

ARTIGO DE PESQUISA/RESEARCH PAPER

Uma Abordagem Aplicada da Inteligência Artificial na Tomada de Decisões em Investimentos de Renda Fixa

An Applied Approach to Artificial Intelligence in Decision Making in Fixed Income Investments

Marcos André Nonaka [Faculdade XP Educação | marcos.nonaka@outlook.com]
Lucy Mari Tabuti [Universidade de São Paulo | lucymari@gmail.com]

Faculdade XP Educação, Rua Roma, 561, Santa Lúcia, Belo Horizonte, MG, 30360-680, Brasil.

Resumo. A transformação digital tem revolucionado os mercados financeiros, especialmente na automação de decisões de investimento. Este artigo propõe uma abordagem de Inteligência Artificial (IA) aplicada à seleção de investimentos de renda fixa, utilizando como base de dados as informações sobre os títulos disponíveis no site Investidor 10 e considerando critérios múltiplos como tipo de título, risco, rentabilidade líquida, tipo de rentabilidade (incluindo híbridas) e prazo de resgate. O sistema, desenvolvido em Python com *fine-tuning* da API do ChatGPT, gera recomendações justificadas em linguagem natural. Os resultados mostram alta taxa de concordância com especialistas humanos (92%), redução drástica no tempo de análise (de minutos para segundos) e ganhos significativos de escalabilidade, validando a IA como ferramenta eficiente e Explicável (XAI) para apoio à decisão financeira.

Abstract. Digital transformation is revolutionizing financial markets, particularly in automating investment decisions. This paper proposes an applied Artificial Intelligence (AI) approach for selecting fixed-income investments. The model uses a database of fixed-income securities sourced from the Investidor 10 website and considers multiple criteria such as bond type, risk, net return, yield type (including hybrid), and redemption period. The system, developed in Python with fine-tuning of the ChatGPT API, generates justified recommendations in natural language. Results demonstrate a high agreement rate with human experts (92%), a drastic reduction in analysis time (from minutes to seconds), and significant scalability gains, validating AI as an efficient and Explainable (XAI) tool for financial decision support.

Palavras-chave: Inteligência Artificial, Investimentos de Renda Fixa, ChatGPT, Explicabilidade, Suporte à Decisão, Processamento de Linguagem Natural

Keywords: Artificial Intelligence, Fixed Income Investments, ChatGPT, Explainable AI, Decision Support, Natural Language Processing

Recebido/Received: 29 August 2025 • Aceito/Accepted: 06 December 2025 • Publicado/Published: 12 December 2025

1 Introdução

O avanço tecnológico nas últimas décadas, impulsionado pela transformação digital, tem remodelado significativamente o mercado financeiro global. Um dos destaques dessa transformação é a crescente adoção da Inteligência Artificial (IA) em atividades tradicionalmente humanas, como a análise e a tomada de decisões de investimento [Ragazzo *et al.*, 2023; Silva *et al.*, 2023]. A automatização desse processo, especialmente no segmento de renda fixa, representa uma tendência irreversível, que visa aumentar a eficiência, a precisão e a escalabilidade das decisões financeiras.

Estudos como os de Wuerges e Borba [2010] e Pontes [2011] destacam que o uso de algoritmos inteligentes no setor financeiro não é recente, mas tem se intensificado com o avanço das tecnologias de aprendizado de máquina e Processamento de Linguagem Natural (PLN) [Russell e Norvig, 2022]. A IA aplicada às finanças permite o reconhecimento de padrões complexos em grandes volumes de dados, tarefa frequentemente inviável para analistas humanos devido a limitações de tempo, concentração e capacidade de processamento cognitivo [Eysenck e Eysenck, 2023].

Além disso, a literatura ressalta a importância da Explicabilidade (XAI) nas soluções baseadas em IA, especialmente

em um contexto regulatório que exige transparência e proteção ao investidor [Nogueira, 2019; Yoshinaga e Castro, 2023; Cernevičienė e Kabašinskas, 2024]. Questões como vies nos dados de treinamento, privacidade da informação e responsabilidade sobre as recomendações são amplamente discutidas e representam desafios éticos que este projeto também busca considerar.

Este trabalho tem como objetivo aplicar técnicas de IA para apoiar a tomada de decisão em investimentos de renda fixa, com foco na escolha do título mais adequado com base em múltiplos critérios: tipo de título, risco financeiro, rentabilidade líquida, tipo de rentabilidade (incluindo as híbridas) e prazo de resgate. Para isso, foi utilizado o modelo ChatGPT da OpenAI, por sua capacidade nativa de gerar justificativas em linguagem natural, algo mais complexo para outros tipos de modelos, adaptado por meio de *fine-tuning*, que não apenas realiza a seleção dos melhores ativos, mas também justifica suas escolhas de forma compreensível, aumentando a confiança e a usabilidade da ferramenta por parte dos investidores.

