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

Marcos André Nonaka¹, Lucy Mari Tabuti², Ronaldo Barbosa³

¹Faculdade XP Educação (XPE) – Belo Horizonte – MG – Brazil

²Interlab POLI – Universidade de São Paulo (POLI-USP) – São Paulo – SP – Brazil

³Instituto Brasileiro de Mercado de Capitais (IBMEC) – São Paulo – SP – Brazil

marcos.nonaka@outlook.com, lucymari@gmail.com,
professor.ronaldobarbosa@gmail.com

***Abstract.** The digital transformation has brought significant changes to financial markets, especially in automating investment decision-making. This research proposes an applied Artificial Intelligence (AI) approach to support decision-making in fixed income investments, considering multiple criteria: bond type, risk, net return, yield type (including hybrid) and redemption period. The system was developed in Python using the ChatGPT API with fine-tuning for qualitative and explainable analysis. Results show efficiency in selecting the best investments compared to human specialists, with time reduction and scalability gains.*

***Resumo.** A transformação digital tem promovido mudanças significativas nos mercados financeiros, principalmente na automatização de decisões de investimento. Esta pesquisa propõe uma abordagem aplicada de Inteligência Artificial (IA) para apoiar a tomada de decisões em investimentos de renda fixa, considerando múltiplos critérios: tipo de título, risco, rentabilidade líquida, tipo de rentabilidade (incluindo híbridas) e prazo de resgate. O sistema foi desenvolvido em Python e utiliza a API do ChatGPT com fine-tuning para análise qualitativa e explicável. Os resultados demonstram eficiência na escolha dos melhores títulos quando comparado a especialistas humanos, com redução de tempo e ganho de escalabilidade.*

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. A

automação 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. 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). Questões como viés 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, 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. Metodologia

A solução foi desenvolvida em Python, utilizando bibliotecas como Pandas, Selenium e OpenAI API para coleta, verificação da disponibilidade, tratamento e análise dos dados. O processo iniciou-se com a construção de uma base de dados contendo informações reais de títulos de renda fixa disponíveis no mercado financeiro brasileiro. Essa base incluiu variáveis como tipo de título (ex.: CDB, LCI, Debênture), risco financeiro (grau de crédito do emissor), rentabilidade líquida anual, tipo de rentabilidade (Prefixada, Pós-fixada CDI, Híbrida IPCA+, etc.) e prazo de resgate.

Após a coleta, foi realizada uma etapa de pré-processamento, incluindo a padronização dos nomes dos ativos, tratamento de títulos disponíveis e categorização dos tipos de rentabilidade. Em seguida, os dados foram organizados em blocos com conjuntos de 3 a 5 títulos por exemplo, simulando cenários reais de escolha.

Esses blocos serviram de base para a criação de um arquivo de treinamento no formato JSONL, necessário para o processo de *fine-tuning* da API do ChatGPT. Cada entrada do *dataset* seguia uma estrutura de mensagens da API, contendo:

- Um *prompt* (*system message*) explicando o contexto da tarefa: recomendar o melhor título com base em múltiplos critérios.
- Um conjunto de opções de títulos (*user message*), contendo para cada título suas principais características: tipo, risco, rentabilidade líquida, tipo de rentabilidade e prazo de resgate.
- Uma resposta (*assistant message*) contendo a recomendação da melhor opção com uma justificativa detalhada.

```
{"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 46, por apresentar boas condições de rentabilidade considerando seu tipo (IPCA+). É adequado para investidores com perfil conservador a moderado."}]}
```

Figura 1. Trecho da estrutura inicial do JSONL, antes dos ajustes

O *fine-tuning* foi realizado utilizando o modelo gpt-3.5-turbo, seguindo as orientações da OpenAI para treinamento supervisionado com múltiplos exemplos de entrada-saída. O processo de treinamento buscou ajustar o modelo para reconhecer padrões relevantes no contexto de renda fixa e gerar respostas explicáveis e consistentes.

Após o treinamento, o sistema foi submetido a uma bateria de testes com novos conjuntos de títulos, não vistos durante o treinamento, para validar sua capacidade de generalização. A qualidade das respostas foi avaliada com base em três critérios principais:

- Aderência ao perfil de risco: se a recomendação respeitava o equilíbrio entre risco e retorno.
- Qualidade da justificativa: se o modelo era capaz de explicar claramente os motivos da escolha.
- Concordância com especialistas: comparação com as decisões de analistas humanos.

