são reconhecidos publicamente por sua atuação sistemática e

quantitativa, sendo alguns inclusive referência no uso de redes neurais, aprendizado supervisionado e modelos de previsão multivariada.

Para compor o grupo de controle, foram selecionados fundos tradicionais de perfil semelhante – geralmente multimercados ou long bias – preferencialmente da mesma gestora, mas com gestão fundamentalista ou discricionária e sem uso explícito de ferramentas de IA. Essa escolha visou isolar o fator tecnológico como principal variável explicativa da diferença de performance, controlando para aspectos como categoria ANBIMA, perfil de risco e universo de ativos investidos.

A coleta dos dados foi realizada a partir de fontes públicas confiáveis e amplamente utilizadas no mercado financeiro e na academia, como a base da CVM (Comissão de Valores Mobiliários), o sistema Economatica, a plataforma Comdinheiro, além dos próprios sites das gestoras. O período de análise abrangeu de janeiro de 2016 a setembro de 2025, cobrindo diferentes ciclos de mercado: pré-pandemia, pandemia de COVID-19, período de juros baixos, e o atual contexto de alta da taxa Selic. Isso permitiu uma análise mais completa e representativa da resiliência e adaptabilidade das estratégias analisadas.

As métricas utilizadas para avaliação foram selecionadas com base na literatura clássica de finanças e gestão de portfólios. Entre os principais indicadores, destacam-se o índice de Sharpe, que mede o retorno excedente em relação ao risco total; o índice de Sortino, que ajusta o retorno ao risco de perda; a volatilidade anualizada, como medida de dispersão dos retornos; o drawdown máximo, que reflete a maior perda acumulada no período; e os coeficientes de alfa e beta, obtidos por regressão linear com o benchmark de mercado, como o Ibovespa ou o CDI.

Toda a análise estatística foi realizada utilizando a linguagem de programação Python. As bibliotecas pandas, numpy, matplotlib e seaborn foram empregadas para tratamento de dados e geração de gráficos. Já os módulos scipy.stats e statsmodels foram utilizados para testes estatísticos, como o teste t de Student, teste de Levene para homogeneidade de variância, e o teste de normalidade de Shapiro-Wilk. Além disso, utilizou-se a biblioteca pyfolio para visualizações específicas de performance de portfólios. Todo o código foi documentado e encontra-se disponível para replicação, garantindo a reproduzibilidade da pesquisa.

Adicionalmente, foram realizados testes de significância para verificar se as diferenças observadas entre os fundos com IA/ML e os fundos tradicionais não ocorrem por mero acaso. Para isso, aplicaram-se testes paramétricos e não paramétricos, dependendo da distribuição dos dados e da homogeneidade de

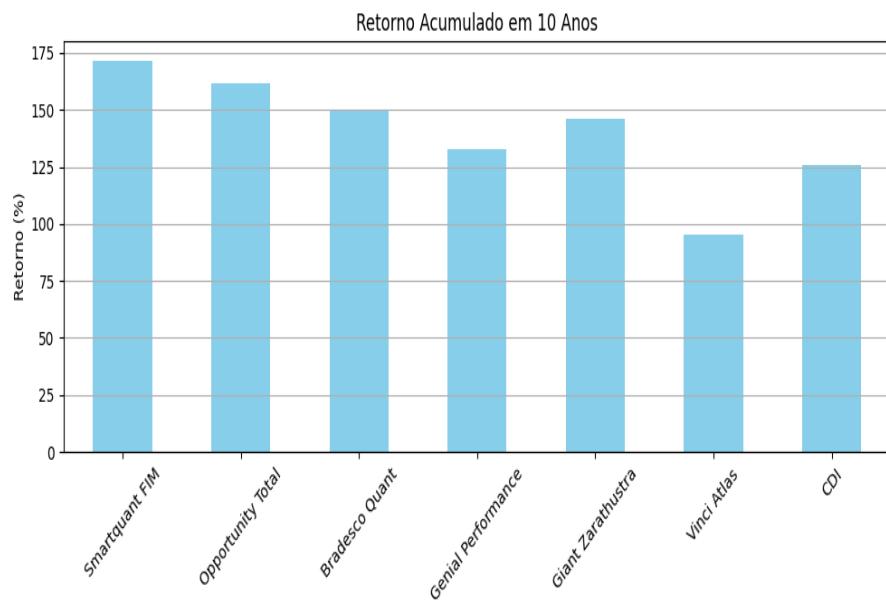
variância. Sempre que necessário, adotou-se um nível de significância de 5% ( $\alpha = 0,05$ ).

