



Entre o medo e a euforia: um modelo de IA para classificação do sentimento coletivo no mercado financeiro

Recebido: 13/03/2026
Aprovado: 10/04/2026

Victor Moreira de Moraes: Graduando em Engenharia de Software, Centro Universitário Opet (UNIOPET), Curitiba, Paraná, Brasil. E-mail: victormoreira3202@gmail.com

Claudio Bilyk: Mestre Profissional em Desenvolvimento de Tecnologia, Centro Universitário Opet (UNIOPET), Curitiba, Paraná, Brasil.
E-mail: claudiobilyk@uniopet.edu.br

RESUMO

O mercado financeiro é influenciado não apenas por fatores técnicos e econômicos, mas também pelo comportamento coletivo dos investidores, frequentemente impulsionado por emoções como medo, euforia ou pânico. Esses estados emocionais afetam decisões de compra e venda, contribuindo para movimentos irracionais e inesperados nos preços dos ativos. Com base nesse fenômeno, este trabalho desenvolveu um sistema de inteligência artificial voltado à classificação do sentimento coletivo do mercado financeiro brasileiro, em torno de uma ação específica (PETR4), com foco em identificar estados emocionais como pânico, medo, neutralidade, otimismo e euforia. O sistema realizou a coleta de dados por meio de web scraping em portais de notícias econômicas nacionais, armazenando os conteúdos em um banco de dados relacional (PostgreSQL). Em seguida, cada notícia foi analisada por um modelo de linguagem de grande porte (Llama 3.1:8B, executado via Ollama), que atribuiu uma pontuação de sentimento em escala de 1 a 10, uma nota de relevância de 1 a 5 e uma breve explicação da avaliação. Posteriormente, os resultados foram agrupados em períodos semanais, calculando-se médias ponderadas pela relevância, o que permitiu observar a evolução do “humor” do mercado ao longo do tempo. O objetivo foi mostrar claramente como as emoções do mercado fluam e como a inteligência artificial pode ser usada para compreender melhor o comportamento dos investidores. Com isso, demonstrou-se que, ao incorporar uma análise emocional ao processo de investimentos, é possível apoiar decisões mais equilibradas, unindo análises técnicas com uma visão mais humana e realista, o que pode contribuir para estratégias mais robustas, especialmente em momentos de instabilidade.

PALAVRAS-CHAVE: Inteligência Artificial; Sentimento de Mercado; Psicologia do Investidor; LLM; Economia Comportamental; PETR4.

Between fear and euphoria: an AI model for classifying collective sentiment in the financial market

ABSTRACT

The financial market is influenced not only by technical and economic factors but also by the collective behavior of investors, often driven by emotions such as fear, euphoria, or panic. These emotional states affect buying and selling decisions, contributing to irrational and unexpected movements in asset prices. Based on this phenomenon, this work developed an artificial intelligence system aimed at classifying the collective sentiment of the Brazilian financial market, specifically focused on one stock (PETR4). The system collected data through web scraping from national financial news portals, storing the contents in a relational database (PostgreSQL). Each news item was then analyzed by a large language model (Llama 3.1:8B, executed via Ollama), which assigned a sentiment score on a 1–10 scale, a relevance rating from 1 to 5, and a brief explanatory note. Subsequently, the results were aggregated on a weekly basis, calculating relevance-weighted averages, which allowed the evolution of the market’s “mood” to be observed over time. The goal was to clearly demonstrate how market emotions fluctuate and how artificial intelligence can be used to better understand investor behavior. By incorporating emotional analysis into the investment process, this work showed that it is possible to support more balanced decisions, combining technical analysis with a more human and realistic perspective, which can contribute to stronger strategies, especially in times of instability.



KEYWORDS: Artificial Intelligence; Market Sentiment; Investor Psychology; LLM; Behavioral Economics; PETR4.

1. INTRODUÇÃO

O comportamento dos investidores mostrou-se um fator decisivo na dinâmica do mercado financeiro, muitas vezes superando análises puramente técnicas ou fundamentos econômicos. Fatores emocionais como medo, euforia ou insegurança coletiva desencadearam movimentos bruscos de compra ou venda, impactando diretamente a formação de preços e a estabilidade dos ativos. Eventos como crises políticas, decisões inesperadas de política monetária ou tensões geopolíticas foram exemplos recorrentes que levaram a reações exacerbadas do mercado, caracterizadas por fases de pânico ou otimismo extremo. Conforme Shiller (2000), “a psicologia do investidor é um campo essencial para compreender a volatilidade do mercado, uma vez que as emoções coletivas podem impulsionar movimentos de mercado que não se baseiam em fundamentos econômicos tradicionais”. Esse tipo de reação, frequentemente associado à chamada “psicologia do investidor”, esteve diretamente relacionado ao campo da economia comportamental, que estuda como fatores cognitivos e emocionais influenciam decisões financeiras. Nesse contexto, tornou-se relevante o desenvolvimento de mecanismos capazes de mapear o sentimento coletivo do mercado de forma estruturada e quantificável. A compreensão desses ciclos emocionais contribuiu para decisões de investimento mais equilibradas, permitindo antecipar momentos de irracionalidade ou identificar oportunidades ocultas por trás do comportamento coletivo. Kahneman (2011) destaca que “a economia comportamental demonstra que decisões financeiras são influenciadas por vieses cognitivos e emocionais, os quais podem gerar comportamentos herdados e tendências de mercado”.