Para análise quantitativa, foi calculada a taxa de concordância percentual entre as escolhas do modelo e as escolhas humanas, além da medição do tempo médio de resposta.

3. 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.

Tabela 1. Tempo médio de resposta na análise de um conjunto de títulos

	Modelo de IA	Especialista humano
Tempo médio de análise e resposta	3,7 segundos	12 minutos

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*.

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.

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.

4. 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. A drástica redução no tempo de análise valida o uso da IA como uma ferramenta para ganho de escala, permitindo que um número muito maior de cenários de investimento seja avaliado em um curto espaço de tempo, algo inviável para analistas humanos.

Um dos pilares deste trabalho foi a capacidade de gerar recomendações explicáveis (XAI), um ponto crucial destacado pelos usuários. Essa característica é fundamental para construir a confiança do investidor e atender às crescentes exigências regulatórias por transparência. Ao fornecer justificativas claras e detalhadas para cada escolha, o sistema deixa de ser uma "caixa-preta" e se torna uma ferramenta de apoio à decisão, permitindo que o usuário final compreenda a lógica por trás da recomendação e se sinta mais seguro para agir.

Apesar dos resultados positivos, é imperativo discutir as limitações inerentes ao modelo. A principal delas é a dependência da qualidade e da atualidade dos dados de treinamento. O viés nos dados pode levar o modelo a favorecer certos tipos de ativos ou a não performar bem em cenários de mercado atípicos. Além disso, o mercado de renda fixa é dinâmico; taxas de juros, indicadores de inflação e a saúde financeira dos emissores mudam constantemente. Portanto, um modelo treinado com dados de um determinado período pode se tornar obsoleto rapidamente. Isso exige a implementação de um processo de atualização e retreinamento contínuo para garantir que as recomendações permaneçam relevantes e precisas frente às novas condições de mercado. A necessidade de incluir variáveis macroeconômicas, como planejado para trabalhos futuros, é um passo essencial para mitigar essa limitação.

5. 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. Primeiramente, planeja-se incluir variáveis macroeconômicas (como a taxa Selic, projeções

de inflação e indicadores de atividade econômica) para tornar o modelo mais robusto e adaptável às dinâmicas de mercado, mitigando as limitações dos dados estáticos de treinamento. Em segundo lugar, a integração de perfis de investidor personalizados permitirá que as recomendações sejam alinhadas não apenas às características dos ativos, mas também à tolerância a risco, aos objetivos e ao horizonte de tempo de cada usuário.

A abordagem proposta representa, portanto, um passo significativo na aplicação prática da IA, pavimentando o caminho para o desenvolvimento de assistentes de investimento cada vez mais inteligentes, transparentes e personalizados.

Referências

Černevičienė, J., Kabašinskas, A. (2024) “Explainable Artificial Intelligence (XAI) in Finance: A Systematic Literature Review”, Springer.

Eysenck, M. W.; 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”, Porto Alegre, Artmed.

Nogueira, G. M. T. S. (2019) “Da inteligência artificial na intermediação financeira: excuro sobre a consultoria para investimento automatizada”, Lisboa, Tese de Doutorado.

OpenAI. (2025) “OpenAI API Reference”, <https://platform.openai.com/docs/api-reference/introduction>, Maio.

OpenAI. (2025) “Fine-tuning Guide”, <https://platform.openai.com/docs/guides/fine-tuning>, Maio.

Pontes, R. (2011) “Inteligência artificial nos investimentos”, Clube de Autores.

Ragazzo, C., Tolentino, M., 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?)”.

Russell, S., Norvig, P. (2021) “Artificial Intelligence: A Modern Approach”, Pearson, 4th edition.

Silva, F. M., Lenz, M. L., Freitas, P. H. C. (2019) “Inteligência Artificial”, Porto Alegre, Sagah.

Wuerges, A. F. E., Borba, J. A. (2010) “Redes neurais, lógica nebulosa e algoritmos genéticos: aplicações e possibilidades em finanças e contabilidade”, *JISTEM-Journal of Information Systems and Technology Management*, v. 7, p. 163-182.

Yoshinaga, C. E., Castro, F. H. (2023) “Inteligência artificial: a vanguarda das finanças”, *GV-EXECUTIVO*, v. 22, n. 3.