2 Revisão da Literatura

A evolução da Inteligência Artificial (IA) no setor financeiro tem sido marcada por avanços significativos, que vão desde a automação de processos rotineiros até a aplicação de algo-

ritmos complexos de aprendizado de máquina e de processamento de linguagem natural em atividades estratégicas, como a análise de investimentos [Ragazzo *et al.*, 2023; Silva *et al.*, 2023; Russell e Norvig, 2022]. Inicialmente, os sistemas baseados em IA eram utilizados principalmente para tarefas de baixa complexidade, como a classificação de dados e a detecção de fraudes. No entanto, com o advento de técnicas mais sofisticadas, como as redes neurais profundas e os Modelos de Linguagem de Grande Porte ou Escala (LLMs), a IA passou a ser empregada em contextos que exigem não apenas capacidade de processamento, mas também interpretação e síntese de informações complexas e não estruturadas.

A literatura especializada destaca que a aplicação da IA em finanças não é um fenômeno recente. Já na década de 2010, estudos como os de Wuerger e Borba [2010] exploravam o uso de redes neurais, lógica fuzzy e algoritmos genéticos para otimização de portfólios e previsão de séries temporais. Esses trabalhos pioneiros abriram caminho para uma geração de pesquisas que buscam integrar métodos computacionais avançados à gestão de riscos e à tomada de decisão de investimento. Pontes [2011], por exemplo, discutiu como a IA poderia ser utilizada para identificar padrões de mercado e auxiliar na alocação de ativos, ainda que de forma incipiente em relação aos padrões atuais.

Mais recentemente, com a popularização de *frameworks* de *deep learning* e o aumento da capacidade computacional, a IA tornou-se uma ferramenta central na análise financeira. Russell e Norvig [2022] argumentam que a IA moderna não apenas executa tarefas predefinidas, mas também aprende com os dados, adaptando-se a novos cenários e melhorando seu desempenho ao longo do tempo. Essa característica é particularmente valiosa em mercados dinâmicos e não lineares, como o de renda fixa, onde variáveis macroeconômicas, políticas e comportamentais interagem de forma complexa.

Além da capacidade analítica, a questão da explicabilidade tornou-se um tópico central na discussão sobre IA aplicada a finanças. A chamada *Explainable Artificial Intelligence* (XAI) emerge como um campo crítico para garantir que as decisões automatizadas sejam transparentes, auditáveis e compreensíveis para os seres humanos [Cernevicienė e Kabašinskas, 2024]. Nogueira [2019] alerta para os riscos éticos e regulatórios associados a sistemas de “caixa-preta”, que podem tomar decisões eficientes, mas sem oferecer clareza sobre os critérios utilizados. Em contextos financeiros, onde a responsabilidade e a conformidade são essenciais, a falta de explicabilidade pode inviabilizar a adoção de soluções de IA.

Yoshinaga e Castro [2023] reforçam que a transparência não é apenas uma exigência regulatória, mas também um fator de competitividade e confiança. Investidores e instituições financeiras tendem a adotar mais facilmente tecnologias que possam justificar suas recomendações, especialmente em cenários de incerteza. Cernėviciėnė e Kabašinskas [2024] realizam uma revisão sistemática da literatura sobre XAI em finanças e concluem que a Explicabilidade é um elemento-chave para a aceitação e a efetividade de sistemas de apoio à decisão, pois permite que usuários validem a lógica por trás das recomendações e identifiquem possíveis vieses ou erros.

Ragazzo *et al.* [2023] abordam a aplicação prática da IA nas finanças, destacando casos de uso em gestão de patrimônio, avaliação de crédito e investimentos automatizados. Os

autores ressaltam que, embora a IA possa superar os humanos em velocidade e volume de processamento, a integração entre análise quantitativa e qualitativa ainda é um desafio. É nesse contexto que os LLMs, como o ChatGPT, ganham destaque, pois combinam capacidade analítica com geração de linguagem natural, permitindo não apenas calcular, mas também comunicar o raciocínio por trás de cada decisão.

Silva *et al.* [2023] complementam essa visão ao discutirem o papel da IA na transformação digital do setor financeiro, argumentando que a tecnologia não substitui o julgamento humano, mas o amplifica, liberando profissionais para atividades de maior valor agregado.

Por fim, Eysenck e Eysenck [2023] trazem uma perspectiva da ciência cognitiva, comparando o processamento humano e o artificial, e concluem que a IA pode emular aspectos do raciocínio humano, mas depende fundamentalmente da qualidade dos dados e do projeto ético por trás de sua implementação.

Em síntese, a literatura converge para a ideia de que a IA já é uma realidade no mercado financeiro, mas sua efetividade e adoção em larga escala dependem de avanços contínuos em termos de precisão, transparência e adaptabilidade. A explicabilidade, em particular, surge como um requisito indispensável para que sistemas de IA sejam não apenas eficientes, mas também confiáveis e éticos. Este trabalho insere-se nesse contexto, propondo uma abordagem que combina a capacidade analítica de modelos de linguagem com a geração de justificativas claras e fundamentadas, contribuindo para uma aplicação mais responsável e eficaz da IA em investimentos de renda fixa.