Neste trabalho, foi desenvolvido um sistema de inteligência artificial (IA) voltado à classificação do sentimento coletivo do mercado financeiro brasileiro, com escopo reduzido para análise de uma ação específica: PETR4 (Petrobras). O sistema realizou a coleta de notícias econômicas por meio de *web scraping* em portais especializados, armazenando-as em um banco de dados PostgreSQL. Em seguida, cada notícia foi analisada por um modelo de linguagem de grande porte (Llama 3.1:8B, executado via Ollama), que atribuiu automaticamente notas de sentimento e relevância, além de uma breve explicação para cada avaliação. A relevância do estudo esteve em demonstrar como a IA pôde ser utilizada como uma ferramenta de apoio à leitura comportamental do mercado, especialmente em



contextos de alta volatilidade, nos quais decisões movidas por impulso se tornam comuns. A incorporação dessa camada emocional ao processo de análise de investimentos representou uma contribuição para estratégias mais completas, combinando precisão técnica com sensibilidade humana. Davenport e Ronanki (2018) apontam que “a integração de análises quantitativas com indicadores comportamentais fornecidos por IA pode aprimorar significativamente a tomada de decisão financeira, reduzindo erros motivados por emoções”. Este artigo foi organizado da seguinte forma: na seção 2, apresenta-se o referencial teórico, com base na psicologia do investidor, sentimento do mercado e fundamentos da IA aplicada. A seção 3 descreve a metodologia adotada. A seção 4 expõe a aplicação prática desenvolvida, a seção 5 cita os diferenciais do projeto e, por fim, a seção 6 apresenta o tipo de pesquisa realizada, a seção 7 representa os resultados da pesquisa, a seção 8 apresenta possíveis melhorias futuras e a seção 9 a conclusão.

2. REVISÃO DE LITERATURA

Este tópico apresenta a revisão dos seguintes temas essenciais para a fundamentação teórica e o desenvolvimento do projeto: 2.1 Psicologia do Investidor, 2.2 Sentimento do Mercado, 2.3 Inteligência Artificial Aplicada à Análise de Sentimento e 2.4 Ferramentas utilizadas, onde é explicado o porquê da escolha de cada uma das ferramentas e para que elas servem. Cada uma dessas áreas contribui para a compreensão dos aspectos comportamentais, econômicos e tecnológicos envolvidos na análise automatizada de notícias financeiras, formando a base para a implementação do sistema proposto.

2.1 Psicologia do investidor

A teoria econômica clássica pressupõe que os agentes são racionais e tomam decisões baseadas em informações completas. No entanto, estudos em economia comportamental demonstram que os investidores frequentemente agem de maneira irracional, influenciados por emoções e heurísticas cognitivas (KAHNEMAN & TVERSKY, 1979). A Teoria da Perspectiva, desenvolvida por Kahneman e Tversky (1979), destaca que os indivíduos tendem a valorizar mais as perdas do que os ganhos equivalentes, fenômeno conhecido como aversão à perda. Essa teoria explica por que investidores podem manter ativos em queda por mais tempo, na esperança de recuperação, e vender rapidamente ativos em alta para garantir lucros. Além disso, comportamentos como o efeito manada, onde investidores seguem as ações de outros sem análise própria, e o viés de confirmação, que



leva os indivíduos a buscar informações que confirmem suas crenças pré-existentes, são comuns no mercado financeiro (THALER, 2017). Esses vieses podem resultar em decisões que podem levar a resultados negativos e contribuir para a formação de bolhas especulativas.

2.2 Sentimento de mercado

O sentimento do mercado refere-se ao clima emocional predominante entre os investidores, influenciando suas decisões de compra e venda. Esse sentimento pode ser de otimismo, pessimismo, medo ou euforia, afetando diretamente os preços dos ativos (SHILLER, 2000). Durante períodos de euforia, os investidores tendem a subestimar riscos e superestimar retornos, levando a avaliações inflacionadas de ativos. Por outro lado, em momentos de pânico, há uma aversão generalizada ao risco, resultando em vendas massivas e quedas abruptas nos preços (DEQUECH, 1999). A medição do sentimento do mercado pode ser realizada por meio da análise de notícias, redes sociais e indicadores como o índice de medo e ganância. Estudos demonstram que há uma correlação significativa entre o sentimento do mercado e os movimentos subsequentes dos preços dos ativos (MOURÃO, 2018).

