



ESTUDO APLICADO DE UM ASSISTENTE DE INVESTIMENTOS PARA RECOMENDAÇÃO DE AÇÕES BASEADOS EM IA

João Victor Miotelli Vitali¹

Lucas de Oliveira Alano²

Max Gabriel Steiner³

Vagner da Silva Rodrigues⁴

Anderson Rodrigo Farias⁵

Resumo: Este estudo tem como proposta investigar o uso da Inteligência Artificial na construção de carteiras de investimento personalizadas, com foco na adaptação ao tipo de investidor. Para isso, foi desenvolvido um sistema baseado em aprendizado de máquina, capaz de ranquear composições de ativos conforme critérios técnicos, preditivos e alinhados ao nível de tolerância de cada perfil. O modelo foi submetido a testes em dois contextos econômicos distintos, com resultados comparativos a *benchmarks* amplamente utilizados no setor financeiro. Os resultados revelam padrões relevantes de comportamento entre os perfis avaliados e abrem espaço para reflexões sobre o potencial de soluções inteligentes na gestão de portfólios. O sistema demonstrou ser uma alternativa promissora para investidores que buscam decisões mais autônomas, técnicas e alinhadas à sua tolerância ao risco.

Palavras-chave: inteligência artificial; investimentos; perfil de risco; ranqueamento de carteiras; aprendizado de máquina.

1 INTRODUÇÃO

Ao longo dos anos, um dos meios mais utilizados para a geração de riqueza tem sido os investimentos, permitindo que recursos modestos se tornassem grandes ativos. No entanto, essa trajetória envolve tanto riscos quanto recompensas. Embora muitos investidores consigam obter retornos expressivos por meio de decisões estratégicas bem fundamentadas, outros acabam enfrentando prejuízos significativos em razão de escolhas equivocadas ou de mudanças inesperadas no cenário econômico (Torres; Barros, 2014).

¹ Graduando em Engenharia de Software – Centro Universitário UniSATC. E-mail: joaomiotelli17@gmail.com.

² Graduando em Engenharia de Software – Centro Universitário UniSATC. E-mail: lucasdeoliveiraalano@gmail.com

³ Professor do Centro Universitário Unisatc. E-mail: max.steiner@satc.edu.br

⁴ Professor do Centro Universitário Unisatc. E-mail: vagner.rodrigues@satc.edu.br

⁵ Professor do Centro Universitário Unisatc. E-mail: anderson.farias@satc.edu.br



De acordo com Oliveira (2021), o mercado financeiro contemporâneo é caracterizado por um alto grau de complexidade e constante transformação. Com o avanço das tecnologias e o aumento exponencial no volume de informações disponíveis, tornou-se cada vez mais difícil para os investidores interpretar os dados e tomarem decisões bem fundamentadas. Nesse cenário, compreender e equilibrar a relação entre risco e retorno torna-se ainda mais essencial. Esse é um dos conceitos centrais no universo dos investimentos: enquanto investidores conservadores priorizam a minimização de incertezas e a previsibilidade dos resultados, há também aqueles com perfil mais arrojado, dispostos a assumir possibilidade de perdas maiores em busca de ganhos potencialmente mais elevados (Ceretta; Costa Jr., 2001; Assaf Neto, 2021).

Diante desse cenário de escolhas complexas e perfis de risco variados, é interessante observar como os brasileiros que aplicam recursos têm se comportado. Nos últimos anos, o mercado de investimentos nacional apresentou um crescimento notável. Na edição mais recente do Raio X do Investidor Brasileiro, publicada pela ANBIMA em 2024, constatou-se que 37% da população adulta já possui algum tipo de aplicação financeira, totalizando aproximadamente 59 milhões de investidores. Esse avanço foi impulsionado principalmente pelo segmento de renda fixa, refletindo a preferência do público por ativos mais estáveis em períodos de maior aversão à volatilidade (Pligher, 2024).

Além disso, o número de investidores em renda variável também apresentou crescimento, alcançando 5,3 milhões de pessoas, um aumento de 6% em relação ao ano anterior. Esses dados reforçam o interesse crescente da população brasileira por alternativas de maior rentabilidade, mesmo diante dos riscos envolvidos. Ainda assim, essa participação segue modesta diante do total de adultos no país, indicando amplo potencial de expansão, especialmente ao se considerar que 32 milhões de brasileiros possuem reservas financeiras, mas ainda não investem (ANBIMA, 2024).

Nesse contexto de crescente inserção da população brasileira no mercado financeiro, torna-se ainda mais relevante compreender os fatores que influenciam as decisões de investimento e o comportamento dos investidores. O aumento no volume de recursos aplicados, tanto em renda fixa quanto em renda variável, reforça a importância de ferramentas que auxiliem na análise de riscos, tendências e



oportunidades. É justamente nesse ponto que a tecnologia, especialmente as soluções baseadas em aprendizado de máquina, surge como um diferencial estratégico.

Nos últimos anos, a Inteligência Artificial (IA) tem sido amplamente empregada para resolver problemas complexos, extraíndo padrões ocultos em grandes volumes de dados. De acordo com Medeiros (2018), essa tecnologia tem se consolidado como uma aliada estratégica no mercado financeiro, transformando a maneira como investidores e instituições interpretam dados e tomam decisões. Leippold, Wang e Zhou (2022) reforçam que, por meio de técnicas de aprendizado de máquina (*machine learning*), torna-se possível treinar sistemas para reconhecer comportamentos recorrentes, adaptar-se a novos contextos e oferecer suporte a decisões mais embasadas. A principal vantagem dessa abordagem, conforme destaca Luger (2013), reside na capacidade da IA de processar dados com agilidade, precisão e consistência - algo que seria extremamente trabalhoso, ou até mesmo inviável, para um ser humano realizar manualmente.

No entanto, apesar do avanço das tecnologias e da maior disponibilidade de dados, muitos investidores ainda enfrentam dificuldades em interpretar corretamente essas informações e tomar decisões alinhadas ao seu perfil de risco. Essa lacuna entre o volume de dados disponíveis e a capacidade de transformá-los em conhecimento útil constitui o problema central deste estudo.

Assim, esta pesquisa tem como objetivo o desenvolvimento e a avaliação de um Assistente de Investimentos Automatizado baseado em técnicas de *machine learning*, com foco em aprendizado de máquina e modelagem computacional. A proposta busca responder a uma dor recorrente entre investidores, sendo essa a dificuldade de identificar, de forma personalizada, quais ativos da bolsa de valores são mais adequados ao seu estilo de investimentos. Para isso, será construído um sistema inteligente capaz de analisar dados do mercado e características individuais dos usuários, classificando seu perfil e sugerindo alocações otimizadas em ativos financeiros.

Dessa forma, a pergunta que orienta esta pesquisa é como o uso de técnicas de aprendizado de máquina pode contribuir para uma gestão de portfólios mais eficiente, equilibrando risco e retorno com base no perfil do investidor?