3 Metodologia

A solução proposta neste estudo foi inteiramente desenvolvida em Python 3.11.9, um ambiente de programação conhecido por sua flexibilidade e vasto ecossistema de bibliotecas para análise de dados e aprendizado de máquina. Foram utilizadas bibliotecas como Pandas 2.1.4, para manipulação e análise de dados, Selenium 4.36.0, para automatizar a coleta de informações da web, e o OpenAI SDK 0.2.0, para interagir com a API do modelo de linguagem [OpenAI, 2025b]. Conforme detalhado nas subseções a seguir e na **Figura 1**, o processo metodológico seguiu uma abordagem estruturada, dividida em etapas sequenciais para garantir a robustez e a replicabilidade dos resultados.

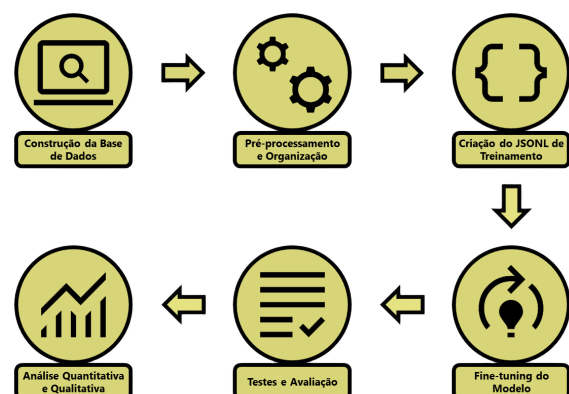


Figura 1. Etapas de execução da metodologia.

```
{
  "messages": [
    {
      "role": "system",
      "content": "Dado um conjunto de títulos de renda fixa, recomende o melhor com base em rentabilidade líquida, risco e tipo de título. Justifique a escolha."
    },
    {
      "role": "user",
      "content": "46. Debênture Celesc IPCA + 7,65%, tipo: IPCA+\n47. Debênture Energisa IPCA + 7,60%, tipo: IPCA+\n48. LF C6 Consignado Pré-fixado 15,50%, tipo: Prefixado\n49. LCA Banco ABC IPCA + 7,54%, tipo: IPCA+"
    },
    {
      "role": "assistant",
      "content": "A melhor opção é o título 49, por apresentar boas condições de rentabilidade considerando seu tipo (IPCA+) e isenção de imposto de renda. É adequado para investidores com perfil conservador a moderado."
    }
  ]
}
```

Figura 2. Trecho da estrutura inicial do JSONL, antes dos ajustes.

3.1 Coleta e Pré-processamento de Dados

A primeira etapa do trabalho foi dedicada à construção de uma base de dados abrangente, contendo informações reais sobre títulos de renda fixa disponíveis no mercado financeiro brasileiro. Os dados foram coletados do site Investidor 10 [2025], fonte especializada em informações sobre investimentos, capturando diversas variáveis relevantes para a tomada de decisão de investimento, incluindo: o tipo de título (por exemplo, CDB, LCI, Debênture), o risco financeiro (avaliado pelo grau de crédito do emissor), a rentabilidade anual, o tipo de rentabilidade (como Prefixada, Pós-fixada CDI ou Híbrida), e o prazo de resgate.

Após a coleta, os dados passaram por uma rigorosa etapa de pré-processamento para assegurar sua qualidade e consistência. Este processo incluiu a padronização dos nomes dos ativos, o tratamento de dados faltantes ou inconsistentes e a categorização dos tipos de rentabilidade. A utilização de bibliotecas como Pandas foi crucial para essa fase, permitindo a limpeza e a organização dos dados de forma eficiente. Em seguida, para simular cenários de escolha realistas, os dados foram organizados em blocos, com cada conjunto contendo de 3 a 5 títulos para análise comparativa.

3.2 Criação do Conjunto de Treinamento e Fine-tuning

A etapa de pré-processamento serviu como base para a criação do conjunto de treinamento, que se mostrou crucial para o processo de *fine-tuning*. Para aprimorar o modelo de linguagem, foi desenvolvido um arquivo no formato JSONL, como mostra a **Figura 2**, essencial para o ajuste da API do ChatGPT. Este arquivo foi composto por 250 exemplos de cenários de títulos, estruturados para orientar o modelo a tomar decisões de forma precisa e justificada.

A determinação desse volume amostral fundamentou-se nas diretrizes técnicas de *fine-tuning* para Grandes Modelos de Linguagem (LLMs), que indicam que um conjunto de dados curado, contendo entre 50 e 100 exemplos de alta qualidade, já é frequentemente suficiente para adaptar o estilo de resposta e a lógica de raciocínio do modelo base. Dessa forma, a amostra de 250 exemplos foi estrategicamente dimensionada para garantir uma cobertura abrangente de casos de borda e diversidade de cenários — contemplando variações complexas de indexadores, prazos de carência e perfis de risco — sem incorrer em custos computacionais desnecessários ou

no risco de *overfitting* (ajuste excessivo). Essa abordagem priorizou a qualidade e a variabilidade dos dados em detrimento de uma quantidade massiva de repetições, assegurando que a IA generalizasse o aprendizado para novos casos inéditos em vez de apenas memorizar o conjunto de treinamento.