2.3 Inteligência artificial aplicada à análise de sentimento

Um modelo de Inteligência Artificial (IA) é uma máquina que aprende a realizar tarefas de forma autônoma, imitando processos de raciocínio humano. Como afirma Andrew Ng (2016), um dos maiores especialistas em IA: “A inteligência artificial é a nova eletricidade. Assim como a eletricidade transformou muitas indústrias no século 20, a IA fará o mesmo no século 21.”

Dentro da IA, o Processamento de Linguagem Natural (NLP) é a área responsável por permitir que computadores compreendam e interajam com a linguagem humana. Como explica Chris Manning, professor de Inteligência Artificial e Linguística em Stanford, “o objetivo do NLP é permitir que os computadores compreendam, interpretem e gerem a linguagem humana de forma útil”. Isso possibilita que sistemas automatizados leiam e interpretem notícias financeiras, identificando sentimentos e padrões que influenciam o mercado.

Neste trabalho, diferentemente de abordagens baseadas em algoritmos supervisionados tradicionais (como TF-IDF ou classificadores treinados manualmente),



utilizou-se um modelo de linguagem de grande porte (LLM) já pré-treinado: o Llama 3.1:8B, executado localmente via Ollama. Esse modelo recebeu prompts específicos e foi capaz de analisar o texto das notícias e atribuir:

- Um escore de sentimento (1 a 10),
- Um grau de relevância (1 a 5),
- E uma breve explicação textual.

Esse tipo de aplicação reforça o avanço trazido pelos LLMs: em vez de depender de classificadores treinados do zero, foi possível aproveitar o conhecimento contextual de um modelo robusto para extrair insights diretamente dos textos, com alto nível de detalhamento e flexibilidade.

No contexto da ação PETR4, essa análise automatizada permitiu observar como variações no noticiário impactaram o humor coletivo dos investidores, evidenciando padrões emocionais de pânico, medo, neutralidade, otimismo ou euforia.

2.4 Ferramentas utilizadas

Python é uma linguagem de programação popular, versátil e de fácil aprendizado, amplamente utilizada em projetos de Inteligência Artificial e análise de dados. Possui uma sintaxe simples e legível, o que facilita o desenvolvimento e a manutenção de sistemas. Segundo Van Rossum (2001), *“Python é uma linguagem com uma sintaxe simples e de fácil leitura, projetada para promover a legibilidade do código e a produtividade do programador.”*

BeautifulSoup e Requests são bibliotecas voltadas para extração de dados da web. A Requests é responsável por realizar requisições HTTP, permitindo acessar o conteúdo de páginas da internet, enquanto a BeautifulSoup possibilita analisar e estruturar o código HTML, extraindo informações de forma organizada. Segundo Richardson (2007), *“bibliotecas de raspagem de dados como BeautifulSoup permitem estruturar informações não organizadas da web, transformando-as em dados úteis para pesquisa e análise.”*

PostgreSQL é um sistema de gerenciamento de banco de dados relacional de código aberto, reconhecido por sua robustez, segurança e aderência a padrões SQL. É amplamente utilizado em aplicações que demandam consistência e alto desempenho. Conforme Momjian (2001), *“o PostgreSQL é um sistema de banco de dados objeto-relacional avançado, que oferece confiabilidade, extensibilidade e aderência a padrões.”*

Ollama e Llama 3.1:8B formam a base de inteligência artificial do projeto. O Ollama é uma plataforma que permite executar modelos de linguagem de grande porte (LLMs)



localmente, sem depender de serviços em nuvem, enquanto o Llama 3.1:8B é um modelo avançado de processamento de linguagem natural desenvolvido pela Meta AI, capaz de compreender e gerar texto de maneira contextual. Segundo Touvron et al. (2023), “os modelos da família LLaMA foram desenvolvidos para serem eficientes e acessíveis, mantendo desempenho competitivo em tarefas de linguagem natural.”

Streamlit é uma ferramenta que possibilita a criação de interfaces gráficas interativas voltadas à ciência de dados, transformando scripts em Python em aplicações web de forma rápida e simples. De acordo com Treuille, Hashimoto e Killeen (2019), criadores do Streamlit, “a proposta é simplificar a construção de aplicações de ciência de dados, tornando o processo tão rápido quanto escrever scripts em Python.”

3. DESENVOLVIMENTO

Para alcançar os objetivos propostos, este trabalho foi estruturado em quatro etapas principais: (1) coleta e armazenamento de dados, (2) análise automatizada com modelo de linguagem, (3) cálculo do índice de sentimento ponderado e (4) desenvolvimento da interface interativa. Cada etapa foi planejada de forma a garantir que o sistema funcionasse de maneira automatizada, confiável e compreensível para usuários não técnicos.

A primeira etapa consistiu na coleta de dados, realizada por meio de web scraping em portais de notícias financeiras nacionais, como MoneyTimes, InfoMoney e G1. As informações coletadas — título; data de publicação; fonte; conteúdo — foram armazenadas em um banco de dados relacional PostgreSQL, garantindo organização temporal e evitando duplicidades.