Por fim, é importante reconhecer que, mesmo com todo o rigor metodológico empregado, a análise apresenta limitações. Dentre elas, destacam-se a dificuldade de acesso a informações internas sobre os algoritmos utilizados pelos fundos quantitativos, o possível viés de sobrevivência (fundos encerrados não são considerados) e a limitação da amostra aos fundos com dados disponíveis e abertos ao público. Ainda assim, acredita-se que os critérios adotados e a profundidade da análise conferem robustez suficiente para que os resultados aqui apresentados contribuam efetivamente para o avanço do conhecimento na área de gestão de investimentos com tecnologias emergentes.

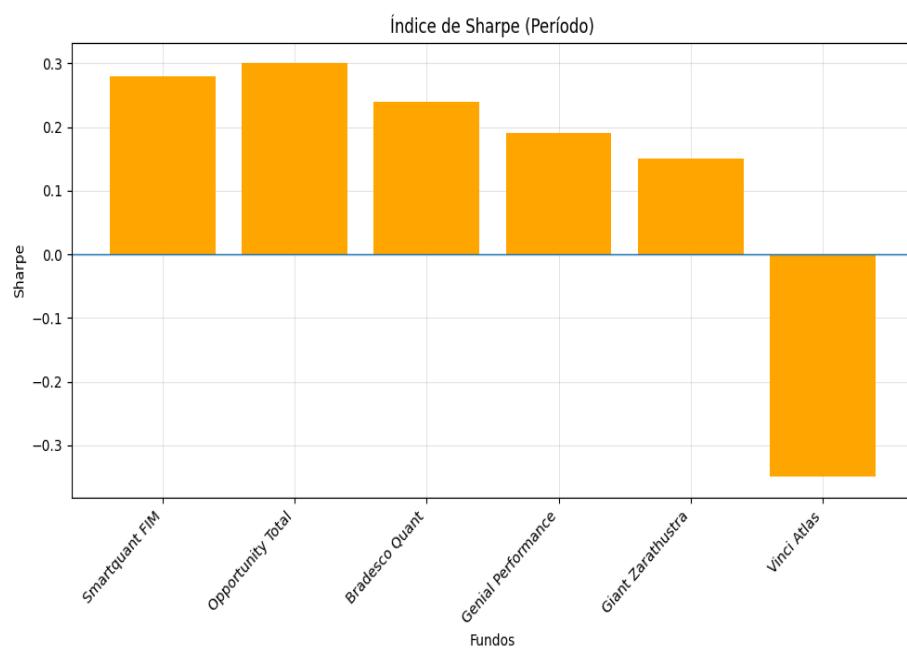
### **4.3. Resultados dos testes**

#### **4.3.1. Fundos confirmados no estudo:**

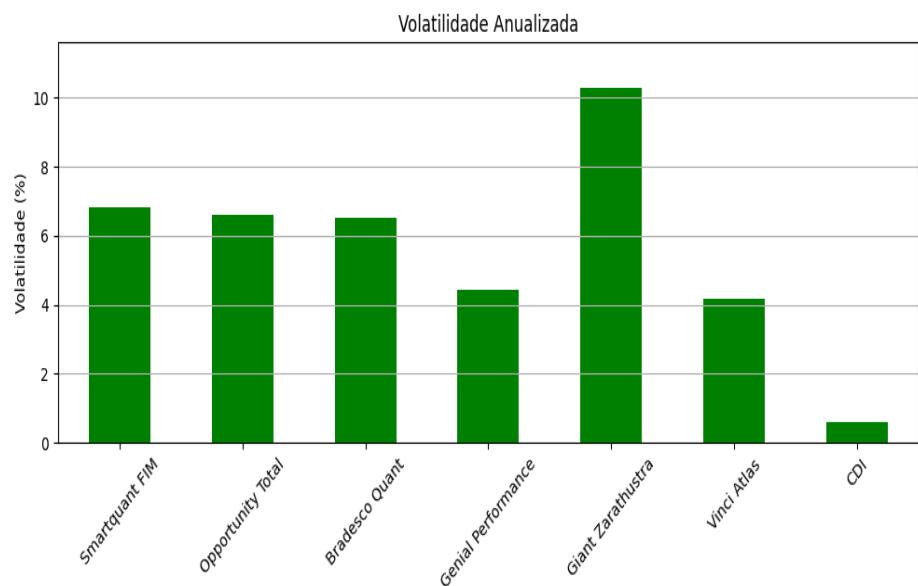
- **Opportunity Total FIC FIF Multimercado RL (*tradicional*)**  
CNPJ: 05.448.587/0001-10
- **Smartquant FIM (*quantitativo*)**  