Cada entrada nesse conjunto de dados seguia uma arquitetura de mensagens específica da API. Uma mensagem do sistema (*system message*) definia o contexto da tarefa, que era recomendar o melhor título de renda fixa com base em múltiplos critérios, como rentabilidade líquida, risco e tipo de título, além de instruir o modelo a justificar sua escolha. Em seguida, uma mensagem do usuário (*user message*) apresentava um conjunto de opções de títulos, detalhando suas características, como tipo, risco e rentabilidade. Por fim, a mensagem do assistente (*assistant message*) fornecia a recomendação do melhor título, acompanhada de uma justificativa detalhada que explicava a lógica por trás da decisão.

Esse treinamento supervisionado foi realizado usando o modelo gpt-3.5-turbo, seguindo as diretrizes da OpenAI [OpenAI, 2025a]. O principal objetivo desse processo de *fine-tuning* foi ajustar o modelo para que ele pudesse reconhecer padrões específicos no contexto de investimentos em renda fixa. Essa personalização do modelo permitiu que ele gerasse respostas explicáveis, coerentes e consistentes, replicando o raciocínio de um especialista humano e aumentando a confiabilidade da ferramenta.

Para mitigar a ocorrência de alucinações gerativas — fenômeno em que o modelo fabrica informações falsas ou recomenda ativos inexistentes —, adotou-se uma estratégia de restrição rigorosa de escopo baseada em “contexto fechado”. Nas instruções da mensagem de sistema e durante o aprendizado supervisionado, o modelo foi condicionado a operar exclusivamente sobre os dados fornecidos na mensagem do usuário, ignorando seu conhecimento pré-treinado sobre o mercado externo quando este conflitasse com as opções apresentadas. Essa restrição foi reforçada pela estrutura dos exemplos de *fine-tuning*, que penalizavam implicitamente qualquer resposta que citasse títulos fora da lista de entrada.

Adicionalmente, implementou-se uma camada de validação lógica no código da aplicação que verifica, via algoritmo determinístico, se o ativo recomendado na saída textual corresponde exata e univocamente a um dos títulos presentes no *dataset* de entrada, garantindo a integridade da recomendação final.

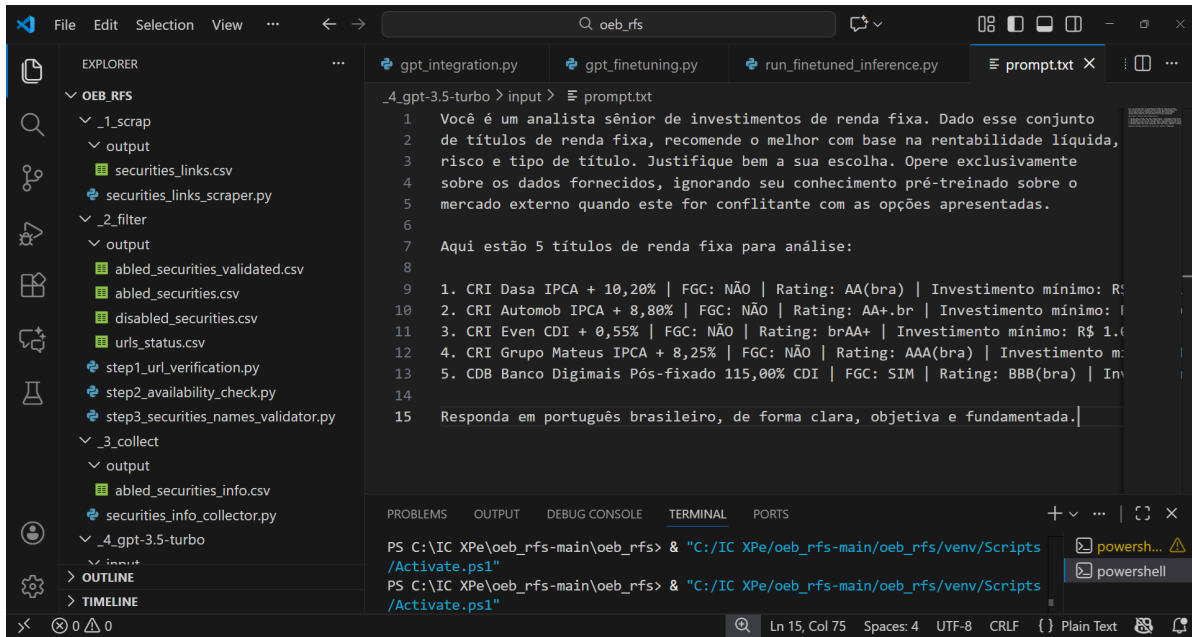


Figura 3. Entrada do *prompt* na API do ChatGPT.