Na segunda etapa, cada notícia armazenada foi submetida a um modelo de linguagem de grande porte (LLM), o Llama 3.1:8B, executado localmente via Ollama. O modelo recebeu instruções específicas (prompt engineering) para analisar o texto da notícia e retornar três informações principais: um escore de sentimento (em escala de 1 a 10), um grau de relevância (de 1 a 5) e uma explicação resumida para a classificação atribuída.

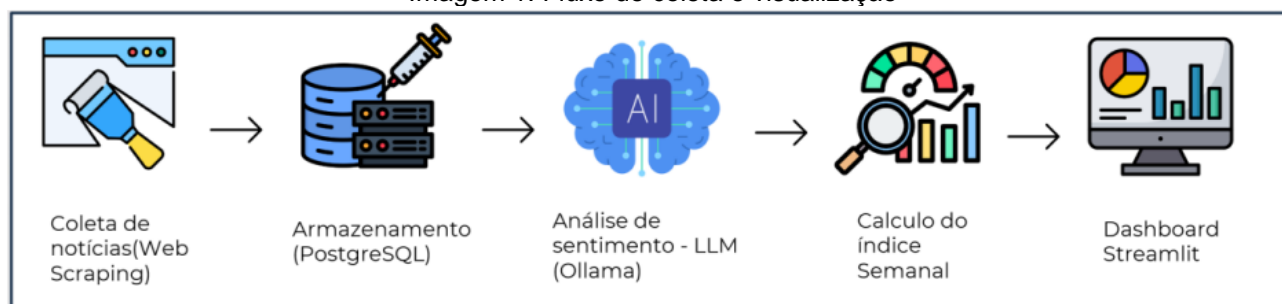
A terceira etapa envolveu o cálculo de índices semanais de sentimento, que foram obtidos a partir da média ponderada entre o escore de sentimento e o grau de relevância. Essa abordagem permitiu dar maior peso a notícias consideradas mais relevantes pelo modelo, produzindo uma visão mais precisa da evolução do “humor coletivo” do mercado em torno da ação PETR4 ao longo do tempo. Por fim, a quarta etapa compreendeu o desenvolvimento da interface interativa, utilizando o Streamlit. O painel criado exibiu gráficos



da evolução semanal do sentimento, categorizando-o em estados emocionais como pânico, medo, neutralidade, otimismo e euforia. Além disso, apresentou a lista de notícias analisadas, acompanhadas de suas respectivas classificações e explicações, tornando o sistema prático tanto para investidores quanto para analistas de mercado.

Temos aqui uma imagem do fluxo completo de coleta e visualização do sentimento do mercado, que ilustra as quatro etapas principais descritas acima. A Imagem 1 apresenta o processo de coleta de dados por meio de *web scraping*, passando pelo armazenamento das notícias no banco de dados PostgreSQL, seguido pela análise automatizada realizada pelo modelo LLama 3.1:8B via Ollama. O fluxo culmina na geração do índice de sentimento semanal, que é visualizado de forma interativa no dashboard desenvolvido com Streamlit. Essa imagem ajuda a visualizar como os dados fluem de uma etapa para outra, garantindo que cada parte do sistema esteja integrada e funcione de maneira automatizada.

Imagem 1: Fluxo de coleta e visualização



Fonte: Elaborado pelo autor

3.1 Coleta de dados

Nesta etapa, as notícias foram coletadas diretamente de portais financeiros nacionais, em especial MoneyTimes, InfoMoney e G1. Por meio de técnicas de *web scraping* implementadas em Python, utilizando as bibliotecas Requests e BeautifulSoup. O objetivo foi compor um conjunto de dados atualizado, deduplicado e rastreável, adequado às fases de análise de sentimento e agregação.

O escopo da coleta restringiu-se a conteúdos públicos, em português, relacionados ao mercado brasileiro e, em especial, à ação PETR4 (Petrobras). Foram extraídos metadados como título, URL, fonte, data de publicação e corpo do texto, todos armazenados de forma estruturada em um banco de dados relacional.



3.2 Limpeza e normalização

Após a coleta, foi realizada uma etapa de limpeza e normalização do texto, necessária para padronizar as informações antes de enviá-las para análise. Esse processo envolveu:

- Remoção de elementos não textuais (tags HTML, scripts, anúncios e trechos de “leia também” ou conteúdos relacionados);
- Padronização ortográfica e de codificação, garantindo acentuação correta e formato UTF-8;
- Tratamento de datas, convertendo todas para o padrão YYYY-MM-DD HH:MM:SS em UTC;
- Remoção de duplicidades, utilizando como critérios a repetição de URLs e a comparação de títulos semelhantes acompanhados da mesma data.