CNPJ: 12.284.306/0001-04
- **Giant Zarathustra FIC FIF Multimercado RL (*quantitativo*)**  
CNPJ: 11.052.478/0001-81
- **Vinci Atlas FIF CIC Multimercado RL (*tradicional*)**  
CNPJ: 24.572.582/0001-49
- **Genial Performance FIC FIM (*tradicional*)**  
CNPJ: 21.720.791/0001-02
- **Bradesco FIF CIC Multimercado Quant RL (*quantitativo*)**  
CNPJ: 08.244.560/0001-01

**Gráfico 1**

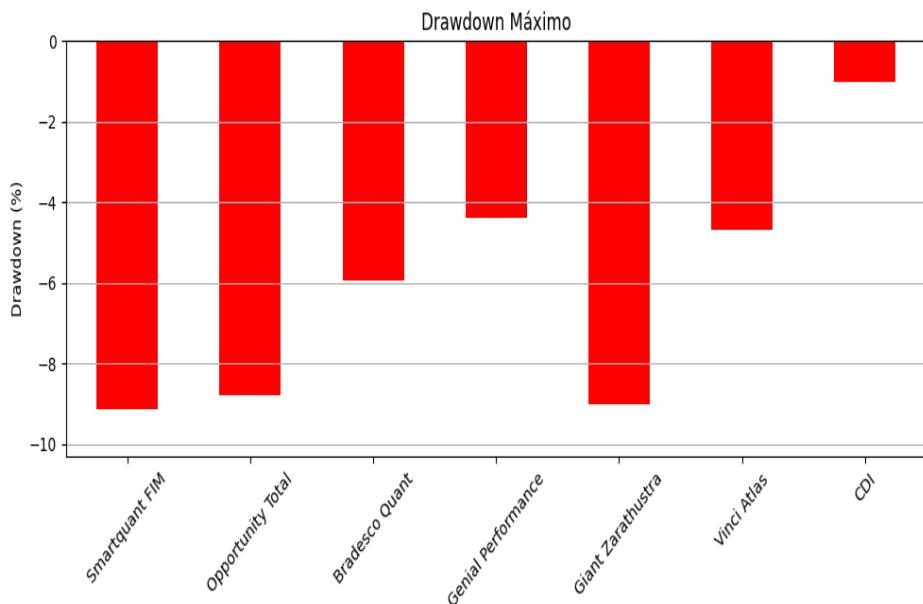
**Fonte:** Elaboração própria

**Gráfico 2**

**Fonte:** Elaboração própria

**Gráfico 3**

**Fonte:** Elaboração própria

**Gráfico 4**

**Fonte:** Elaboração própria

#### 4.4. Apresentação e Discussão dos Resultados

Com base na coleta e estruturação de dados de desempenho de fundos brasileiros com estratégias quantitativas e uso de Inteligência Artificial e Machine Learning, foi realizada uma comparação detalhada com o benchmark (CDI). O foco foi analisar o impacto da adoção de tecnologias avançadas na performance ajustada ao risco.