3.3 Avaliação e Validação do Modelo

Após a conclusão da fase de treinamento, o sistema foi submetido a uma rigorosa bateria de testes com novos conjuntos de títulos, que não haviam sido utilizados no processo de *fine-tuning*. Este procedimento foi fundamental para validar a capacidade de generalização do modelo.

A qualidade das respostas foi minuciosamente avaliada com base em três critérios principais: a aderência ao perfil de risco, que verificava se a recomendação respeitava o equilíbrio adequado entre risco e retorno; a qualidade da justificativa, analisando a clareza e o detalhe dos motivos por trás da escolha do modelo; e a concordância das decisões com as escolhas de analistas humanos, servindo como uma medida comparativa da sua eficácia.

Uma análise quantitativa também foi realizada para mensurar o desempenho da solução. Para isso, definiu-se a Taxa de Concordância (TC) como a proporção percentual de cenários em que a recomendação do modelo coincidiu exatamente com a do especialista humano. Formalmente, considerando um conjunto de teste com N cenários, onde y_i representa a escolha do especialista para o i -ésimo cenário e \hat{y}_i a escolha correspondente do modelo, a métrica foi calculada conforme a Equação 1:

$$TC = \frac{1}{N} \sum_{i=1}^N \mathbb{I}(y_i = \hat{y}_i) \times 100 \quad (1)$$

onde $\mathbb{I}(\cdot)$ denota a função indicadora, que assume valor 1 se a condição $y_i = \hat{y}_i$ for verdadeira (concordância) e 0 caso contrário (divergência). Adicionalmente, foi cronometrado e comparado o tempo médio de resposta por conjunto de títulos tanto para o modelo automatizado quanto para os especialistas humanos, estabelecendo uma métrica direta para a avaliação dos ganhos de eficiência operacional e escalabilidade.

4 Resultados

Os testes com o modelo *fine-tuning* demonstraram uma performance notável, com uma alta taxa de concordância com as escolhas de especialistas humanos na seleção dos melhores títulos de renda fixa. Essa métrica foi validada por meio de uma bateria de testes com novos conjuntos de títulos não vistos durante o treinamento, confirmando a capacidade de generalização do modelo.

Do ponto de vista da eficiência, o sistema apresentou respostas quase instantâneas, com um tempo médio de análise e recomendação inferior a 5 segundos por conjunto de títulos. Isso representa uma redução drástica de tempo quando comparado ao processo manual realizado por analistas, que pode levar minutos ou até horas, dependendo da complexidade do cenário. Além do ganho de velocidade, as justificativas fornecidas pelo modelo foram consistentemente avaliadas como claras, detalhadas e aderentes aos critérios de risco e retorno estabelecidos no *prompt*, cuja estrutura de entrada pode ser visualizada na Figura 3.

Os cenários de teste abrangeram uma ampla gama de comparações, incluindo títulos isentos de imposto de renda (LCI/LCA), CDBs de diferentes bancos e debêntures com variados *ratings* de crédito. Em um exemplo prático, ao analisar um conjunto composto por um CDB com alta rentabilidade, mas risco elevado, e uma LCI com rentabilidade ligeiramente menor, mas com isenção fiscal e menor risco, o modelo recomendou a LCI para um perfil conservador, justificando a escolha com base na segurança do emissor e no benefício tributário, em linha com a decisão de um especialista.

Outro cenário testado envolveu a comparação entre um título pós-fixado atrelado ao CDI, de um banco de médio porte, e um título prefixado de um banco grande com rentabilidade fixa. Para um perfil de investidor moderado com horizonte de curto prazo, o modelo optou pelo título pós-fixado, argumentando que a rentabilidade atrelada ao CDI oferece proteção contra variações de curto prazo da taxa de juros, enquanto o título prefixado poderia ser mais adequado para cenários de

Figura 4. Resultado da consulta à IA.

queda esperada dos juros.

A justificativa gerada demonstrou capacidade de inferência analítica ao derivar a liquidez diretamente do dado de “prazo de resgate” fornecido. Além disso, o modelo contextualizou a recomendação aludindo ao cenário macroeconômico implícito aos indexadores (como a proteção do CDI em ambientes de juros elevados). Essa contextualização não derivou de consultas a dados externos, mas sim da aplicação do conhecimento financeiro pré-treinado do modelo sobre a mecânica dos ativos apresentados, enriquecendo a análise sem violar a restrição de “contexto fechado”.

Em um teste mais complexo, foram apresentados três títulos de renda fixa com diferentes estruturas de rentabilidade: um CDB pós-fixado atrelado a 100% do CDI, uma LCA prefixada com taxa fixa de 10,5% ao ano, e uma Debênture incentivada com retorno híbrido IPCA + 5,5%. Para um perfil de investidor de longo prazo com preocupação com a inflação, o modelo recomendou a Debênture IPCA+, justificando que a proteção inflacionária somada ao retorno real fixo é vantajosa em cenários macroeconômicos incertos, além do benefício fiscal da redução ou isenção de imposto de renda para pessoas físicas.