3.3 Estruturação dos dados

Os artigos finais foram armazenados em um banco PostgreSQL, em tabelas que continham índices por URL e data de publicação. Essa escolha garantiu integridade, rapidez em consultas e facilidade para integração com as etapas posteriores do pipeline.

Ao término desta fase, obteve-se um conjunto confiável de notícias sobre a PETR4, limpo e deduplicado, pronto para ser processado pelo modelo de inteligência artificial na etapa seguinte.

3.4 Análise de sentimento

Após a etapa de coleta e limpeza, cada notícia armazenada foi submetida a uma análise de sentimento automatizada utilizando um modelo de linguagem de grande porte (LLM). Para isso, foi adotado o Llama 3.1:8B, executado localmente por meio do Ollama, aproveitando a capacidade computacional disponível (GPU dedicada e processamento local).

O modelo recebeu prompts específicos com instruções claras, nas quais foi solicitado que:

- Atribuisse um escore de sentimento em uma escala de 1 a 10 (do pânico extremo à euforia extrema);
- Avaliasse a relevância da notícia para o mercado em uma escala de 1 a 5;
- Apresentasse uma explicação breve justificando a classificação atribuída. O resultado da análise foi retornado em formato JSON, o que permitiu a integração direta com o



banco de dados PostgreSQL. Dessa forma, cada notícia passou a ter associada uma avaliação estruturada composta por sentimento, relevância e justificativa.

O uso de um LLM pré-treinado trouxe duas vantagens principais:

1. eliminou a necessidade de treinar modelos supervisionados complexos (como TF-IDF ou Random Forest), reduzindo tempo de implementação;
2. possibilitou análises mais contextuais e detalhadas, já que o modelo foi capaz de interpretar nuances textuais comuns em notícias financeiras, como incerteza, otimismo exagerado ou tom de alerta.

No contexto específico da ação PETR4, essa etapa foi fundamental para capturar como o noticiário repercutiu emocionalmente entre investidores, permitindo observar flutuações entre estados de pânico, medo, neutralidade, otimismo e euforia.

3.5 Cálculo do índice de sentimento ponderado

Concluída a etapa de análise individual das notícias, foi necessário consolidar os resultados em um indicador agregado que representasse o humor coletivo do mercado em torno da ação PETR4. Para isso, desenvolveu-se um método de cálculo de índice ponderado, combinando as notas de sentimento e relevância atribuídas pelo modelo de linguagem.

Cada notícia possuía:

- um escore de sentimento (1 a 10), representando o tom predominante;
- uma nota de relevância (1 a 5), indicando o quanto aquele conteúdo era significativo para o mercado.

O índice semanal foi obtido pela média ponderada dessas avaliações, onde a relevância funcionou como peso, de forma que notícias consideradas mais importantes tiveram maior impacto no resultado final.

Formalmente, o cálculo seguiu a seguinte lógica:

$$\text{Índice Semanal} = \frac{\sum (\text{sentimento}_i \times \text{relevância}_i)}{\sum \text{relevância}_i} \quad (1)$$



Esse índice foi calculado em janelas semanais, permitindo acompanhar a evolução do sentimento de mercado ao longo do tempo. A partir dos valores numéricos, definiu-se uma classificação qualitativa que facilitou a interpretação dos resultados:

- **0 a 2** → Pânico
- **2 a 4** → Medo
- **4 a 6** → Neutralidade
- **6 a 8** → Otimismo
- **8 a 10** → Euforia

Dessa forma, o sistema não apenas forneceu números, mas traduziu-os em categorias emocionais, facilitando a compreensão por parte de investidores e analistas. Esse indicador semanal consolidado representou uma camada adicional de inteligência, capaz de sintetizar múltiplas notícias em uma visão única sobre o humor do mercado.

3.6 Visualização de resultados

Após o cálculo do índice semanal de sentimento, desenvolveu-se uma interface interativa utilizando o Streamlit, com o objetivo de apresentar os resultados de forma clara, acessível e visualmente intuitiva.

A aplicação exibiu inicialmente um gráfico de linha, representando a evolução do índice de sentimento ao longo das semanas. A escala numérica (0 a 10) foi associada às categorias emocionais definidas no estudo: pânico, medo, neutralidade, otimismo e euforia. Dessa forma, o usuário pôde identificar rapidamente em que “humor coletivo” o mercado se encontrava em cada período.

Além do gráfico, o painel também mostrou métricas destacadas, como o valor do índice da semana mais recente e sua classificação correspondente. Por exemplo, caso o índice calculado fosse 6,4, a aplicação destacava o humor do mercado como otimismo, tornando a interpretação imediata.

Na parte inferior da interface, foi apresentada uma lista expandida de notícias analisadas, contendo:

- o título da notícia,
- a data de publicação,
- o sentimento atribuído (nota de 1 a 10),
- a relevância (de 1 a 5),
- e a explicação textual gerada pelo modelo de linguagem.



Cada notícia também manteve o link para a fonte original, permitindo que o usuário pudesse consultar diretamente o conteúdo completo.