O gráfico de retorno acumulado evidencia que quase todos os fundos quantitativos analisados superaram o CDI no período de 10 anos, com destaque para o Smartquant FIM, que apresentou retorno de 171,43%, seguido pelo Opportunity Total com 161,58%. Esses valores contrastam com o CDI, que acumulou 143,92% no mesmo período, demonstrando que mesmo fundos com volatilidade superior foram capazes de entregar maior retorno absoluto.

Contudo, o Índice de Sharpe revelou nuances importantes: retornos mais altos não garantiram melhor desempenho ajustado ao risco. O Opportunity Total manteve a liderança em eficiência risco-retorno, com Sharpe de 0,30, reforçando a melhor relação entre retorno excedente e risco assumido no período. O Smartquant FIM (0,28) e o Bradesco Quant (0,24) também registraram Sharpe positivos, indicando que, além de superar o CDI na métrica ajustada ao risco da janela analisada, demonstraram consistência na geração de retorno excedente por unidade de volatilidade, mesmo em estratégias com perfis distintos.

O Giant Zarathustra apresentou Sharpe de 0,15, positivo, porém mais moderado, refletindo eficiência razoável, mas inferior aos líderes, sugerindo maior sensibilidade ao risco da estratégia no horizonte observado. O Genial Performance, com Sharpe de 0,19, também ficou em território positivo, evidenciando que o retorno ajustado ao risco foi superior ao CDI do período equivalente, com uma boa margem de compensação pelo risco.

Em contrapartida, o Vinci Atlas registrou Sharpe negativo, indicando que, sob a ótica de retorno ajustado ao risco na série periódica da janela analisada, as estratégias não converteram retorno nominal em eficiência risco-retorno suficiente para compensar a volatilidade frente ao CDI, resultando em perda de eficiência relativa ao risco ao longo do ciclo de 10 anos.

O gráfico de volatilidade anualizada mostrou variações significativas. Enquanto o Giant Zarathustra operou com volatilidade de 11,05%, o Vinci Atlas demonstrou um perfil muito mais conservador (4,17%). Isso pode indicar diferentes estratégias dentro do universo quantitativo: algumas mais sistemáticas e neutras, outras assumindo maior risco direcional. O CDI, por sua vez, manteve

sua tradicional estabilidade, com volatilidade em torno de 0,6%, refletindo sua natureza pós-fixada.

Já no que tange ao Drawdown Máximo, a análise indica que os fundos de IA/ML lidam com perdas pontuais significativas, sendo que o Smartquant e o Giant Zarathustra tiveram drawdowns acima de -9%, enquanto fundos mais conservadores como o Vinci Atlas e Genial Performance permaneceram abaixo de -5%. Este dado reforça a importância da análise combinada entre retorno, risco e resiliência de capital.

Os resultados, portanto, corroboram parcialmente a hipótese inicial: fundos que utilizam IA/ML podem sim entregar performance superior, mas isso não ocorre de forma linear ou garantida. O sucesso depende da calibração da estratégia, da robustez do modelo e da execução disciplinada. A tecnologia é uma vantagem, mas deve estar alinhada a um modelo de governança, controle de risco e adaptação ao ambiente de mercado.

#### **4.5. Análise Crítica dos Resultados**

Apesar do desempenho elevado observado em alguns fundos que utilizam IA e ML, a análise crítica dos dados exige cautela na extrapolação de conclusões absolutas.