2 PROCEDIMENTOS EXPERIMENTAL

A presente seção descreve os procedimentos adotados para o desenvolvimento, implementação e avaliação do sistema de recomendação automatizado proposto neste trabalho. Todas as etapas foram conduzidas com base em dados históricos reais de mercado, organizadas de forma modular e replicável. A construção do sistema envolveu desde a seleção dos materiais computacionais até a definição da metodologia de simulação das carteiras, respeitando os perfis de risco previamente estabelecidos.

Trata-se de um estudo aplicado, de natureza quantitativa e abordagem experimental, voltado ao desenvolvimento e à validação de um modelo computacional preditivo para recomendação de investimentos personalizados. Segundo Gil (2017), as pesquisas aplicadas têm como finalidade gerar conhecimento direcionado à solução de problemas concretos, utilizando princípios teóricos consolidados como base para o desenvolvimento de ferramentas práticas.

2.1 MATERIAIS

Os materiais utilizados no desenvolvimento deste trabalho foram essencialmente computacionais, com foco em bibliotecas especializadas em manipulação de dados, aprendizado de máquina e simulação de carteiras de investimentos. A seguir, são detalhados os principais componentes empregados ao longo do projeto.

2.1.1 Linguagem de Programação

Todo o projeto foi desenvolvido em *Python*, devido à sua robustez e à vasta gama de bibliotecas voltadas à ciência de dados e aprendizado de máquina, como *NumPy*, *pandas*, *scikit-learn* e *XGBoost*. Essa escolha permitiu não apenas a modelagem preditiva, mas também a automação dos processos de coleta, simulação e avaliação dos resultados. Além disso, a linguagem oferece uma sintaxe acessível e conta com forte suporte da comunidade científica (Raschka; Mirjalili, 2019; Oliveira; Costa, 2018).



2.1.2 Bibliotecas Utilizadas

As principais bibliotecas empregadas ao longo do projeto foram responsáveis por diferentes etapas, como manipulação de dados, modelagem preditiva e coleta automatizada de informações do mercado financeiro. A biblioteca *pandas* foi utilizada para a manipulação e organização de dados financeiros em estruturas tabulares. Já a *numpy* ofereceu suporte às operações. Para a geração dos gráficos utilizados na visualização dos resultados das carteiras simuladas, empregou-se a *matplotlib*. A *xgboost*, por sua vez, foi aplicada na construção de modelos supervisionados baseados em árvores de decisão otimizadas. Por fim, *yfinance* viabilizou a coleta automatizada de dados históricos de ações por meio da API do *Yahoo Finance*.

2.1.3 Dados Financeiros

Foram utilizados dados históricos de ações pertencentes ao S&P 500 (EUA) e ao IBrX 100 (Brasil), dois dos principais índices acionários de seus respectivos mercados.

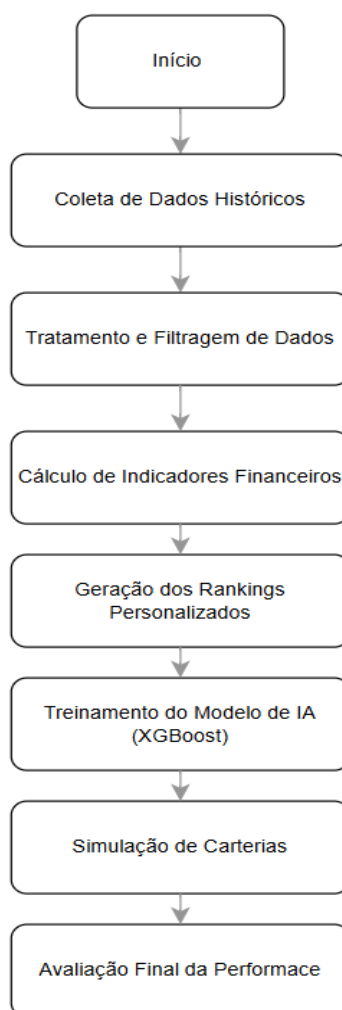
A coleta foi realizada por meio da biblioteca *yfinance*, com acesso a preços ajustados, volume de negociações e dividendos. Ativos com séries incompletas ou ausência de dados relevantes foram excluídos da análise.

3 DESENVOLVIMENTO

A seguir, apresenta-se a metodologia utilizada para o desenvolvimento do sistema automatizado de recomendação de investimentos. O processo foi estruturado de forma modular, permitindo a integração de múltiplas etapas, desde a coleta dos dados brutos do mercado até a simulação prática de carteiras personalizadas para diferentes perfis de risco.

Para facilitar a compreensão geral da arquitetura do projeto, o Fluxograma da Metodologia Experimental Fig. 1 sintetiza visualmente o encadeamento das etapas executadas.

Figura 1 – Fluxograma da Metodologia Experimental



Fonte: Autores (2025)

Etapas utilizadas na construção do sistema de recomendação, desde a coleta de dados históricos até a avaliação de performance das carteiras simuladas.

3.1.1 Coleta e Construção do Dataset

A primeira etapa fundamental da pesquisa consistiu na construção de um banco de dados robusto e confiável, capaz de refletir de maneira precisa e confiável o comportamento histórico dos ativos financeiros analisados. Para isso, foi realizada a coleta automatizada de dados históricos por meio da biblioteca *yfinance*, que fornece acesso estruturado à API pública do *Yahoo Finance*. Essa ferramenta permitiu a extração direta de informações detalhadas sobre ações listadas tanto na bolsa norte-



americana (S&P 500) quanto na bolsa brasileira (IBrX 100), garantindo diversidade geográfica e representatividade setorial na base de análise.

Foram coletadas as principais variáveis necessárias para a simulação de investimentos realistas, incluindo o fechamento diário, o volume diário negociado e os valores de dividendos pagos por cada ativo ao longo do tempo. Esses dados foram organizados em séries temporais diárias, possibilitando análises em alta granularidade e a posterior aplicação de cálculos estatísticos e comparativos. Ao priorizar a extração direta de dados financeiros brutos da fonte, buscou-se eliminar vieses e garantir maior reprodutibilidade dos experimentos.

O período total coberto pela base de dados se estendeu de 2000 a 2025, possibilitando uma visão histórica ampla e atualizada. No entanto, para fins de construção das carteiras e avaliação do desempenho, foi adotada uma janela principal de análise entre 2010 e 2020, onde ocorreram as decisões simuladas de investimento. Com base nessa estrutura, os resultados foram validados de forma retroativa até o ano de 2025, permitindo medir os efeitos das recomendações ao longo de um horizonte de cinco anos com dados reais de mercado.

3.1.2 Construção do Sistema Automatizado

A segunda etapa do projeto consistiu no desenvolvimento de um sistema automatizado capaz de processar os dados financeiros coletados, classificar os ativos conforme o perfil do investidor e simular a evolução de carteiras ao longo do tempo. Todo o sistema foi construído com base em técnicas de aprendizado supervisionado, empregando uma arquitetura modular que possibilita a replicação e expansão dos experimentos com facilidade.