Essa abordagem combinou análise quantitativa (gráficos e índices) e análise qualitativa (explicações do LLM), criando uma ferramenta prática tanto para investidores quanto para analistas de mercado. A interface não apenas resumiu a oscilação do sentimento, mas também forneceu transparência ao detalhar o raciocínio por trás de cada classificação.

4. DIFERENCIAL DO PROJETO

O que deixou este projeto único foi a união de duas áreas: a economia comportamental, que estuda como as emoções afetam os investidores, e a inteligência artificial, que analisou as notícias de forma automática.

Outro ponto importante foi a escolha de usar o Llama 3.1:8B rodando localmente no Ollama. Isso trouxe mais liberdade e controle, sem depender de serviços externos na nuvem, e mostrou que é possível aplicar modelos de linguagem avançados em um computador pessoal.

Além disso, a criação de um painel interativo no Streamlit transformou os resultados em algo prático e fácil de usar. Assim, a solução deixou de ser apenas um experimento acadêmico e passou a ter cara de um produto que pode ajudar investidores no dia a dia.

5. TIPO DE PESQUISA

Este trabalho foi uma pesquisa aplicada, porque buscou resolver um problema real: entender o sentimento do mercado sobre a ação PETR4 a partir das notícias.

Quanto aos objetivos, foi uma pesquisa exploratória e descritiva. Exploratória porque testou uma ideia nova, que é usar modelos de linguagem modernos nesse tipo de análise. Descritiva porque mostrou, de forma prática, como cada notícia recebeu uma nota de sentimento e relevância.

A pesquisa teve uma parte teórica, onde foram estudados conceitos de economia comportamental e inteligência artificial, e uma parte prática, onde o sistema foi realmente construído, testado e aplicado.

Por fim, foi também uma pesquisa quantitativa, já que os resultados foram transformados em números — notas de sentimento e relevância — e depois agrupados em médias para mostrar como o humor do mercado mudou ao longo do tempo.



7. RESULTADOS DA PESQUISA

Os resultados obtidos indicam que o sistema desenvolvido possui potencial promissor para compreender o sentimento coletivo do mercado financeiro brasileiro a partir do noticiário econômico, especialmente em torno da ação PETR4, que foi a escolhida para a demonstração.

O modelo foi capaz de classificar emoções predominantes — como medo, neutralidade, otimismo e euforia — e transformá-las em métricas quantitativas, fornecendo uma primeira visão mensurável do “humor” do mercado.

Durante os testes, observou-se uma coerência parcial entre os índices de sentimento gerados e o comportamento real das cotações da PETR4.

Um exemplo ilustrativo ocorreu na semana de 03 de novembro de 2025, quando o sistema registrou um índice médio de seis vírgula sessenta e sete (6,97), classificado na zona de Otimismo.

Nesse mesmo período, as ações da Petrobras apresentaram uma valorização aproximada de seis vírgula nove por cento (6,9%), passando de trinta reais e dez centavos (R\$ 30,10) no início da semana para trinta e dois reais e dezoito centavos (R\$ 32,18) no fechamento de 07 de novembro de 2025.

Essa variação sugere uma correspondência entre o tom positivo predominante nas notícias e a movimentação real do mercado, indicando que o modelo é capaz de captar tendências emocionais compatíveis com os comportamentos observados.

Embora não se possa afirmar uma relação causal direta, o resultado indica que o modelo consegue capturar tendências emocionais compatíveis com os movimentos observados.

Nas semanas anteriores, o sentimento médio manteve-se entre 6,0 e 7,0, coincidindo com períodos de menor oscilação nas cotações — comportamento que reforça a consistência qualitativa do método, mesmo em janelas curtas de análise.

Esses achados demonstram que o modelo de linguagem utilizado (Llama 3.1:8B, executado via Ollama) foi capaz de interpretar o contexto das notícias e gerar avaliações coerentes em termos qualitativos.

Entretanto, não se trata de um sistema preditivo consolidado, e sim de uma prova de conceito exploratória, que evidencia o potencial da abordagem, mas ainda carece de volume de dados, refinamento metodológico e validação estatística para conclusões mais robustas.



Fatores externos — como variações no preço do petróleo, decisões políticas e eventos macroeconômicos — continuam a exercer influência significativa sobre o mercado e não foram controlados nesta fase.

Dessa forma, a análise de sentimento deve ser entendida como uma camada complementar de leitura comportamental, e não como ferramenta isolada de previsão financeira.

Os resultados também dialogam com a literatura clássica sobre comportamento financeiro. A correspondência entre o tom do noticiário e a oscilação da PETR4 reforça as observações de Shiller (2000), que descreve como as emoções coletivas influenciam o mercado de forma não racional.

As flutuações entre medo e otimismo observadas no modelo refletem a Teoria da Perspectiva proposta por Kahneman e Tversky (1979), segundo a qual os investidores reagem de maneira desproporcional a ganhos e perdas.