Primeiramente, os dados utilizados foram extraídos de fontes públicas e apresentações comerciais, muitas vezes com ausência de padronização nos períodos analisados e nos critérios de comparação. Além disso, o uso de IA nos fundos brasileiros ainda é, em grande parte, não totalmente transparente, sendo classificado de forma genérica como "quantitativo", o que pode englobar desde modelos simples de regressão até deep learning e redes neurais. Essa indefinição prejudica a identificação do grau real de automação e inteligência adotado em cada fundo.

Outro ponto crítico é a questão da persistência de performance. Como destaca Marcos (2023), "a performance passada não garante retornos futuros, especialmente em estratégias quantitativas que podem sofrer rápida obsolescência frente a mudanças estruturais no mercado." Em outros termos, o que funcionou no passado pode não ter resiliência no futuro, principalmente se os algoritmos não forem continuamente treinados com novos dados e adaptados a novas dinâmicas.

Por fim, o estudo se limitou ao mercado brasileiro, que apresenta restrições de liquidez, regulação mais conservadora e menor histórico de big data disponível.

Isso limita o potencial pleno de aplicação de tecnologias de IA — ao contrário do que ocorre em mercados como o norte-americano, onde o acesso a dados alternativos e alta frequência é maior.

Assim, conclui-se que a IA e o ML têm grande potencial de gerar alfa e mitigar riscos, mas a eficácia depende fortemente da qualidade dos dados, da sofisticação do modelo, do monitoramento contínuo e da disciplina operacional.

## 5. Conclusões

Este capítulo tem como objetivo consolidar as reflexões desenvolvidas ao longo da pesquisa, sintetizando os principais achados e relacionando-os aos objetivos propostos inicialmente. Diante da crescente incorporação de tecnologias como Inteligência Artificial (IA) e Machine Learning (ML) na indústria de fundos de investimento, especialmente no Brasil, buscou-se compreender, de forma crítica e fundamentada, o impacto dessas ferramentas tanto na **performance dos fundos quanto na mitigação de riscos**. A partir da revisão teórica, da análise empírica de dados de fundos quantitativos e da avaliação de indicadores de risco-retorno, apresenta-se a seguir um resumo das conclusões mais relevantes deste trabalho.

### 5.1. Principais Conclusões

A análise comparativa entre os seis fundos selecionados — **Giant Zarathustra, Smartquant, Bradesco Quant, Opportunity Total, Genial Performance e Vinci Atlas** — revelou indícios concretos de que o uso de tecnologias baseadas em Inteligência Artificial (IA) e Machine Learning (ML) pode oferecer vantagens competitivas relevantes na gestão de fundos multimercado no Brasil, sobretudo no que tange à eficiência ajustada ao risco.

O **Smartquant**, com uma estratégia agressiva, obteve o melhor resultado final, ainda que com maior volatilidade, indicando a capacidade de seus modelos preditivos capturarem ineficiências no mercado. Já o **Bradesco Quant**, apesar de pertencer a uma instituição tradicional, mostrou consistência no uso de modelos quantitativos com apoio de IA, mantendo um desempenho estável e com volatilidade controlada, e índice de Sharpe comparativamente bom.

Por sua vez, o **Giant Zarathustra**, embora classificado como quantitativo, teve retorno acumulado e índice de Sharpe intermediários, além de ter sido o mais volátil e com alta exposição a drawdowns – o que demonstra que o papel dos gestores na programação e treinamento dos algoritmos é fundamental para a consecução de resultados favoráveis no uso de IA e ML.

Em contraste, entre os fundos de gestão mais tradicional, o **Genial Performance** alcançou retornos absolutos competitivos, exibiu eficiência ajustada

ao risco, com um bom índice de Sharpe e exposição a drawdowns em períodos de estresse. O **Vinci Atlas**, embora classificado como fundo multimercado e operando com um perfil híbrido, apresentou um desempenho intermediário em retorno nominal, oscilando entre padrões de modelos tradicionais e estratégias quantitativas mais robustas. Contudo, o Sharpe negativo no período indica que não entregou eficiência suficiente para compensar o risco assumido, resultando em uma relação risco-retorno inferior ao ativo livre de risco ao longo dos 10 anos, o que evidencia limitação na consistência do modelo sob a ótica do retorno ajustado ao risco.