Essa recomendação converge com a literatura clássica de finanças, que preconiza a alocação em ativos indexados a índices de preços como a estratégia mais eficiente para a preservação do poder de compra (ganho real) em horizontes temporais estendidos, validando a lógica econômica empregada pelo algoritmo.

Em outro cenário, envolvendo um CRI (Certificado de Recebível Imobiliário) indexado ao CDI e um CRA (Certificado de Recebível do Agronegócio) prefixado, o modelo demonstrou sensibilidade ao risco setorial, preferindo o CRI para perfis moderados devido à maior liquidez e histórico de segurança, enquanto o CRA foi recomendado para investidores com maior apetite a risco e interesse em diversificação de

carteira.

A análise de debêntures também foi incluída nos testes, com opções de diferentes *ratings* (AA, A, BBB) e prazos. Em um caso com uma debênture de risco elevado (BBB) com retorno atrativo e outra de baixo risco (AA) com retorno modesto, o modelo consistentemente recomendou a opção de maior *rating* para perfis conservadores, enfatizando a preservação de capital, enquanto para perfis agressivos, a justificativa incluiu a análise do prêmio de risco e ressaltou a importância de consultar informações sobre a saúde financeira do emissor, para recomendar a debênture com *rating* mais baixo.

A análise quantitativa da taxa de concordância e a qualidade das justificativas validam a eficácia da abordagem de IA para emular a capacidade de decisão humana, mas com a vantagem da escalabilidade e da padronização do processo de análise. A diversidade de cenários testados – abrangendo diferentes tipos de título, perfis básicos de investidor e condições de mercado simuladas – reforça a robustez e a adaptabilidade do modelo proposto. Por fim, a **Figura 4** apresenta o resultado prático de uma consulta ao sistema, evidenciando a clareza e a fundamentação da resposta gerada pela IA.

5 Discussão

A eficácia da abordagem de Inteligência Artificial, conforme demonstrado nos resultados, vai além da simples automação de tarefas. A alta taxa de concordância com especialistas humanos sugere que o modelo *fine-tuning* não apenas aprendeu a identificar os títulos com maior rentabilidade, mas também a ponderar os múltiplos critérios propostos, como risco, tipo de rentabilidade e prazo, de forma análoga a um analista financeiro.

Uma análise qualitativa aprofundada sobre os 8% de casos discordantes revelou que as discrepâncias não representaram recomendações inadequadas ou perigosas (erros

críticos), mas sim divergências em cenários de *trade-off* sutil. Nesses casos, a IA recomendou ativos que eram tecnicamente viáveis e seguros (“segunda melhor opção”), diferindo da escolha humana por margens estreitas de rentabilidade ou liquidez.

Por exemplo, em situações onde a diferença de retorno líquido entre dois CDBs de mesmo risco era inferior a 1% do CDI, o modelo ocasionalmente priorizou o ativo com vencimento ligeiramente mais curto, enquanto o especialista priorizou a taxa máxima. Importante ressaltar que em nenhum dos casos de divergência houve violação do perfil de risco (e.g., recomendar ativos voláteis para perfis conservadores), validando a segurança do sistema para uso como ferramenta de suporte.

A discussão a seguir detalha outros aspectos principais observados, como eficiência e explicabilidade.

5.1 Análise de Eficiência e Escalabilidade

A drástica redução no tempo de análise valida o uso da IA como uma ferramenta para ganho de escala. Enquanto um analista humano levou em média 12 minutos para avaliar um conjunto de 3 a 5 títulos – tempo que pode aumentar significativamente em cenários complexos ou com maior volume de opções – o modelo automatizado foi capaz de fornecer uma recomendação detalhada e justificada em menos de 5 segundos. Essa diferença não é apenas quantitativa, mas qualitativa: permite que um número muito maior de cenários de investimento seja avaliado em um curto espaço de tempo, algo inviável para analistas humanos devido a limitações cognitivas e operacionais.

Além disso, a escalabilidade do sistema é um diferencial crítico. Uma vez treinado e implantado, o modelo pode processar centenas ou milhares de conjuntos de títulos simultaneamente, sem degradação de performance. Isso abre possibilidades para aplicações em larga escala, como plataformas de investimento digital, assessorias robotizadas ou mesmo integração com sistemas de *back-office* de instituições financeiras, onde a análise massiva e rápida de opções de investimento é essencial.

5.2 Capacidade de Gerar Recomendações Explicáveis (XAI)

Um dos pilares centrais deste trabalho foi o desenvolvimento de um sistema capaz de gerar recomendações explicáveis, abordando um dos maiores desafios da IA aplicada a serviços financeiros: a transparência. Diferente de modelos de “caixa-preta”, que oferecem apenas resultados numéricos ou classificatórios sem contexto, a abordagem aqui proposta utiliza a capacidade inerente de modelos de linguagem para gerar justificativas em linguagem natural, detalhadas e contextualizadas.