De modo semelhante, as respostas emocionais identificadas nas notícias ecoam as análises de Thaler (2017) sobre a irracionalidade dos agentes econômicos e o papel dos vieses cognitivos nas bolhas e quedas de mercado.

Sob a ótica da tecnologia, o trabalho exemplifica o que Davenport e Ronanki (2018) descrevem como a integração entre dados quantitativos e cognitivos no apoio à decisão, utilizando a IA como ferramenta de análise interpretativa.

Essa visão converge com o argumento de Ng (2016), que posiciona a inteligência artificial como uma força transformadora, capaz de ampliar a compreensão humana sobre fenômenos complexos — neste caso, o comportamento emocional do mercado.

Em conjunto, os resultados e os diálogos teóricos indicam que o projeto apresenta viabilidade técnica e relevância científica, ainda que em estágio inicial.

8. MELHORIAS FUTURAS

Embora os resultados obtidos nesta pesquisa sejam coerentes e indiquem potencial de desenvolvimento, o sistema ainda se encontra em estágio inicial e oferece múltiplas oportunidades de aprimoramento técnico e metodológico.

As sugestões abaixo visam fortalecer a robustez analítica, a escalabilidade e a aplicabilidade prática do modelo proposto:

- 1. Ampliação da base de dados** – Aumentar o número de fontes e o período histórico de coleta, incluindo portais internacionais e diferentes tipos de veículos (jornais,



relatórios corporativos e redes sociais), para formar uma amostra mais representativa e balanceada.

- 2. Automação contínua do pipeline** – Implementar rotinas agendadas de coleta e análise (por exemplo, execução diária ou semanal automatizada), permitindo monitorar a evolução do sentimento de mercado em tempo real.
- 3. Refinamento do modelo de linguagem** – Testar versões mais recentes ou maiores do Llama, bem como outros LLMs especializados em domínio financeiro (como FinBERT ou Mistral Finance), comparando desempenho e consistência das classificações.
- 4. Análise estatística e validação quantitativa** – Correlacionar os índices de sentimento com séries históricas de preços, volumes de negociação e volatilidade, aplicando testes estatísticos (como coeficiente de correlação de Pearson) para quantificar o grau de relação entre sentimento e variação de preço.
- 5. Integração de variáveis macroeconômicas** – Incorporar fatores externos como cotação do petróleo, taxa de câmbio e indicadores econômicos, buscando compreender como esses elementos influenciam o sentimento detectado e o comportamento das ações.
- 6. Aprimoramento da interface e da experiência do usuário** – Expandir o painel interativo com novos filtros (por período, fonte ou intensidade do sentimento), alertas automáticos para mudanças bruscas de humor e exportação de relatórios.
- 7. Exploração de outros ativos e mercados** – Aplicar a mesma metodologia a ações de diferentes setores e empresas, possibilitando comparações entre o sentimento de mercado e o desempenho de diversos papéis ou índices setoriais.

Essas melhorias permitirão evoluir o projeto de uma prova de conceito acadêmica para uma plataforma funcional de análise comportamental de mercado, capaz de integrar dados econômicos, emocionais e tecnológicos em uma única estrutura interpretativa.

9. CONCLUSÃO

O presente trabalho teve como objetivo geral investigar se a análise de sentimento, baseada em modelos de linguagem de grande porte, pode contribuir para a compreensão do comportamento do mercado financeiro brasileiro.

De forma mais específica, buscou-se: (i) desenvolver um sistema capaz de coletar e processar notícias financeiras; (ii) aplicar um modelo de linguagem para classificar o tom



emocional das publicações; e (iii) comparar os resultados obtidos com o comportamento real de uma ação (utilizado PETR4), a fim de avaliar a coerência entre o sentimento captado e a movimentação de mercado.

A pergunta que guiou esta pesquisa foi: *“É possível identificar e mensurar o sentimento coletivo do mercado financeiro brasileiro por meio da análise de notícias, utilizando inteligência artificial?”*

Com base nos resultados apresentados, conclui-se que a resposta é parcialmente positiva. Os experimentos mostraram que há correspondência qualitativa entre o sentimento detectado nas notícias e as variações das cotações da Petrobras (ação escolhida), o que demonstra o potencial da metodologia proposta, ainda que de forma exploratória e limitada.

A aplicação prática desenvolvida demonstrou a viabilidade técnica de empregar modelos de linguagem de grande porte na análise de sentimento do mercado financeiro.

Por meio da coleta automatizada de notícias, processamento textual e interpretação semântica, foi possível identificar tendências emocionais associadas ao noticiário da ação PETR4, transformando informações qualitativas em indicadores quantitativos compreensíveis.

O sistema construído — do web scraping ao painel interativo — representou um fluxo completo de análise comportamental, ainda em escala experimental, mas funcional o suficiente para comprovar a coerência inicial da abordagem.