O núcleo do sistema foi implementado em *Python*, com a utilização de bibliotecas específicas para manipulação de dados, cálculos estatísticos, construção de *rankings* e simulação de estratégias.

As recomendações geradas foram baseadas em parâmetros quantitativos, calculados previamente para cada ativo, como valorização média anual (*CAGR*), volatilidade e *drawdown*. A partir desses indicadores, os ativos foram classificados com base em um *score* de desempenho previsto para o ano seguinte, utilizando o



modelo *XGBoost*, reconhecido pela sua alta capacidade preditiva e robustez em dados tabulares.

Esse *score* serviu como base para o ranqueamento dos ativos dentro de cada perfil de investidor, permitindo uma seleção coerente com o nível de risco associado a cada composição. O sistema, portanto, consolida em um único fluxo a coleta, o processamento, a recomendação e a avaliação dos ativos de maneira sistemática, contribuindo para a construção de portfólios simulados com fundamentos consistentes.

3.1.3 Definição dos Perfis de Investidor

A categorização dos perfis de investidor é uma etapa essencial em qualquer sistema de recomendação de ativos, pois garante que as sugestões estejam alinhadas ao nível de tolerância ao risco e aos objetivos financeiros de cada usuário. Essa classificação é amplamente utilizada no mercado financeiro e serve como base para personalizar estratégias de investimento conforme o comportamento esperado de cada tipo de investidor (Assaf Neto, 2021).

Neste estudo, foram definidos três perfis clássicos: conservador, moderado e arrojado. Cada perfil representa uma forma distinta de lidar com os riscos de mercado e com as expectativas de retorno no longo prazo (Souza; Lima, 2021).

3.1.3.1 Perfil Conservador

O investidor conservador apresenta baixa tolerância à volatilidade e a perdas financeiras, mesmo que sejam momentâneas. Esse perfil prioriza a segurança, optando por estratégias que ofereçam maior previsibilidade nos retornos, mesmo que isso limite o potencial de valorização no longo prazo (Assaf Neto, 2021).

No contexto da construção das carteiras, os ativos selecionados para o perfil conservador apresentaram histórico de performance estável, com baixa volatilidade, menor risco de *drawdown* e pagamento frequente de dividendos.



3.1.3.2 Perfil Moderado

O perfil moderado representa o investidor que busca equilíbrio entre segurança e rentabilidade. Esse grupo aceita uma exposição moderada ao risco, desde que haja expectativa razoável de retorno (Assaf Neto, 2021). A carteira ideal para essa abordagem é aquela que combina ativos com bons fundamentos e estabilidade, mas que também oferecem potencial de crescimento ao longo do tempo.

As carteiras simuladas para investidores moderados apresentam uma composição diversificada, unindo empresas com bom histórico de pagamento de dividendos e desempenho consistente, com outras de maior crescimento, porém risco mais elevado.

3.1.3.3 Perfil Arrojado

O investidor arrojado está disposto a assumir níveis mais elevados de risco em busca de maior rentabilidade no longo prazo. Esse perfil prioriza a valorização do capital, mesmo que isso implique em enfrentar períodos de maior volatilidade ou quedas temporárias no valor dos ativos (Souza; Lima, 2021).

As carteiras projetadas para o perfil arrojado concentram-se em empresas com alto potencial de valorização, mesmo que apresentem maior instabilidade nos retornos. O foco está na maximização dos resultados, assumindo os riscos inerentes a essa abordagem.

Ao estruturar essas categorias, o sistema de recomendação foi projetado para ajustar automaticamente os critérios de seleção e pontuação dos ativos conforme o perfil escolhido.

3.1.4 Parâmetros Utilizados na Construção das Carteiras

A construção das carteiras simuladas foi guiada por indicadores financeiros clássicos, amplamente reconhecidos na literatura de finanças quantitativas e utilizados na gestão de portfólios, como os descritos por Damodaran (2012) e Bodie, Kane e Marcus (2014). Esses parâmetros, extraídos diretamente de dados históricos



de mercado, fundamentaram a atribuição de pontuações, a ordenação dos ativos por desempenho e a posterior seleção dos componentes de cada carteira conforme o perfil de investidor.

3.1.4.1 Valorização Esperada (CAGR)

O *CAGR* (*Compound Annual Growth Rate*), ou taxa composta de crescimento anual, representa a valorização média anual de um ativo ao longo de um determinado período, assumindo um crescimento constante. Ele é calculado com base no valor inicial e final do ativo, considerando o número de anos entre os dois pontos (ASSAF NETO, 2021; DAMODARAN, 2012). A Equação (1) apresenta a fórmula utilizada para esse cálculo:

$$CAGR = \left(\frac{Vf}{Vi} \right)^{\frac{1}{n}} - 1 \quad (1)$$

Onde:

V_f = valor final;

V_i = valor inicial;

N = número de anos;

3.1.4.2 Volatilidade Histórica

A volatilidade mede a intensidade das oscilações nos preços de um ativo ao longo do tempo, sendo diretamente associada ao grau de incerteza do retorno esperado. Ativos com maior volatilidade apresentam grandes variações de preço em curtos períodos, enquanto aqueles com baixa volatilidade tendem a ter preços mais estáveis (Bodie; Kane; Marcus, 2014; Damodaran, 2012).

Neste projeto, a volatilidade foi calculada com base no desvio padrão dos retornos diários dos ativos dentro da janela de análise. O desvio padrão (σ) é uma medida estatística que expressa o quanto os valores de uma série se afastam da média, sendo amplamente adotado como métrica de risco em finanças (Assaf Neto, 2021). A Equação (2) apresenta a fórmula utilizada



$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (R_i - \bar{R})^2} \quad (2)$$

Onde:

σ (sigma): desvio padrão dos retornos (representa a volatilidade do ativo)

R_i : retorno diário do ativo no dia i

\bar{R} (R com barra): média dos retornos diários no período analisado

n : número total de observações (dias úteis)

3.1.4.3 Drawdown Máximo

O *drawdown* máximo representa a maior perda percentual registrada em uma sequência de quedas no valor de um ativo ou carteira, a partir de um pico anterior até o ponto mínimo subsequente. Esse indicador é amplamente utilizado em análises de risco por sua capacidade de expressar a profundidade de perdas acumuladas, sendo especialmente relevante para investidores com baixa tolerância a perdas significativas (Damodaran, 2012; Bodie; Kane; Marcus, 2014).

Ao considerar o *drawdown* na composição das carteiras, foi possível evitar a seleção de ativos com histórico de perdas prolongadas, favorecendo a resiliência das alocações simuladas em diferentes cenários econômicos. A Equação (3) apresenta a fórmula utilizada para o cálculo do *Drawdown* Máximo:

$$DD_{max} = \max_{t \in [0, T]} \left(\frac{P_{pico} - P_t}{P_{pico}} \right) \quad (3)$$

Onde:

$DD_{máx}$: maior perda percentual observada no período

P_{pico} : maior valor atingido até o tempo t

P_t : valor do ativo na data t

T : total de dias no período analisado



Esse indicador, juntamente com o *CAGR* e a volatilidade, foi calculado para todos os ativos elegíveis e posteriormente integrado a uma lógica de pontuação ponderada, conforme o perfil de risco definido, abordado no tópico seguinte.