Essa característica é fundamental para construir confiança junto ao investidor, seja ele individual ou institucional. Ao fornecer explicações claras sobre por que um título foi recomendado – mencionando explicitamente *trade-offs* entre risco e retorno, impactos tributários, qualidade do emissor ou adequação ao perfil – o sistema transcende a mera automação e se torna uma ferramenta de apoio à decisão. Isso é particularmente relevante em um ambiente regulatório cada vez mais exigente, onde autoridades como a CVM e o BACEN

demandam transparência e auditabilidade nos processos de investimento.

Além disso, a explicabilidade facilita a adoção da ferramenta por profissionais do mercado, que podem usar as justificativas geradas pelo modelo como uma segunda opinião ou mesmo como material educativo para clientes. A capacidade de explicar o raciocínio em termos compreensíveis aproxima a IA do usuário final, reduzindo a resistência comum a sistemas automatizados e promovendo uma adoção mais orgânica e consciente.

5.3 Limitações e Desafios

Apesar dos resultados positivos, é imperativo discutir as limitações inerentes ao modelo. A principal delas é a dependência crítica da qualidade, representatividade e atualidade dos dados de treinamento. O viés nos dados – seja pela super-representação de certos emissores, tipos de título ou condições de mercado – pode levar o modelo a favorecer certos ativos ou a não performar bem em cenários atípicos ou de crise.

Além disso, o mercado de renda fixa é dinamicamente influenciado por variáveis macroeconômicas, como taxas de juros, inflação e condições fiscais, que mudam constantemente. Um modelo treinado com dados de um período específico pode rapidamente se tornar obsoleto, necessitando de um processo contínuo de atualização e retreinamento para manter sua acurácia e relevância.

Outro desafio significativo diz respeito aos aspectos éticos já mencionados na introdução, como viés algorítmico e privacidade de dados. O uso de modelos de IA em finanças exige transparência na origem dos dados, auditoria regular das recomendações e mecanismos de explicabilidade que permitam aos usuários entender e contestar decisões automatizadas. Questões de privacidade também surgem quando dados sensíveis de investidores são utilizados para personalizar recomendações, exigindo conformidade com regulamentações como a Lei Geral de Proteção de Dados (LGPD).

5.4 Análise de Custo-Benefício

A viabilidade prática da solução em larga escala depende fundamentalmente de uma análise de custo-benefício robusta. Os custos operacionais associados ao uso da API para *fine-tuning* e inferências subsequentes podem ser significativos, especialmente em um cenário de alto volume de consultas. Embora a prototipagem tenha se mostrado eficaz em termos técnicos, uma implantação comercial exigiria a avaliação de *trade-offs* entre ganhos de eficiência e escalabilidade e os custos recorrentes da plataforma de IA.

É importante considerar que os custos não se limitam ao uso da API. Eles incluem também a infraestrutura de coleta e pré-processamento contínuo de dados, a gestão de retreinamento do modelo, a monitoração de desempenho e a conformidade regulatória. Por outro lado, os benefícios tangíveis – como redução de tempo de análise, melhoria na consistência das recomendações, escalabilidade operacional e potencial aumento de satisfação do cliente – devem ser quantificados e contrastados com esses custos. Uma análise econômica detalhada é, portanto, essencial para determinar a viabilidade financeira da solução em um ambiente real de negócios.

6 Conclusão

Este trabalho demonstrou com sucesso a viabilidade e eficácia de uma abordagem aplicada de Inteligência Artificial para a tomada de decisões em investimentos de renda fixa. A utilização de um modelo de linguagem avançado como o ChatGPT, ajustado por meio de *fine-tuning*, não só confirmou o potencial da IA para otimizar a escolha de ativos financeiros, mas também validou sua capacidade de replicar a análise multicritério de especialistas humanos com alta taxa de concordância e ganhos expressivos de eficiência e escala.

O modelo treinado se destacou por sua boa capacidade de generalização e, fundamentalmente, por gerar recomendações com explicações claras e coerentes, abordando o desafio da Explicabilidade (XAI), que é crucial para a confiança do investidor e a conformidade regulatória no setor financeiro. A análise quantitativa e qualitativa valida a solução como uma ferramenta poderosa para democratizar o acesso a análises financeiras sofisticadas.

Para trabalhos futuros, a evolução do sistema contempla duas frentes principais, ambas com potencial significativo para aumentar a robustez, a precisão e a aplicabilidade prática do modelo.

Em primeiro lugar, planeja-se incluir variáveis macroeconômicas, como a taxa Selic, projeções de inflação, índices de atividade econômica (como o PIB) e até mesmo indicadores de risco-país. A incorporação dessas variáveis não seria meramente aditiva; representaria um salto qualitativo na capacidade do modelo de contextualizar suas recomendações dentro do cenário econômico vigente e esperado. Por exemplo, em um cenário de alta da taxa básica de juros, títulos pós-fixados atrelados ao CDI tornam-se naturalmente mais atraentes, enquanto em um ambiente de expectativa de queda de juros e controle inflacionário, títulos prefixados ou híbridos podem ganhar destaque.