A correlação observada entre o sentimento médio das notícias e a variação das cotações da Petrobras sugere que a análise de sentimento pode servir como uma camada complementar de interpretação de mercado, ajudando a compreender o impacto emocional das informações sobre o comportamento dos investidores.

Entretanto, não se trata de um sistema preditivo consolidado, e sim de uma prova de conceito que evidencia o potencial do uso de inteligência artificial no campo da economia comportamental.

O tamanho reduzido da amostra, a ausência de controle de variáveis externas e a falta de validação estatística impedem conclusões generalizáveis, mas indicam um caminho de pesquisa viável e promissor.

Os resultados também reforçam o diálogo com a literatura teórica. As reações emocionais identificadas pelo modelo refletem os princípios da Teoria da Perspectiva de Kahneman e Tversky (1979), que descreve como os investidores reagem de maneira desproporcional a ganhos e perdas. Do mesmo modo, confirmam a visão de para quem o



componente emocional é um dos principais motores de flutuação dos mercados, mesmo em ambientes dominados por dados e automatização.

A inteligência artificial, aqui representada pelo modelo Llama 3.1:8B via Ollama, não substitui a análise humana, mas atua como Thaler (2017) e Shiller (2000), instrumento de apoio interpretativo, capaz de processar grandes volumes de informação e revelar padrões de sentimento que escapariam à observação intuitiva.

A justificativa central do projeto está no esforço de unir tecnologia e comportamento humano para criar formas de compreender o mercado financeiro.

O trabalho beneficia não apenas o meio acadêmico — ao propor uma metodologia de estudos de economia comportamental com uso de IA, mas também a própria faculdade, ao reforçar o papel da instituição como espaço de pesquisa aplicada e inovação tecnológica.

No âmbito pessoal, a realização deste projeto proporcionou o desenvolvimento de competências técnicas e analíticas, consolidando o aprendizado em programação, banco de dados e inteligência artificial, além de fortalecer a autonomia e o pensamento crítico no processo de pesquisa.

Conclui-se, portanto, que a proposta *Entre o Medo e a Euforia* cumpre seu propósito de explorar os limites e as possibilidades da inteligência artificial na economia comportamental, oferecendo uma base inicial para o desenvolvimento de ferramentas que unem dados e emoção.

Mais do que um produto final, o projeto representa um ponto de partida para novas investigações sobre como o sentimento coletivo, mediado pela linguagem, pode ser medido, visualizado e, futuramente, integrado à análise financeira de maneira ética, interpretável e responsável.

REFERÊNCIAS

BIRD, S.; KLEIN, E.; LOPER, E. (2009). **Natural Language Processing with Python**. O'Reilly Media.

DAVENPORT, T.; RONANKI, R. (2018). **Artificial Intelligence for the Real World**. Harvard Business Review.

DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. (2019). BERT: **Pre-training of Deep Bidirectional Transformers for Language Understanding**. NAACL-HLT.

HUNTER, J. D. (2007). Matplotlib: A 2D Graphics Environment. **Computing in Science & Engineering**, 9(3), p. 90–95.



- KAHNEMAN, D. (2011). **Thinking, Fast and Slow**. Farrar, Straus and Giroux.
- KAHNEMAN, D.; TVERSKY, A. (1979). Prospect Theory: An Analysis of Decision under Risk. **Econometrica**, 47(2), p. 263–291.
- LIAW, A.; WIENER, M. (2002). Classification and Regression by RandomForest. **R News**, 2(3), p. 18–22.
- MANNING, C. D. (2015). **Foundations of Statistical Natural Language Processing**. MIT Press.
- MANNING, C. D. (2019). **Natural Language Processing with Deep Learning**. Stanford University.
- MARTINS, E.; SILVA, L. (2015). A IA na análise de sentimentos do mercado financeiro. **Journal of Finance and Technology**.
- MCKINNEY, W. (2010). Data Structures for Statistical Computing in Python. **Proceedings of the 9th Python in Science Conference**.
- MOMJIAN, B. (2001). **PostgreSQL: Introduction and Concepts**. Addison-Wesley. NG, A. (2016). Artificial Intelligence is the New Electricity. Medium.
- RICHARDSON, L. (2007). **Beautiful Soup Documentation**. Disponível em: <https://www.crummy.com/software/BeautifulSoup/>.
- SHILLER, R. J. (2000). **Irrational Exuberance**. Princeton University Press.
- THALER, R. H. (2017). Misbehaving: **The Making of Behavioral Economics**. W. W. Norton & Company.
- TOUVRON, H. et al. (2023). LLaMA: Open and Efficient Foundation Language Models. **arXiv preprint arXiv:2302.13971**.
- TREUILLE, A.; HASHIMOTO, T.; KILLEEN, A. (2019). **Streamlit: Turning data scripts into shareable web apps**. Disponível em: <https://streamlit.io>.
- VAN ROSSUM, G. (2001). Python: **A Programming Language for the Future**. Python Software Foundation.