3.1.5 Geração de Rankings

Após o cálculo dos indicadores fundamentais, como valorização esperada (*CAGR*), volatilidade histórica e *drawdown* máximo, os ativos foram organizados em *rankings* específicos para cada perfil de investidor, considerando os diferentes níveis de tolerância ao risco e os objetivos estratégicos de cada categoria.

A lógica de pontuação foi construída com base em pesos específicos atribuídos a cada métrica de avaliação, levando em conta as prioridades e características específicas de cada tipo de investidor. Essa diferenciação foi essencial para que a seleção de ativos refletisse não apenas os melhores desempenhos absolutos, mas também a compatibilidade de cada ativo com os objetivos e a tolerância ao risco da categoria analisada (Souza; Lima, 2021; Pligher, 2024).

No caso do investidor conservador, o sistema priorizou fortemente a estabilidade e a proteção do capital. Por isso, os ativos com baixa volatilidade e baixo *drawdown* histórico receberam os maiores pesos na composição da nota final. A valorização média anual (*CAGR*) teve um peso secundário, sendo considerada apenas quando não compromettesse a segurança da carteira. O foco aqui foi minimizar perdas e incertezas, mesmo que isso implicasse em renunciar as maiores rentabilidades (Gonçalves et al., 2020).

Já o perfil moderado buscou o equilíbrio entre risco e retorno, representando um investidor que está disposto a aceitar oscilações moderadas em troca de um desempenho mais expressivo no longo prazo. Esse comportamento é típico de perfis que desejam mitigar perdas significativas sem abrir mão de certa valorização consistente ao longo do tempo (Souza; Lima, 2021; Assaf Neto, 2021). Nesse caso, os pesos atribuídos às três métricas (*CAGR*, volatilidade e *drawdown*) foram mais equilibrados, garantindo que os ativos escolhidos tivessem uma boa performance histórica, mas sem apresentar níveis extremos de instabilidade.



Por fim, o perfil arrojado foi projetado para investidores com alta tolerância ao risco, tendo como principal objetivo maximizar os ganhos no longo prazo. Estudos apontam que esse tipo de investidor está mais exposto a perdas temporárias acentuadas, sendo sujeito a ciclos de alta volatilidade, com maior potencial de valorização futura (Souza; Lima, 2021; Machado; Souza, 2022; Gonçalves et al., 2020). Por isso, a valorização esperada (CAGR) teve peso predominante na pontuação dos ativos, enquanto a volatilidade e o *drawdown* foram considerados, mas com menor influência negativa.

Com base nesses critérios ponderados, cada ativo recebeu uma pontuação consolidada, que refletia seu grau de aderência ao perfil-alvo. A pontuação serviu para organizar os ativos em *rankings* específicos por tipo de investidor, em ordem decrescente de *score*. Esses *rankings* foram fundamentais para guiar a seleção final dos ativos que compuseram as carteiras simuladas, garantindo coerência entre os objetivos estratégicos da categoria analisada e a lógica aplicada na escolha dos ativos.

3.1.6 Modelagem e Simulação

Com os ativos devidamente ranqueados para cada perfil de investidor, a etapa final da metodologia consistiu na simulação das carteiras, com o objetivo de testar, de forma prática, a eficácia das recomendações geradas pelo sistema. Essa fase permitiu observar o desempenho real das carteiras ao longo do tempo, com base em dados históricos do mercado.

Após o tratamento inicial, o sistema aplicou um modelo preditivo utilizando o algoritmo *XGBoost*, que gerou uma pontuação baseada no desempenho esperado dos ativos para o ano seguinte. Essa pontuação foi usada para definir a ordem de prioridade de cada ativo dentro dos respectivos perfis de investidor.

A partir dos ativos obtidos, foram montadas carteiras simuladas para cada perfil, utilizando um capital inicial fixo de R\$10.000,00. Esse valor foi distribuído entre os ativos que compõem as vinte carteiras simuladas, formadas a partir das melhores combinações conforme os critérios definidos. Em seguida, essas alocações foram acompanhadas ao longo de cinco anos, com reinvestimento automático dos

dividendos recebidos durante o período, simulando de forma mais realista o comportamento de um investidor de longo prazo.

Por fim, o sistema gerou gráficos de desempenho e calculou métricas como retorno acumulado, volatilidade e *drawdown* máximo, além de realizar comparações com os principais benchmarks do mercado, como o CDI e o Ibovespa. Essa análise teve como objetivo estruturar os dados necessários para a avaliação da aderência das carteiras aos diferentes perfis de risco, conforme proposto na metodologia.

A Fig. 2 ilustra uma das vinte carteiras simuladas para o perfil arrojado no período de 2015 a 2020, permitindo visualizar a evolução de valor ao longo do tempo em comparação com o benchmark de mercado.

Figura 2 – Desempenho acumulado da Carteira 7 (Perfil Arrojado) 2015–2020



Fonte: Autores (2025)

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os principais resultados das simulações realizadas com o sistema de recomendação, considerando os diferentes perfis de investidor. A análise inclui métricas de desempenho e comparações com benchmarks, com o objetivo de verificar a eficácia do modelo em dois cenários econômicos distintos: o mercado americano e o mercado brasileiro.



4.1 INTRODUÇÃO AOS RESULTADOS

Esta seção, apresenta os resultados obtidos pelas simulações realizadas com o sistema de recomendação, aplicadas aos diferentes perfis de investidor. As análises foram conduzidas em dois contextos econômicos distintos: o mercado americano e o mercado brasileiro, ao longo do período de 2010 a 2020, com o objetivo de avaliar o desempenho das carteiras em cenários reais e contrastantes.

Todas as simulações seguiram uma configuração padrão composta por investimento inicial fixo de R\$10.000,00, reinvestimento automático de dividendos e um horizonte de avaliação de cinco anos a partir da data de entrada. Essa escolha foi baseada na classificação da Comissão de Valores Mobiliários (CVM), que considera investimentos com prazo superior a três anos como sendo de longo prazo, sendo cinco anos um intervalo amplamente aceito para avaliação da consistência de estratégias de alocação (CVM, 2021). Essa padronização garantiu que os diferentes perfis fossem avaliados sob condições idênticas, assegurando maior consistência na comparação e interpretação dos resultados.

Os resultados desta etapa foram segmentados conforme os três perfis previamente definidos: conservador, moderado e arrojado. Essa divisão permitiu analisar de forma comparativa como cada estratégia se comportou diante das condições de mercado simuladas. Para cada grupo, foram consideradas métricas de desempenho como retorno composto (*CAGR*), volatilidade histórica, *drawdown* máximo e valor final acumulado ao término da simulação.