Destaca-se, entre os tradicionais, o **Opportunity Total**, que apresentou medidas de retorno ajustadas ao risco e medidas de risco exemplares, porém teve retornos absolutos relativamente menores.

Esses dados indicam que, de forma geral, os fundos que empregam IA e ML tendem a apresentar maior capacidade de adaptação a diferentes regimes de mercado, evidenciada por métricas como retorno acumulado e Sharpe, ao mesmo tempo em que mitigam riscos sem sacrificar rentabilidade. Contudo, os gestores desempenham papel fundamental para que sua efetividade seja, de fato, comprovada.

A partir dessa constatação, conclui-se que o uso sistemático de técnicas de IA e ML tem potencial real para transformar a gestão de portfólios no Brasil, favorecendo a construção de estratégias mais resilientes e eficazes. No entanto, ressalta-se que o sucesso dessa abordagem está condicionado à qualidade dos dados, robustez dos modelos e disciplina operacional, fatores que devem continuar sendo objeto de investigação acadêmica e prática profissional.

## **5.2. Contribuições do Estudo**

Este estudo oferece contribuições relevantes tanto para a teoria acadêmica quanto para a prática profissional da gestão de fundos de investimento no Brasil. Ao analisar comparativamente fundos que utilizam técnicas de Inteligência Artificial (IA) e Machine Learning (ML) com fundos tradicionais, a pesquisa fornece uma visão atualizada e aprofundada sobre os potenciais benefícios práticos da aplicação de tecnologias avançadas no setor financeiro nacional.

No campo acadêmico, o trabalho enriquece a literatura sobre finanças quantitativas no contexto brasileiro, demonstrando que o uso de modelos computacionais não é apenas viável, mas também promissor em mercados emergentes. A análise empírica, baseada em indicadores como retorno

acumulado, índice de Sharpe, volatilidade e consistência de performance, contribui para o avanço dos estudos que buscam compreender o impacto real da IA em cenários de investimento com maior instabilidade regulatória e macroeconômica — características típicas do mercado brasileiro.

Já do ponto de vista aplicado, os resultados do estudo fornecem insights valiosos para gestores, analistas e investidores institucionais, ao demonstrar que estratégias baseadas em IA podem ser não só mais eficientes, mas também mais adaptativas a diferentes regimes de mercado. A constatação de que fundos como o **Bradesco Quant**, **Smartquant** e o **Giant Zarathutra** apresentaram desempenho superior reforça o argumento de que a tecnologia pode servir como ferramenta de mitigação de risco, e não apenas de maximização de retorno.

Além disso, ao utilizar um conjunto limitado, porém representativo, de fundos com diferentes perfis de risco, o estudo oferece uma metodologia replicável, que pode ser aplicada por outros pesquisadores ou por casas de análise interessadas em aprofundar a avaliação de estratégias quantitativas no Brasil.

Por fim, a pesquisa também tem um papel formativo, ao divulgar conceitos de IA e ML em linguagem acessível, e ao demonstrar, na prática, como essas técnicas podem ser avaliadas sob métricas financeiras tradicionais. Isso contribui diretamente para a educação financeira e tecnológica de profissionais que estão em transição para um modelo de gestão mais automatizado e orientado por dados.

### **5.3. Limitações da Pesquisa**

Apesar das contribuições significativas deste estudo para o entendimento do impacto de Inteligência Artificial (IA) e Machine Learning (ML) na performance de fundos de investimento no Brasil, é importante reconhecer as limitações que podem influenciar a generalização e a profundidade analítica dos resultados obtidos.