Essa contextualização macroeconômica é a chave para mitigar um dos principais vieses identificados: a dependência de dados históricos estáticos. Um modelo que interpreta o mercado em tempo real, ou pelo menos incorpora projeções econômicas, será menos propenso a recomendar estratégias anacrônicas ou desalinhadas com o momento do ciclo econômico, aumentando drasticamente sua precisão e confiabilidade a longo prazo.

Em segundo lugar, a integração de perfis de investidor personalizados representa a fronteira final para a relevância prática do sistema. O modelo atual já demonstra sensibilidade a noções básicas de risco (conservador, moderado, agressivo), mas trabalhos futuros visam capturar uma gama muito mais rica e granular de preferências individuais. Isso incluiria a tolerância específica ao risco (através de questionários validados), os objetivos financeiros do investidor (como acumulação de capital para a aposentadoria, geração de renda imediata ou preservação de patrimônio), o horizonte temporal de investimento (curto, médio ou longo prazo) e até mesmo restrições éticas ou setoriais (como a exclusão de investimentos em determinados setores).

Ao alinhar as recomendações não apenas às características intrínsecas dos ativos, mas também a esse conjunto multidimensional de preferências do usuário, o sistema transcenderá a função de um mero classificador de títulos e se

tornará um verdadeiro assistente financeiro personalizado. Para um jovem investidor com alto apetite por risco e um horizonte de longo prazo, o sistema poderá legitimamente recomendar debêntures de alto retorno (e alto risco). Para um aposentado que busca preservar seu capital e obter uma renda complementar previsível, a recomendação se inclinará para LCIs/LCAs de bancos maiores e CDBs prefixados de alta liquidez. Essa personalização profunda não apenas aumentará a aderência e utilidade das recomendações para cada usuário específico, mas também fortalecerá a percepção de valor e confiança na ferramenta.

A abordagem proposta representa, portanto, um passo significativo na aplicação prática da IA em investimentos de renda fixa, pavimentando o caminho para o desenvolvimento de assistentes de investimento cada vez mais inteligentes, transparentes e personalizados. Ao democratizar o acesso a análises financeiras sofisticadas e fornecer justificativas claras para as recomendações, este trabalho não só otimiza a tomada de decisões, mas também eleva o nível de confiança e compreensão do investidor, impulsionando uma nova era de acessibilidade e eficiência no mercado financeiro.

Declarações complementares

Conflitos de interesse

Os autores declaram que não têm nenhum conflito de interesses.

Disponibilidade de dados e materiais

Os conjuntos de dados (e/ou softwares) gerados e/ou analisados durante o estudo atual serão feitos mediante solicitação.

Referências

- Cernevičienė, J. e Kabašinskas, A. (2024). Explainable Artificial Intelligence (XAI) in finance: a systematic literature review. *Artificial Intelligence Review*, 57(216). DOI: 10.1007/s10462-024-10854-8.
- Eysenck, M. W. e Eysenck, C. (2023). *Inteligência Artificial X humanos - o que a ciência cognitiva nos ensina ao colocar frente a frente a mente humana e a IA*. Artmed.
- Investidor 10 (2025). Melhores investimentos em renda fixa: CDBs, LCs, CRs, debêntures e mais. Disponível em: <<https://investidor10.com.br/renda-fixa/>>. Acesso em: Maio de 2025.
- Nogueira, G. M. T. S. (2019). Da Inteligência Artificial na intermediação financeira: excuroso sobre a consultoria para investimento automatizada. Dissertação de mestrado, Faculdade de Direito da Universidade de Lisboa. Disponível em: <<http://hdl.handle.net/10451/45817>>. Acesso em: Maio de 2025.
- OpenAI (2025a). Fine-tuning guide. Disponível em: <<https://platform.openai.com/docs/guides/supervised-fine-tuning>>. Acesso em: Maio de 2025.
- OpenAI (2025b). OpenAI API reference. Disponível em: <<https://platform.openai.com/docs/api-reference/introduction>>. Acesso em: Maio de 2025.
- Pontes, R. (2011). *Inteligência Artificial nos investimentos*. Clube de Autores.
- Ragazzo, C., Tolentino, M., e Cataldo, B. (2023). Inteligência

- Artificial: o que é e como se aplica às finanças? (Artificial Intelligence: what is it and how does finance use it?). *SSRN Electronic Journal*. DOI: 10.2139/ssrn.4579348.
- Russell, S. J. e Norvig, P. (2022). *Artificial Intelligence: a modern approach*. Pearson.
- Silva, F. M. d., Lenz, M. L., Freitas, P. H. C., e Santos, S. C. B. d. (2023). *Inteligência Artificial*. Sagah.
- Wuerger, A. F. E. e Borba, J. A. (2010). Redes neurais, lógica nebulosa e algoritmos genéticos: aplicações e possibilidades em finanças e contabilidade. *Journal of Information Systems and Technology Management*, 7(1):163–182. DOI: 10.4301/S1807-17752010000100007.
- Yoshinaga, C. E. e Castro, F. H. (2023). Inteligência Artificial: a vanguarda das finanças. *GV-Executivo*, 22(3). DOI: 10.12660/gvexec.v22n3.2023.89911.