No caso do mercado americano, o S&P 500 foi adotado como *benchmark*, por se tratar do principal índice de ações dos Estados Unidos. Ele serviu como referência para comparar o desempenho das carteiras simuladas com o comportamento geral do mercado.

As análises a seguir têm como objetivo não apenas quantificar os resultados, mas também interpretar os impactos práticos das recomendações feitas pelo sistema. O foco está em verificar se os resultados obtidos estão de acordo com os perfis definidos e se as estratégias propostas demonstram viabilidade para aplicação em cenários reais de investimento.



4.1.1 Introdução à Análise das Ações Americanas

A análise a seguir apresenta os resultados obtidos pela aplicação do sistema de recomendação no mercado de ações norte-americano, um dos ambientes mais competitivos e consolidados do mundo. A escolha desse cenário permitiu avaliar a robustez da estrutura de inteligência computacional, confrontando suas recomendações com um ecossistema altamente estruturado, líquido e dinâmico.

A seleção dos ativos foi realizada com base nos perfis de risco definidos e nos *rankings* gerados pela IA com base em critérios técnico-quantitativos.

O objetivo desta etapa é verificar se a lógica aplicada se mantém coerente mesmo em um ambiente com características econômicas distintas, analisando a aderência dos resultados aos perfis e sua competitividade frente a *benchmarks* como o S&P 500 e o CDI real médio.

4.1.2 Desempenho Médio por Perfil das Ações Americanas (2010–2020)

A Tabela 1 apresenta os resultados médios obtidos pelas carteiras simuladas pela IA no mercado norte-americano entre 2010 e 2020. As análises foram segmentadas conforme os três perfis de risco definidos na metodologia: conservador, moderado e arrojado. Onde os dados apresentados representam o desempenho médio das carteiras geradas para cada categoria ao longo do período.

Para garantir uma avaliação estatisticamente confiável e evitar distorções causadas por desempenhos extremos, os valores médios apresentados nesta seção foram calculados exclusivamente a partir dessas vinte composições anuais por categoria analisada. Essa abordagem tem como objetivo representar o comportamento típico da IA ao longo do tempo, excluindo exceções de performance fora da curva e proporcionando uma visão mais equilibrada e realista do sistema.

No total, foram simulados onze ciclos consecutivos de alocação, de 2010 a 2020, o que permitiu avaliar o desempenho do sistema em diferentes fases do mercado. Os valores apresentados a seguir representam a média desses ciclos, garantindo uma base sólida para as comparações entre perfis.

Tabela 1 – Resultados médios por perfil de investidor no mercado norte-americano
(2010–2020)

Perfil	CAGR (%)	Volatilidade (%)	Drawdown Máx. (%)
Conservador	14,32	18,68	28,33
Moderado	15,96	19,6	29,58
Arrojado	15,99	19,62	29,78

Fonte: Autores (2025)

Os resultados médios apresentados indicam que o sistema foi capaz de entregar desempenhos consistentes em todos os perfis avaliados. O retorno composto anual (*CAGR*) superou a marca de 14% ao ano em todos os casos, validando a capacidade da inteligência artificial em identificar ativos com potencial de valorização, sem ultrapassar os limites de risco definidos para cada estratégia.

O perfil arrojado registrou o maior retorno médio anual (15,99%), com volatilidade de 19,62% e *drawdown máximo* de 29,78%. Em seguida, o investidor moderado obteve desempenho bastante semelhante, com *CAGR* de 15,96%, volatilidade de 19,60% e *drawdown* de 29,58%. Já a categoria conservadora apresentou os menores valores nas três métricas analisadas, com rentabilidade média de 14,32%, volatilidade de 18,68% e *drawdown máximo* de 28,33%, confirmando seu posicionamento mais defensivo em relação ao risco.

A semelhança entre os resultados obtidos pelos perfis moderado e arrojado indica uma possível sobreposição parcial nas seleções de ativos realizadas pela IA ao longo do tempo. Esse comportamento sugere a necessidade de ajustes na lógica de pontuação utilizada, com o intuito de ampliar a diferenciação entre os perfis e tornar os resultados mais coerentes com as expectativas de risco e retorno em cenários práticos de investimento.

A repetição da metodologia por onze ciclos consecutivos contribui para a consistência estatística dos resultados, evidenciando a viabilidade da solução proposta como ferramenta de apoio à alocação estratégica de investimentos em mercados desenvolvidos.



4.1.3 Comparação com Benchmarks das Ações Americanas

Para avaliar a eficácia das carteiras geradas pela inteligência artificial desenvolvida neste trabalho no contexto do mercado norte-americano, foi realizada uma comparação entre os resultados médios obtidos nas simulações e dois benchmarks amplamente utilizados: o índice S&P 500, representando o desempenho da renda variável internacional, e o CDI brasileiro, principal indicador da renda fixa nacional (Assaf Neto, 2021).

O S&P 500, principal índice de ações dos Estados Unidos, reúne as 500 maiores empresas listadas na bolsa americana e é amplamente utilizado como referência global de desempenho em renda variável.

A Tabela 2 apresenta a comparação direta entre os ganhos médios anuais obtidos pelas carteiras simuladas pela IA e os dois *benchmarks* utilizados neste estudo, o S&P 500 e o CDI bruto. A análise foi segmentada por categoria de investidor, considerando os resultados consolidados para os grupos conservador, moderado e arrojado.

Tabela 2 – Comparação entre IA e benchmarks (2010–2020)

Perfil	CAGR IA (%)	S&P 500 (%)	CDI Bruto (%)
Conservador	14,32	13,6	9,22
Moderado	15,96	13,6	9,22
Arrojado	15,99	13,6	9,22

Fonte: Autores (2025)

Os resultados demonstram que as carteiras simuladas pela IA superaram de forma consistente ambos os *benchmarks* adotados. O perfil conservador apresentou um retorno médio de 14,32% ao ano, superando o S&P 500 (13,6%) e mantendo desempenho significativamente superior ao CDI (9,22%).

Os diferenciais foram ainda mais expressivos nos perfis moderado e arrojado, com ganhos de +2,36 e +2,39 pontos percentuais, respectivamente, em relação ao índice americano. Esses dados indicam que o sistema foi capaz de gerar retornos incrementais relevantes mesmo em um ambiente caracterizado por elevada eficiência de mercado.



Os resultados médios apresentados confirmam a capacidade do sistema de identificar composições competitivas, com desempenho superior aos benchmarks avaliados no período. Essa consistência entre os diferentes perfis reforça o potencial da abordagem adotada, especialmente em ambientes de alta liquidez e eficiência como o mercado norte-americano.