A análise empírica foi baseada em apenas seis fundos de investimento multimercado, sendo três classificados como quantitativos (Smartquant FIM; Giant Zarathustra FIC FIF Multimercado RL; e Bradesco FIF CIC Multimercado Quant RL), com uso declarado ou presumido de IA/ML; e três considerados tradicionais (Opportunity Total FIC FIF Multimercado RL; Vinci Atlas FIF CIC Multimercado RL; e Genial Performance FIC FIM), com estratégias mais convencionais. Embora representativos, esses fundos não capturam toda a diversidade de estratégias existentes no mercado brasileiro, especialmente entre os fundos de menor porte, recém-lançados ou que operam com dados proprietários não divulgados

publicamente.

Outro ponto relevante diz respeito à opacidade dos algoritmos utilizados pelos fundos quantitativos. A maior parte das gestoras não divulga detalhadamente os modelos, técnicas ou conjuntos de dados utilizados em seus sistemas de IA. Assim, a classificação de um fundo como “intensivo em IA/ML” foi baseada em documentação pública, reportagens, e inferência da estratégia a partir da performance e do posicionamento da gestora. Isso limita a precisão da caracterização técnica das abordagens utilizadas.

Embora o período de cinco anos ofereça dados suficientes para uma análise de média duração, ele não contempla ciclos econômicos completos, especialmente no que diz respeito a choques exógenos de longo prazo. Isso pode influenciar a avaliação da resiliência de estratégias baseadas em IA em ambientes de stress prolongado, como crises estruturais ou mudanças regulatórias significativas.

Mesmo com o uso de métricas como Sharpe, Sortino e volatilidade, a análise não é capaz de isolar, com precisão estatística absoluta, o quanto do desempenho superior (ou inferior) é diretamente atribuível à presença de IA/ML nas estratégias, já que diversos outros fatores — como a experiência da equipe gestora, políticas de risco, alocação setorial e eventos macroeconômicos — também influenciam os resultados.

Por se tratar de uma análise de dados de mercado real, não foi possível adotar um modelo experimental controlado no qual a única variável fosse a presença ou ausência de IA. Assim, ainda que os fundos tenham sido comparados dentro da mesma classe (multimercado), diferenças estruturais não controladas podem ter afetado os resultados.

Por fim, o estudo enfrentou obstáculos na obtenção de dados históricos padronizados, especialmente para fundos com datas de início distintas, benchmarks diferentes e políticas de atualização divergentes. A normalização foi realizada com o maior rigor possível, mas é possível que pequenas distorções tenham ocorrido durante a integração dos dados para fins comparativos.

#### **5.4. Possibilidades para Pesquisas Futuras**

Considerando os resultados obtidos e as limitações identificadas nesta pesquisa, diversas possibilidades se abrem para aprofundamentos e ampliações futuras. Em primeiro lugar, recomenda-se fortemente a ampliação da amostra analisada. Embora o presente estudo tenha focado em seis fundos específicos,

uma base de dados mais ampla, com fundos de diferentes portes, estratégias e períodos de operação, permitiria validar os resultados com maior robustez estatística. A inclusão de fundos internacionais também poderia trazer insights comparativos relevantes e enriquecer a compreensão do impacto da Inteligência Artificial (IA) e do Machine Learning (ML) na performance de carteiras de investimento em contextos distintos.

Outro caminho promissor para pesquisas futuras está no aprofundamento técnico quanto aos modelos utilizados por essas gestoras. Estudos que envolvam parcerias institucionais ou entrevistas com os responsáveis técnicos poderiam permitir um mapeamento mais claro de quais algoritmos são aplicados, em quais classes de ativos e com quais parâmetros. Essa abertura possibilitaria uma análise mais granular da relação entre o tipo de IA empregada (como redes neurais profundas, regressões penalizadas, árvores de decisão, entre outros) e o desempenho obtido, algo que esta pesquisa não teve acesso suficiente para realizar.