Nota metodológica: o CDI brasileiro foi utilizado aqui em sua forma bruta, sem correção cambial. Como os ativos simulados referem-se a empresas negociadas em dólar e o CDI está atrelado à economia brasileira em reais, o ideal seria descontar o efeito da desvalorização cambial do real frente ao dólar. No entanto, por limitação de dados, adotou-se o CDI médio anual bruto de 9,22% como uma referência prática, visando manter a coerência da análise. Ainda assim, sua inclusão oferece um bom contraponto para o investidor brasileiro, facilitando comparações entre estratégias locais e internacionais.

4.1.4 Diferenciação entre Perfis das Ações Americanas

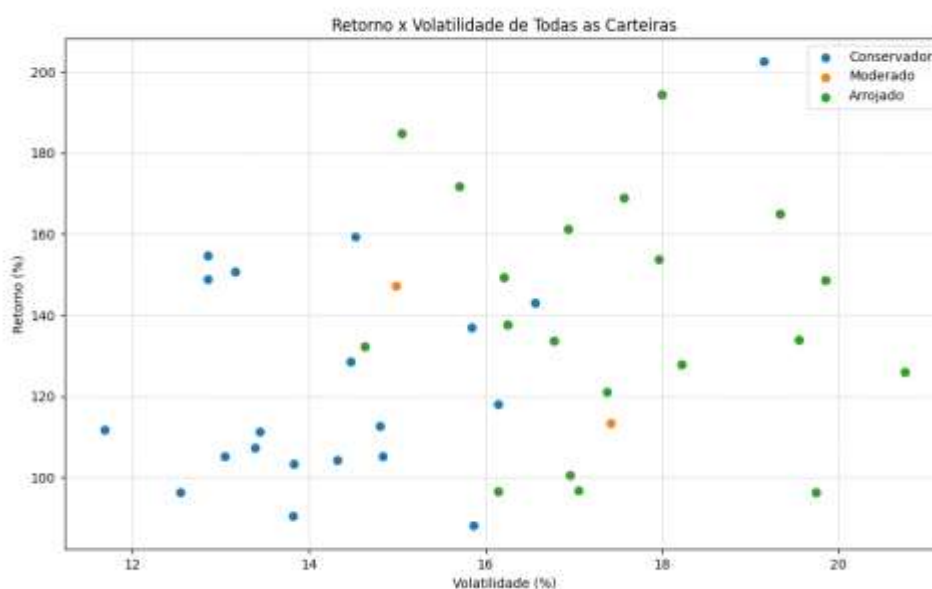
A personalização das carteiras conforme o nível de tolerância ao risco foi uma das premissas centrais do modelo desenvolvido neste trabalho. Para avaliar se essa lógica se manteve ao longo das simulações realizadas entre 2010 e 2020 no mercado norte-americano, foi conduzida uma análise comparativa entre as três categorias de investidor definidas na metodologia: conservadora, moderada e arrojada.

A coerência entre os níveis de tolerância ao risco foi avaliada com base no retorno composto anual (*CAGR*), na volatilidade e no *drawdown* máximo de cada carteira. Embora os valores médios já tenham sido apresentados anteriormente, a análise gráfica a seguir oferece uma perspectiva visual sobre como essas carteiras se distribuem em termos de potencial de perda e rentabilidade.

A estratégia conservadora apresentou o menor desempenho médio anual (14,32%), acompanhado de menor volatilidade (18,68%) e *drawdown* máximo mais controlado (-28,33%), características esperadas em composições com foco na preservação de capital. Enquanto isso, a categoria moderada se posicionou de forma intermediária entre os extremos, com um *CAGR* de 15,96%, assumindo níveis de risco proporcionais ao seu posicionamento. Já a abordagem arrojada obteve o maior ganho

médio (15,99%), mas com volatilidade e *drawdown* superiores (-29,78%), o que é compatível com estratégias mais agressivas e tolerantes a oscilações de mercado.

Figura 3 – Dispersão das carteiras no ano de 2012 (Retorno x Volatilidade).



Fonte: Autores (2025)

A Fig. 3 apresenta a dispersão das carteiras simuladas no ciclo de 2012, classificadas por tipo de investidor com base na relação entre retorno (%) e volatilidade (%). Cada ponto no gráfico representa uma carteira distinta gerada pela IA sendo as cores utilizadas para identificar as categorias: azul para a linha conservadora, laranja para o grupo moderado e verde para a abordagem arrojada.

Além disso, a figura confirma que as carteiras do perfil conservador (em azul) concentram-se majoritariamente em regiões de menor risco e retorno, como é característico de estratégias defensivas. Por outro lado, as carteiras dos perfis moderado (laranja) e arrojado (verde) ocupam áreas mais dispersas e voláteis, com sobreposição visual notável, especialmente na faixa entre 16% e 20% de volatilidade. Essa evidência gráfica reforça que, embora a lógica geral do sistema esteja alinhada com os perfis definidos, ainda há espaço para ajustes que ampliem a distinção prática entre os perfis mais agressivos, sobretudo em contextos de mercado com tendência de alta generalizada.



4.2 INTRODUÇÃO À ANÁLISE DAS AÇÕES BRASILEIRAS

Testar um modelo de Inteligência Artificial no mercado brasileiro equivale a submetê-lo a um ambiente altamente desafiador, marcado por elevada volatilidade, instabilidades macroeconômicas recorrentes, ruídos institucionais e choques externos frequentes (Gonçalves et al., 2020).

A escolha pelas ações brasileiras teve como principal objetivo verificar se a IA desenvolvida manteria a lógica de personalização por perfil de risco mesmo fora de contextos mais estáveis, como o norte-americano. Nesse ambiente, o sistema é colocado à prova em múltiplas dimensões, lidando não apenas com dados financeiros, mas também com cenários prolongados de incerteza, flutuações abruptas de confiança e fatores político-econômicos que desafiam abordagens tradicionais (Pimenta, 2017).

Mais do que buscar rentabilidades absolutas, o foco desta etapa foi testar a resiliência do modelo diante de um mercado emergente instável, avaliando sua capacidade de manter coerência técnica, aderência aos perfis definidos e diferencial de performance mesmo sob condições adversas, que são elementos-chave para validação de modelos baseados em inteligência artificial aplicados a finanças, conforme apontado por Machado e Souza (2022).

4.2.1 Desempenho Médio por Perfil das Ações Brasileiras (2010–2020)

A Tabela 3 apresenta os resultados consolidados das simulações realizadas no mercado de ações brasileiro entre 2010 e 2020.

A estratégia adotada priorizou a análise do comportamento médio das carteiras ao longo do tempo, reduzindo a influência de ciclos atípicos ou carteiras com desempenho extremo. Esse recorte estatístico buscou representar de forma mais estável a lógica de alocação implementada pela IA no contexto brasileiro.