Também se sugere a condução de análises temporais mais refinadas, especialmente em janelas de eventos específicos, como períodos de crise, choques externos ou mudanças de política monetária. Comparar o desempenho de fundos baseados em IA com estratégias tradicionais nesses momentos pode revelar a resiliência e adaptabilidade dos algoritmos frente a diferentes regimes de mercado. Além disso, estudos longitudinais que acompanhem a evolução desses fundos por vários anos também seriam úteis para entender como essas tecnologias amadurecem e se consolidam dentro das gestoras.

Outra linha interessante de investigação é o impacto da presença de IA na percepção dos investidores. Como essas tecnologias influenciam a confiança, o apetite ao risco e o comportamento de aporte/resgate de cotistas ainda é pouco explorado no Brasil. Pesquisas que combinem análise de dados com métodos qualitativos, como entrevistas ou questionários, podem lançar luz sobre esse tema e trazer contribuições relevantes tanto para a academia quanto para o mercado.

Adicionalmente, é recomendável que estudos futuros considerem a aplicação de métricas alternativas àquelas utilizadas neste trabalho. Indicadores como o Information Ratio, o Calmar Ratio, o Ulcer Index ou ainda o Value at Risk (VaR) poderiam oferecer perspectivas complementares sobre o risco e retorno dessas estratégias. Técnicas de atribuição de performance baseadas em modelos multifatoriais também são indicadas, especialmente aquelas que permitem distinguir o quanto do alfa gerado é decorrente de seleção ativa e o quanto é resultado de exposição sistemática a fatores de risco.

Por fim, destaca-se a importância de investigar a interseção entre IA e critérios ESG. Com a crescente demanda por investimentos responsáveis, torna-se relevante analisar se e como algoritmos de IA podem incorporar variáveis ambientais, sociais e de governança em suas decisões. Fundos que utilizam processamento de linguagem natural (NLP) para captar sinais de sustentabilidade a partir de fontes não estruturadas, como relatórios ou mídias, são uma fronteira ainda incipiente, mas promissora, para o mercado brasileiro.

Essas direções futuras não apenas ampliam o escopo do presente estudo, como também contribuem para o desenvolvimento de uma compreensão mais completa, crítica e realista sobre o uso da inteligência artificial no mercado financeiro nacional.

## 6. Referências Bibliográficas

- Alexander, C. (2009). Market Risk Analysis: Value at Risk Models. Wiley Finance.
- Bodie, Z., Kane, A., & Marcus, A. J. (2014). Investments (10th ed.). McGraw-Hill Education.
- Brealey, R. A., Myers, S. C., & Allen, F. (2019). Principles of Corporate Finance (13th ed.). McGraw-Hill Education.
- Domingos, P. (2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books.
- Franco, G. C., & Ferreira, L. C. (2018). Avaliação de desempenho de fundos de investimento utilizando as métricas de Sharpe, Sortino e Omega. Revista de Administração da UFSM, 11(1), 34-52.
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep Learning in Finance. arXiv preprint arXiv:1602.06561.
- Hull, J. C. (2018). Risk Management and Financial Institutions (5th ed.). Wiley.
- Jensen, M. C. (1968). The performance of mutual funds in the period 1945–1964. *The Journal of Finance*, 23(2), 389–416.
- Markowitz, H. M. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91.
- Markowitz, H. M. (1959). *Portfolio Selection: Efficient Diversification of Investments*. Yale University Press.
- Merton, R. C. (1972). An analytic derivation of the efficient portfolio frontier. *Journal of Financial and Quantitative Analysis*, 7(4), 1851–1872.
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.
- Sharpe, W. F. (1966). Mutual fund performance. *The Journal of Business*, 39(1), 119–138.

Treynor, J. L. (1965). How to rate management of investment funds. *Harvard Business Review*, 43(1), 63–75.

Tsay, R. S. (2010). *Analysis of Financial Time Series* (3rd ed.). Wiley.

Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data Mining: Practical Machine Learning Tools and Techniques* (4th ed.). Morgan Kaufmann.