Tabela 3 – Resultados médios por perfil de investidor (2010–2020)

Perfil	CAGR (%)	Volatilidade (%)	Drawdown Máx. (%)
Conservador	16,79	25,06	41,84
Moderado	16,85	25,11	41,99
Arrojado	13,89	25,67	41,49

Fonte: Autores (2025)

Os resultados indicam que, mesmo em um dos mercados mais voláteis do mundo, a IA conseguiu adaptar suas recomendações de forma eficiente. Em um comportamento fora do padrão clássico de risco-retorno, o perfil conservador superou o arrojado em diversas métricas. Esse resultado pode ser atribuído às particularidades do mercado brasileiro, como choques sistêmicos, eventos fiscais abruptos e elevada sensibilidade a fatores políticos (Pimenta, 2017).

O investidor moderado apresentou o maior desempenho médio (16,85%), com volatilidade e *drawdown* praticamente equivalentes à estratégia conservadora, sugerindo um bom equilíbrio entre exposição de mercado e rentabilidade. Já a abordagem arrojada, por sua vez, teve o menor resultado médio (13,89%), mesmo apresentando o maior nível de volatilidade (25,67%), o que indica que, em ambientes de instabilidade como o brasileiro, a lógica clássica de risco-retorno pode ser distorcida por choques sistêmicos e crises recorrentes.

De forma geral, a lógica de personalização adotada pela IA foi mantida com consistência ao longo do período analisado, mesmo diante das adversidades do mercado brasileiro. As recomendações respeitaram os diferentes níveis de risco definidos para cada perfil e responderam de maneira coerente às condições econômicas de cada ciclo.

4.2.2 Comparação com Benchmarks das Ações Brasileiras

Para avaliar a performance das carteiras simuladas, foram utilizados dois benchmarks amplamente reconhecidos no mercado brasileiro: o CDI bruto médio, com rentabilidade estimada de 9,22% ao ano entre 2010 e 2020, e o Ibovespa, principal índice de ações da bolsa brasileira, com retorno médio de aproximadamente 7,8% ao ano no mesmo período (ANBIMA, 2023; B3, 2023).

A Fig. 4 apresenta a comparação direta entre os três perfis da IA e esses indicadores, com base na projeção do valor acumulado ao longo de cinco anos. Os resultados demonstram que todas as carteiras simuladas superaram consistentemente os dois *benchmarks*. Isso reforça a robustez da lógica aplicada, especialmente considerando o histórico de dominância da renda fixa nas decisões de investidores brasileiros de perfil conservador e moderado.

Mesmo durante períodos críticos, como a recessão de 2015–2016 e a crise provocada pela pandemia em 2020, o sistema demonstrou capacidade de adaptação.

Figura 4 – Evolução de R\$10.000 ao longo de 5 anos por perfil da IA e benchmarks.

Comparação baseada nas taxas médias anuais entre 2010 e 2020



Fonte: Autores (2025)

A diferença entre os retornos médios dos perfis da IA e dos *benchmarks*, embora pareça modesta em termos percentuais, gera um impacto expressivo ao longo do tempo. Em apenas cinco anos, essa vantagem representa um ganho adicional entre R\$6.000 e R\$8.000 em comparação ao CDI, evidenciando o efeito dos juros compostos aplicados a uma estratégia mais eficiente de alocação. Esses resultados reforçam o potencial da IA como ferramenta prática para otimização de carteiras, mesmo em contextos de alta volatilidade como o mercado brasileiro (Damodaran, 2012; ANBIMA, 2023).



4.2.3 Diferenciação entre Perfis das Ações Brasileiras

Um dos pilares do modelo de Inteligência Artificial desenvolvido é a personalização das carteiras conforme o nível de tolerância ao risco. Para verificar se essa lógica foi respeitada no contexto brasileiro, foram comparados os resultados médios das carteiras simuladas entre 2010 e 2020 para os perfis conservador, moderado e arrojado (Souza; Lima, 2021).

Os dados consolidados revelam padrões distintos, ainda que com nuances inesperadas. A abordagem conservadora, embora mais cautelosa, alcançou uma rentabilidade anual expressiva de 16,79%, com menor exposição à volatilidade e *drawdown*.

O perfil moderado entregou o maior retorno médio (16,85%), com indicadores de risco muito próximos ao conservador.

Já a estratégia arrojada contrariou a expectativa tradicional de risco-recompensa. Apesar da maior exposição à volatilidade (25,67%), não houve compensação proporcional em ganhos. Sua rentabilidade foi a menor entre as três categorias analisadas (13,89%), sem apresentar redução significativa de *drawdown* em relação às demais.

Esse comportamento reforça a necessidade de ajustes específicos na lógica adotada para esse perfil mais agressivo, com o objetivo de alinhar melhor potencial de perda e retorno em composições voltadas ao longo prazo.

5 CONSIDERAÇÕES FINAIS

Este trabalho investigou como o uso de técnicas de aprendizado de máquina pode contribuir para uma gestão de portfólios mais eficiente, equilibrando exposição de mercado e retorno com base no perfil do investidor. A partir dessa questão, o objetivo foi desenvolver e validar um sistema de Inteligência Artificial capaz de sugerir carteiras de investimento personalizadas, com base em dados reais e alinhadas a diferentes perfis de risco. Os resultados obtidos indicam que a resposta foi positiva: o modelo mostrou-se funcional, adaptável e apresentou robustez técnica.

Ao longo de 11 ciclos consecutivos, o modelo foi testado em dois contextos econômicos distintos, sendo esses o mercado americano, mais previsível e



estruturado, e o mercado brasileiro, caracterizado por instabilidade e choques recorrentes. Em ambos os cenários, a IA demonstrou solidez técnica e adaptabilidade, entregando desempenho estável ao longo do tempo e alinhado aos perfis de risco definidos. As simulações apresentaram retornos médios acima de 13% ao ano em todos os perfis, superando os principais *benchmarks* utilizados como referência, como o CDI, o IBOVESPA e o S&P 500. No Brasil, a abordagem conservadora se destacou em diversos ciclos, conseguindo preservar capital e, em alguns casos, superar os demais em rentabilidade líquida. Já no mercado americano, a estratégia arrojada mostrou maior efetividade, aproveitando com sucesso os períodos de alta mais prolongada. Esses resultados confirmam não apenas a viabilidade técnica da proposta, mas também sua efetividade prática, validando a IA como uma solução funcional para a recomendação personalizada de carteiras de investimento.

O sistema desenvolvido também apresenta forte potencial de aplicação prática. Sua lógica de recomendação por perfil pode ser integrada a plataformas de fintechs, corretoras, simuladores de investimento ou soluções de assessoria automatizada. Para o investidor de varejo, representa uma ferramenta capaz de oferecer decisões autônomas, personalizadas e orientadas por dados reais, sem depender de estratégias genéricas ou replicações de índice.

Apesar dos resultados consistentes, algumas limitações devem ser reconhecidas. A simulação atual ainda opera de forma estática, considerando apenas uma alocação inicial de ativos sem rebalanceamentos ao longo do tempo. Além disso, em determinados ciclos, foi observada uma sobreposição entre os perfis moderado e arrojado, o que indica a necessidade de ajustes mais finos na lógica de *score* e segmentação. Outra limitação técnica está no uso do CDI bruto como benchmark no comparativo com o mercado americano, sem aplicação de correção cambial, o que pode distorcer parcialmente a análise entre os dois contextos.

Como próximos passos, pretende-se a implementação de uma segunda camada de Inteligência Artificial, voltada para decisões de venda, permitindo simulações mais realistas com ciclos completos de entrada e saída. Além disso, efetivar ajustes finos nos critérios de *score*, com ênfase na separação entre os perfis moderado e arrojado, com o objetivo de minimizar eventuais sobreposições. Outro aprimoramento proposto é o aumento da granularidade das simulações, com a adoção de janelas trimestrais ou mensais, de modo a aumentar a sensibilidade do modelo às



variações de mercado ao longo do tempo. Por fim, o escopo do sistema será ampliado para incluir outros tipos de ativos, como *ETFs*, *small caps*, títulos de renda fixa, criptomoedas, fundos imobiliários (FIIs) e ativos com critérios ESG, ampliando sua aplicabilidade prática em diferentes estratégias de investimento.

Os resultados obtidos ao longo desta pesquisa indicam que o uso de Inteligência Artificial na gestão de portfólios pode representar uma abordagem viável para personalização de carteiras conforme o perfil do usuário. O modelo desenvolvido demonstrou funcionamento estável nas simulações propostas, apresentando performance sólida e coerente com os objetivos definidos no início do trabalho. Embora ainda em estágio inicial, esta solução contribui de forma objetiva para a discussão sobre o uso de tecnologia na construção de estratégias de alocação mais adaptadas à realidade do investidor brasileiro, sinalizando um caminho possível para aplicações futuras em contextos práticos.

REFERÊNCIAS

ANBIMA – ASSOCIAÇÃO BRASILEIRA DAS ENTIDADES DOS MERCADOS FINANCEIRO E DE CAPITAIS. **Raio X do investidor brasileiro – 8ª edição**. São Paulo: ANBIMA, 2023. Disponível em: <https://www.anbima.com.br/pt_br/informar/pesquisas/raio-x-do-investidor.htm>. Acesso em: 17 maio 2025.

ANBIMA – ASSOCIAÇÃO BRASILEIRA DAS ENTIDADES DOS MERCADOS FINANCEIRO E DE CAPITAIS. **CDI – Indicador financeiro**. 2024. Disponível em: <https://www.anbima.com.br/pt_br/informar/indicadores/cdi.htm>. Acesso em: 3 maio 2025.

ASSAF NETO, Alexandre. **Mercado financeiro**. 14. ed. São Paulo: Atlas, 2021.
BODIE, Zvi; KANE, Alex; MARCUS, Alan J. **Investimentos**. 10. ed. Porto Alegre: AMGH, 2014.

CERETTA, Paulo Sérgio; COSTA JR., Newton da. **Perfil de risco do investidor e decisão de investimento: uma aplicação da análise de clusters**. Revista de Administração Contemporânea, v. 5, n. 1, p. 85–103, jan./abr. 2001.

CVM – COMISSÃO DE VALORES MOBILIÁRIOS. **Classificação de riscos para longo prazo**. 2021. Disponível em: <<https://www.gov.br/cvm/pt-br/assuntos/noticias/classificacao-de-risco>>. Acesso em: 19 abril 2025.

DAMODARAN, Aswath. **Investment valuation: tools and techniques for determining the value of any asset**. 3. ed. Hoboken: Wiley, 2012.



GONÇALVES, Sérgio; MORAIS, Heloísa; FERREIRA, Thiago. **Volatilidade dos ativos financeiros no Brasil: uma análise empírica**. Revista Brasileira de Economia, v. 74, n. 2, p. 101–120, 2020.

LEIPPOLD, Markus; WANG, Yifan; ZHOU, Zhaoxu. **Machine learning in asset pricing: a survey**. Journal of Financial Economics, 2022.

LUGER, George F. **Inteligência artificial: estruturas e estratégias para a solução complexa de problemas**. 6. ed. Porto Alegre: Bookman, 2013.

MACHADO, Juliana; SOUZA, Fernando. **Inteligência artificial e mercados emergentes: oportunidades e riscos**. Revista de Economia Aplicada, v. 26, n. 1, p. 55–74, 2022.

MEDEIROS, Ana Carolina de Oliveira. **Mineração de dados e inteligência artificial aplicadas à análise do mercado de ações**. 2018. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) – UEG.

OLIVEIRA, Ana Carolina. **Inteligência artificial aplicada ao mercado financeiro: uma análise sobre riscos e decisões**. 2021. Disponível em: <<https://repositorio.unb.br/handle/10482/40826>>. Acesso em: 10 maio 2025.

OLIVEIRA, Maria Marly de; SILVA, Silvio Luiz de; TRIGUEIROS, Florisvaldo dos Santos. **Investimentos financeiros: uma análise dos alunos investidores de uma Instituição de ensino superior de Brasília – DF**. Gestão e TI, Brasília, v. 4, n.1, p. 39–53, jan./jun. 2014.

OLIVEIRA, Tiago; COSTA, Marina. **Introdução à inteligência artificial com Python**. São Paulo: Novatec, 2018.

PIMENTA, R. A. **Análise dos efeitos da instabilidade política sobre os mercados financeiros brasileiros**. Revista de Economia Contemporânea, v. 21, n. 3, p. 1–22, 2017.

PLIGHER, Fábio. **Renda fixa lidera crescimento dos investimentos em 2023**. Valor Econômico, São Paulo, 15 jan. 2024. Disponível em: <<https://valor.globo.com/financas-pessoais/noticia/2024/01/15/renda-fixa-lidera-crescimento.ghtml>>. Acesso em: 17 maio 2025.

PLIGHER, Pedro. **Investimentos dos brasileiros atingem R\$ 7,22 trilhões e renda fixa lidera crescimento em 2024**. Funds Society, 27 nov. 2024. Disponível em: <<https://www.fundsociety.com/br/news/mercados/investimentos-dos-brasileiros>>. Acesso em: 10 maio 2025.

RASCHKA, Sebastian; MIRJALILI, Vahid. **Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow 2**. 2. ed. Birmingham: Packt Publishing, 2019.



S&P GLOBAL. **S&P 500 Historical Annual Returns**. New York: S&P Dow Jones Indices, 2021. Disponível em: <<https://www.spglobal.com/spdji/en/indices/equity/sp-500/>>. Acesso em: 11 maio 2025.

SOUZA, Rodrigo; LIMA, Caio. **Sistemas de recomendação financeira baseados em perfil de risco**. Revista Brasileira de Finanças, v. 19, n. 2, p. 45–63, 2021.

TORRES, Maria Carolina; BARROS, Marcelo. **Investimentos financeiros: análise do perfil dos investidores e da relação com o risco**. Revista de Administração da Universidade Federal de Goiás, v. 10, n. 2, p. 120–138, 2014.